

INTELIGENCIA ARTIFICIAL APLICADA A LA ALIMENTACIÓN ANIMAL: FORMULACIÓN, SEGURIDAD, BIENESTAR Y EFICIENCIA

José Manuel López, BSc, MD, PhD
INTABIOTECH · Dirección Técnica

Inteligencia artificial aplicada a la alimentación animal: formulación, seguridad, bienestar y eficiencia productiva

De la optimización de piensos a los sistemas predictivos de nutrición, salud, control de riesgos y trazabilidad en la ganadería de precisión

José Manuel López, BSc, MD, PhD

SERVICIO DE ESTUDIOS DE INTABIOTECH

I Edición · Julio de 2026

Información editorial

© 2026 José Manuel López. Todos los derechos reservados.

Título: Inteligencia artificial aplicada a la alimentación animal: formulación, seguridad, bienestar y eficiencia productiva.

Subtítulo: De la optimización de piensos a los sistemas predictivos de nutrición, salud, control de riesgos y trazabilidad en la ganadería de precisión.

Edición: Edición científica y editorial 1.0, julio de 2026.

Cita recomendada: López, J.M. (2026). *Inteligencia artificial aplicada a la alimentación animal: formulación, seguridad, bienestar y eficiencia productiva*.

Nota Técnica y Legal: La información técnica, jurídica y regulatoria se ofrece con finalidad científica y profesional. Su aplicación industrial exige validación específica para la especie, la instalación, el proceso, el producto y el marco normativo correspondiente.

Resumen

La incorporación de inteligencia artificial a la alimentación animal está modificando progresivamente la forma en que se caracterizan las materias primas, se formulan los piensos, se gestionan los procesos de fabricación, se detectan los riesgos de contaminación y se ajusta la nutrición a las necesidades reales de los animales. La convergencia entre sensores, espectroscopia, visión artificial, sistemas de alimentación automatizada, datos productivos, registros sanitarios y modelos de aprendizaje automático permite avanzar desde formulaciones estáticas basadas en valores medios hacia sistemas dinámicos de nutrición de precisión.

Este cambio ofrece oportunidades relevantes para mejorar el aprovechamiento de nutrientes, reducir el índice de conversión, anticipar desviaciones sanitarias, controlar micotoxinas y contaminantes, disminuir la excreción de nitrógeno y fósforo y adaptar la alimentación a la especie, línea genética, fase productiva, ambiente y estado fisiológico. Las investigaciones recientes muestran aplicaciones de aprendizaje automático tanto en la predicción de ingestión y rendimiento como en la formulación multicriterio, la vigilancia de contaminantes y la monitorización continua de salud y comportamiento. No obstante, la mayor parte de los desarrollos continúa dependiendo de conjuntos de datos históricos, entornos experimentales y modelos cuya capacidad de generalización industrial todavía debe ser demostrada.

La inteligencia artificial no elimina la incertidumbre inherente a la nutrición animal. Puede incluso amplificarla cuando los datos analíticos son incompletos, los animales utilizados para entrenar el modelo no representan la población real, las formulaciones se optimizan mediante objetivos excesivamente económicos o los sistemas de recomendación no incorporan restricciones fisiológicas, toxicológicas y de bienestar. Una predicción matemáticamente precisa puede resultar biológicamente incorrecta si se apoya en variables indirectas, correlaciones espurias o condiciones productivas diferentes de aquellas en las que se aplica.

El presente trabajo analiza de forma integrada las aplicaciones de inteligencia artificial en la formulación de piensos, la evaluación de materias primas, la nutrición de precisión, la gestión de micotoxinas, la salud y el bienestar animal, la eficiencia productiva y la trazabilidad. Asimismo, examina sus implicaciones jurídicas dentro del régimen europeo de seguridad de los piensos y del Reglamento de Inteligencia Artificial, prestando especial atención a la validación de modelos, la supervisión humana, la calidad de los datos, la trazabilidad probatoria y la distribución de responsabilidades entre proveedores tecnológicos, fabricantes de piensos, integradoras, veterinarios, nutricionistas y titulares de explotaciones.

La conclusión fundamental es que la IA aplicada a la alimentación animal debe gobernarse como una tecnología de intervención sobre sistemas biológicos y no como una mera herramienta informática de reducción de costes. Su legitimidad técnica y regulatoria dependerá de que pueda demostrar no solo mejoras productivas, sino también seguridad, robustez, explicabilidad suficiente, control humano efectivo y ausencia de deterioros inadvertidos en la salud y el bienestar de los animales.

Palabras clave: *inteligencia artificial; alimentación animal; formulación de piensos; nutrición de precisión; micotoxinas; materias primas; bienestar animal; salud animal; ganadería de precisión; trazabilidad; seguridad de los piensos; aprendizaje automático.*

Abstract

The incorporation of artificial intelligence into animal nutrition is progressively transforming the characterization of raw materials, feed formulation, manufacturing control, contaminant surveillance and the adjustment of nutrient supply to the actual requirements of animals. The convergence of sensors, spectroscopy, computer vision, automated feeding systems, production records, health data and machine-learning models makes it possible to move from static formulations based on average values toward dynamic precision-nutrition systems.

This transition creates significant opportunities to improve nutrient utilization, reduce feed conversion ratios, anticipate health deviations, control mycotoxins and other contaminants, decrease nitrogen and phosphorus excretion, and adapt feeding strategies to species, genetics, productive stage, environment and physiological status. Nevertheless, most current developments still depend on historical datasets, experimental environments and models whose industrial generalizability remains to be demonstrated.

Artificial intelligence does not eliminate the uncertainty inherent in animal nutrition. It may amplify that uncertainty when analytical data are incomplete, training populations do not represent the target population, optimization objectives are excessively cost-driven or recommendation systems fail to incorporate physiological, toxicological, technological and welfare constraints. A mathematically accurate prediction may be biologically incorrect when it relies on proxy variables, spurious correlations or conditions that differ from the context of use.

This monograph provides an integrated analysis of artificial intelligence in feed formulation, raw-material evaluation, precision nutrition, mycotoxin management, animal health and welfare, manufacturing, sustainability, traceability and supply-chain resilience. It also examines the European legal framework governing feed safety and artificial intelligence, with particular attention to model validation, human oversight, data quality, evidentiary traceability and the allocation of responsibilities among technology providers, feed manufacturers, integrators, veterinarians, nutritionists and livestock operators.

The central conclusion is that artificial intelligence in animal nutrition must be governed as a technology that intervenes in biological systems rather than as a mere cost-reduction tool. Its technical and regulatory legitimacy will depend on the demonstration of safety, robustness, sufficient explainability, effective human control and the absence of unintended deterioration in animal health and welfare.

Keywords: artificial intelligence; animal nutrition; feed formulation; precision feeding; mycotoxins; raw materials; animal welfare; animal health; precision livestock farming; traceability; feed safety; machine learning.

Lista de abreviaturas

Abreviatura	Significado
ACV / LCA	Análisis de ciclo de vida / Life Cycle Assessment
APPCC / HACCP	Análisis de Peligros y Puntos de Control Crítico
API	Interfaz de programación de aplicaciones
AUC	Área bajo la curva ROC
CV	Coefficiente de variación
DL	Deep learning o aprendizaje profundo
DMI	Ingestión de materia seca
EFSA	Autoridad Europea de Seguridad Alimentaria
ERP	Sistema de planificación de recursos empresariales
FAO	Organización de las Naciones Unidas para la Alimentación y la Agricultura
FCR	Índice de conversión alimentaria
GPAI / IAGP	Inteligencia artificial de propósito general
IA	Inteligencia artificial
IoT	Internet de las cosas
ISO	Organización Internacional de Normalización
KPI	Indicador clave de rendimiento
LIMS	Sistema de gestión de información de laboratorio
MAE	Error absoluto medio
MAPE	Error porcentual absoluto medio
MES	Sistema de ejecución de fabricación
ML	Machine learning o aprendizaje automático
NIRS	Espectroscopia de infrarrojo cercano
OMS / WHO	Organización Mundial de la Salud
PDI	Índice de durabilidad del gránulo
PLF	Precision Livestock Farming o ganadería de precisión
RFID	Identificación por radiofrecuencia
RGPD / GDPR	Reglamento General de Protección de Datos
RMSE	Raíz del error cuadrático medio
ROI	Retorno de la inversión
SCADA	Sistema de supervisión, control y adquisición de datos
UE	Unión Europea
XAI	Inteligencia artificial explicable

Índice general

1. Introducción: la alimentación animal entra en la era de los sistemas predictivos	8
2. De la programación lineal a la formulación inteligente: qué aporta realmente la IA y qué sigue dependiendo del nutricionista	12
3. La infraestructura de datos: materias primas, animales, proceso y ambiente	24
4. Materias primas inteligentes: de la matriz nutricional estática a la caracterización dinámica por lote	41
5. Micotoxinas, contaminantes y sistemas predictivos de alerta: de la detección puntual a la gestión dinámica del riesgo	60
6. Alimentación de precisión y adaptación en tiempo real: del animal medio a la decisión individual	78
7. Microbiota, salud intestinal e inteligencia artificial: de la correlación ómica a la intervención nutricional validada	100
8. Inteligencia artificial, salud animal y bienestar: detección precoz, nutrición clínica y límites del diagnóstico algorítmico	128
9. La fábrica inteligente de piensos: control de proceso, calidad en línea y autonomía industrial segura	153
10. Cadena de suministro inteligente, trazabilidad y resiliencia: del proveedor de materias primas al destino final del pienso	188
11. Inteligencia artificial, sostenibilidad y huella ambiental de la nutrición animal: medir, atribuir y reducir sin desplazar impactos	217
12. Gobernanza, regulación y responsabilidad de la inteligencia artificial en nutrición animal: del cumplimiento formal al control efectivo del riesgo	249
13. Economía, implantación y escalabilidad de la inteligencia artificial en nutrición animal: del proyecto piloto al valor industrial verificable	281
14. Capital humano, competencias y organización del conocimiento: el profesional de la nutrición animal en sistemas aumentados por inteligencia artificial	314
15. Fronteras emergentes y escenarios de futuro: hacia sistemas nutricionales autónomos, multimodales y biológicamente adaptativos	342
16. Hoja de ruta para la implantación de inteligencia artificial en empresas de nutrición animal: diagnóstico, priorización, validación y escalado	382
17. Casos de uso sectoriales y arquitecturas de aplicación: de la formulación inteligente a la explotación conectada	424
18. Validación científica de los sistemas de inteligencia artificial en nutrición animal: evidencia, reproducibilidad y demostración de valor	478
19. Estandarización metodológica de la inteligencia artificial en nutrición animal: criterios científicos para el diseño, evaluación y comunicación de sistemas inteligentes	485
20. Agenda de investigación para la próxima década: de los modelos predictivos aislados a los sistemas nutricionales verificables	491
Conclusiones generales: de la promesa algorítmica a la nutrición animal verificable	496
Glosario esencial	498
Bibliografía científica, normativa y técnica	500

Índice de tablas

Tabla 1. Síntesis de capa, función principal y ejemplo.....	17
Tabla 2. Síntesis de elemento y pregunta de control.....	37
Tabla 3. Síntesis de riesgo, ejemplo, consecuencia y control principal.....	39
Tabla 4. Síntesis de parámetro, valor esperado, variabilidad, fuente y confianza.....	55
Tabla 5. Síntesis de etapa, resultado y acción.....	75
Tabla 6. Síntesis de variable y frecuencia orientativa.....	89
Tabla 7. Síntesis de dimensión y indicador.....	97
Tabla 8. Síntesis de capa y pregunta principal.....	103
Tabla 9. Síntesis de estado, evidencia y acción.....	123
Tabla 10. Síntesis de riesgo, ejemplo, consecuencia y control.....	125
Tabla 11. Síntesis de nivel, acción y supervisión.....	147
Tabla 12. Síntesis de dimensión y indicador.....	149
Tabla 13. Síntesis de nivel y capacidad.....	182
Tabla 14. Síntesis de aplicación, impacto potencial y autonomía recomendable.....	182
Tabla 15. Síntesis de dimensión y indicador.....	184
Tabla 16. Síntesis de dimensión y indicador.....	214
Tabla 17. Síntesis de nivel, evidencia y uso.....	245
Tabla 18. Síntesis de dimensión y indicador.....	245
Tabla 19. Síntesis de riesgo, manifestación y control.....	246
Tabla 20. Síntesis de elemento y descripción.....	251
Tabla 21. Síntesis de nivel y función.....	264
Tabla 22. Síntesis de dimensión y indicador.....	274
Tabla 23. Síntesis de riesgo, control preventivo, control detectivo y respuesta.....	275
Tabla 24. Síntesis de dimensión y indicador.....	305
Tabla 25. Síntesis de criterio y pregunta.....	310
Tabla 26. Síntesis de dimensión y indicador.....	337
Tabla 27. Síntesis de función, dominio, datos, ia, riesgo y operación.....	338
Tabla 28. Síntesis de riesgo, manifestación y control.....	338
Tabla 29. Síntesis de dimensión y indicador.....	379
Tabla 30. Síntesis de objetivo empresarial y contribución potencial de ia.....	384
Tabla 31. Síntesis de elemento y pregunta.....	386
Tabla 32. Síntesis de nivel y característica.....	390
Tabla 33. Síntesis de factibilidad alta y factibilidad baja.....	394
Tabla 34. Síntesis de dimensión y criterio.....	401
Tabla 35. Síntesis de dimensión y indicador.....	409
Tabla 36. Síntesis de dimensión y indicador.....	421
Tabla 37. Síntesis de elemento y contenido.....	425
Tabla 38. Síntesis de caso, valor, datos, actuación, riesgo y madurez.....	469
Tabla 39. Prioridades de investigación y criterios de demostración para el periodo 2026–2036.....	495

1. Introducción: la alimentación animal entra en la era de los sistemas predictivos

La formulación de piensos ha sido, desde hace décadas, una de las actividades más cuantificadas de la producción ganadera. Los nutricionistas trabajan con matrices de ingredientes, restricciones nutricionales, coeficientes de digestibilidad, necesidades fisiológicas, precios de materias primas y objetivos productivos. La utilización de programación lineal permitió convertir buena parte de este conocimiento en problemas de optimización matemática, generalmente orientados a obtener una fórmula que satisficiera determinados requerimientos al menor coste posible.

La inteligencia artificial no parte, por tanto, de un sector ajeno al cálculo. Se introduce en una actividad que ya estaba profundamente modelizada. Su verdadera novedad no consiste simplemente en sustituir una hoja de cálculo por un algoritmo más sofisticado, sino en ampliar de forma sustancial la cantidad, velocidad y heterogeneidad de la información que puede incorporarse al proceso de decisión.

Los modelos tradicionales trabajan principalmente con datos previamente estructurados: composición declarada o analizada de las materias primas, valores tabulados de energía y nutrientes, límites de incorporación, precios y requerimientos medios de una categoría animal. Los sistemas contemporáneos pueden añadir datos procedentes de espectroscopia en línea, cámaras, básculas, comederos electrónicos, sensores ambientales, acelerómetros, collares de rumia, registros veterinarios, curvas de crecimiento, consumo de agua, producción de leche, calidad de las deyecciones, información meteorológica y resultados históricos de lotes anteriores.

Este ecosistema permite que la alimentación deje de configurarse exclusivamente como una decisión previa al proceso productivo y pase a convertirse en una variable ajustable durante el propio proceso. La ración puede modificarse en función de la ingestión real, la evolución del peso, la temperatura ambiental, la actividad, la producción, determinados biomarcadores o la aparición de desviaciones compatibles con enfermedad, estrés o pérdida de eficiencia.

La denominada *precision livestock farming* combina sensores, automatización y análisis algorítmico para observar animales y procesos con una resolución temporal y poblacional difícilmente alcanzable mediante supervisión humana convencional. Sus aplicaciones incluyen el reconocimiento de patrones de comportamiento, la detección de cojeras, mastitis o alteraciones respiratorias, la estimación de peso, la monitorización del consumo y la identificación precoz de cambios productivos. La literatura reciente muestra avances significativos en visión artificial, integración de sensores y modelos predictivos, aunque también reconoce problemas de transferibilidad entre explotaciones, calidad de los datos, interoperabilidad y dependencia de entornos controlados.

En alimentación animal, estas tecnologías abren al menos cinco grandes ámbitos de transformación.

El primero es la **caracterización inteligente de materias primas**. Cereales, harinas proteicas, subproductos agroindustriales, grasas, forrajes y coproductos presentan una variabilidad composicional que no siempre queda representada por los valores medios utilizados en las matrices de formulación. La combinación de análisis rápidos, espectroscopia, datos de origen y modelos predictivos puede estimar con mayor precisión nutrientes, digestibilidad, humedad, contaminantes o comportamiento tecnológico.

El segundo ámbito es la **formulación multicriterio**. El objetivo ya no tiene por qué limitarse al coste mínimo. Los algoritmos pueden intentar equilibrar simultáneamente precio, disponibilidad, digestibilidad, productividad, riesgo de micotoxinas, huella de carbono, excreción de nutrientes, salud intestinal, estabilidad de fabricación y robustez frente a cambios en las materias primas. Los modelos de optimización con múltiples objetivos muestran que es posible tratar conjuntamente varias restricciones económicas y nutricionales,

aunque el resultado depende de cómo se jerarquicen los objetivos y de qué penalizaciones se asignen a cada desviación.

El tercero es la **nutrición de precisión**. Frente a la alimentación de grupos relativamente homogéneos mediante dietas estandarizadas, los sistemas de precisión intentan aproximar el aporte nutricional a la necesidad real de cada animal o subgrupo. El ajuste puede efectuarse según edad, peso, sexo, genética, estado fisiológico, producción, consumo, condiciones ambientales y evolución sanitaria. El propósito es reducir tanto el déficit como el exceso de nutrientes, evitando que el margen de seguridad utilizado para cubrir la variabilidad biológica se traduzca en costes innecesarios o mayores emisiones.

El cuarto ámbito es la **seguridad de los piensos**. La IA puede utilizarse para priorizar controles, detectar anomalías en datos analíticos, predecir el riesgo de contaminación y generar alertas tempranas. Un estudio publicado en 2025 aplicó aprendizaje automático a la predicción de cuatro grupos de contaminantes en alimentación animal —micotoxinas, metales pesados, dioxinas y plaguicidas— con el objetivo de apoyar sistemas de vigilancia basados en riesgo.

En el caso específico de las micotoxinas, los modelos pueden integrar climatología, cultivo, procedencia, almacenamiento, humedad, actividad de agua, resultados analíticos e historial de proveedores. También se están desarrollando métodos de detección rápida mediante imagen, espectroscopia, sensores y narices electrónicas. Sin embargo, la literatura advierte que la escalabilidad, la reproducibilidad, la disponibilidad de datos abiertos y la validación en condiciones reales continúan siendo limitaciones importantes.

El quinto ámbito es la conexión entre **nutrición, salud y bienestar animal**. La alimentación afecta a la función ruminal, salud intestinal, inmunidad, integridad ósea, comportamiento, aparición de trastornos metabólicos y capacidad de adaptación al ambiente. La IA puede detectar patrones tempranos que permitan intervenir antes de que una alteración se manifieste clínicamente. No obstante, también puede favorecer una visión excesivamente productivista si los indicadores utilizados se concentran en crecimiento, leche, puesta o índice de conversión y no incorporan medidas directas del estado del animal.

Esta distinción es esencial. Un sistema puede considerar que un lote funciona correctamente porque mantiene la producción prevista, aunque lo consiga a costa de mayor competencia por el alimento, restricción de determinadas conductas, estrés térmico compensado nutricionalmente o aumento de patologías subclínicas. EFSA ha señalado la utilidad potencial de las tecnologías de ganadería de precisión para recopilar datos de bienestar, pero la evaluación no puede reducirse a variables productivas: debe incorporar medidas basadas directamente en el animal y en su capacidad de afrontar el entorno.

Por ello, el uso de inteligencia artificial en alimentación animal plantea una cuestión de diseño institucional y no solo de rendimiento tecnológico. Es necesario decidir qué variables se optimizan, cuáles funcionan como restricciones inviolables y qué señales obligan a detener o revisar una recomendación automatizada.

1.1. La falsa neutralidad de la optimización

Todo sistema de formulación u optimización contiene una función objetivo. Incluso cuando el algoritmo se presenta como neutral, alguien ha decidido qué debe maximizar o minimizar: coste por tonelada, margen por animal, crecimiento, producción de leche, conversión, mortalidad, emisiones o una combinación ponderada de estos factores.

La ponderación no es una cuestión puramente matemática. Representa una decisión empresarial, biológica y, en determinadas circunstancias, ética. Un modelo que penaliza fuertemente el coste de la dieta y débilmente la variabilidad de los ingredientes generará recomendaciones diferentes de otro que priorice la estabilidad digestiva. Del mismo modo, un sistema que valore la eficiencia productiva sin introducir límites relativos a

salud locomotora, comportamiento, mortalidad o incidencia de enfermedad puede trasladar parte del coste económico al animal.

La IA no elimina estas decisiones. Las hace menos visibles cuando quedan incorporadas en parámetros, pesos, variables latentes o modelos propietarios. La sofisticación matemática puede producir una apariencia de objetividad que dificulte cuestionar la recomendación. Esta circunstancia obliga a documentar la función objetivo, las restricciones, los datos utilizados y los supuestos biológicos del modelo.

1.2. Una tecnología situada entre dos cadenas de seguridad

La alimentación animal ocupa una posición singular porque afecta simultáneamente a la salud animal y, cuando se trata de animales productores de alimentos, a la seguridad alimentaria humana. Un error de formulación puede provocar deficiencias, toxicidad, pérdida de rendimiento o mortalidad. La presencia de contaminantes, sustancias indeseables o residuos puede además trasladarse a carne, leche, huevos, pescado u otros productos.

El marco europeo refleja esta conexión. El Reglamento (CE) n.º 1831/2003 exige que los operadores garanticen la higiene en las fases de producción, transformación y distribución de los piensos y establece obligaciones preventivas para reducir los riesgos biológicos, químicos y físicos. El Reglamento (CE) n.º 767/2009 regula la comercialización y utilización de los piensos, mientras que la Directiva 2002/32/CE y la Recomendación 2006/576/CE forman parte del sistema de control de sustancias indeseables y micotoxinas.

La utilización de un algoritmo no desplaza estas obligaciones. Una empresa no puede alegar que una materia prima fue aceptada, que una fórmula fue liberada o que un lote fue considerado seguro porque así lo determinó un modelo automatizado. La decisión continúa formando parte del sistema de gestión del operador y debe poder justificarse mediante datos, procedimientos y controles verificables.

1.3. IA no significa necesariamente sistema de alto riesgo, pero sí decisión de impacto elevado

Desde la perspectiva del Reglamento (UE) 2024/1689, no todos los sistemas empleados en formulación de piensos, predicción sanitaria o gestión ganadera serán automáticamente considerados sistemas de inteligencia artificial de alto riesgo. La clasificación depende de su finalidad prevista, del contexto de utilización y, en determinados casos, de su integración en productos o ámbitos específicamente regulados.

Sin embargo, la ausencia de clasificación formal como sistema de alto riesgo no debe confundirse con ausencia de riesgo material. Un modelo que determine automáticamente la incorporación de un aditivo, modifique la dosificación de nutrientes, descarte alertas de contaminación o condicione la alimentación de miles de animales puede producir efectos relevantes sobre salud, bienestar, seguridad alimentaria y patrimonio empresarial.

La gobernanza adecuada debe, por tanto, superar el cumplimiento mínimo del Reglamento de Inteligencia Artificial. Debe incorporar los principios preventivos propios de la seguridad de los piensos, los sistemas APPCC o equivalentes, el control de proveedores, la validación nutricional, la vigilancia veterinaria, la ciberseguridad, la trazabilidad y la revisión humana.

En julio de 2026, el Reglamento de Inteligencia Artificial se encuentra además en una fase decisiva de aplicación progresiva. Las obligaciones sobre alfabetización en IA y prácticas prohibidas son aplicables desde febrero de 2025; las relativas a modelos de propósito general comenzaron a aplicarse en agosto de 2025 y buena parte del régimen general está prevista para agosto de 2026, con calendarios específicos para determinadas categorías de alto riesgo.

Las empresas de alimentación animal que ya utilizan sistemas predictivos, herramientas de formulación con aprendizaje automático o plataformas generativas no deberían esperar a una eventual clasificación regulatoria para establecer controles internos. Deben identificar desde ahora los casos de uso, responsables, fuentes de datos, funciones automatizadas, límites de actuación y procedimientos de revisión.

1.4. Del pienso formulado al sistema nutricional adaptativo

La transición más relevante puede resumirse como el paso desde el **pienso formulado** al **sistema nutricional adaptativo**.

En el modelo tradicional, la empresa define una fórmula a partir de requerimientos y materias primas disponibles. El pienso se fabrica, se distribuye y posteriormente se evalúan los resultados productivos. Existe un desfase inevitable entre la decisión nutricional y la observación de sus consecuencias.

En un sistema adaptativo, la formulación se conecta con datos de fabricación y explotación. El sistema puede conocer la composición estimada de cada lote, las desviaciones del proceso, el consumo real, la respuesta productiva, el comportamiento y determinados indicadores sanitarios. A partir de ellos puede recalcular recomendaciones, detectar pérdida de eficacia o advertir que una fórmula válida en condiciones normales deja de ser adecuada ante calor, enfermedad, cambios de genética o variaciones de materias primas.

Este enfoque convierte la alimentación en un bucle de retroalimentación:

datos de materias primas → formulación → fabricación → ingestión → respuesta animal → evaluación algorítmica → ajuste nutricional.

La calidad del resultado depende de todos los eslabones. Un sensor mal calibrado, una muestra no representativa, una identificación incorrecta del lote, un dato productivo incompleto o una deriva del modelo pueden propagarse por el sistema y generar decisiones aparentemente coherentes pero materialmente erróneas.

La alimentación animal basada en IA debe, por ello, diseñarse como una arquitectura de control con barreras sucesivas. Ningún resultado crítico debería depender de una única predicción. Los modelos deben estar acompañados por límites composicionales, reglas nutricionales, controles analíticos, revisión profesional y mecanismos de bloqueo cuando los datos sean insuficientes o se sitúen fuera del dominio para el que el sistema fue validado.

La cuestión ya no consiste en determinar si la inteligencia artificial será utilizada en la alimentación animal. Ya está siendo incorporada a sistemas de formulación, monitorización, control de contaminantes y gestión ganadera. La cuestión decisiva es si esa incorporación se realizará como una capa opaca de automatización o como una tecnología verificable, sometida a criterios nutricionales, veterinarios, toxicológicos, industriales, jurídicos y éticos.

Sobre esa distinción se construye el presente trabajo.

2. De la programación lineal a la formulación inteligente: qué aporta realmente la IA y qué sigue dependiendo del nutricionista

La formulación de alimentos para animales constituye uno de los primeros ámbitos agroindustriales en los que la toma de decisiones se formalizó mediante modelos matemáticos. Mucho antes de que se generalizara el término inteligencia artificial, las fábricas de piensos y los especialistas en nutrición ya utilizaban algoritmos de optimización para determinar qué combinación de materias primas podía satisfacer unas especificaciones nutricionales determinadas al menor coste posible.

Esta trayectoria histórica obliga a introducir una precisión conceptual fundamental: **la utilización de un programa informático para formular piensos no implica necesariamente que se esté empleando inteligencia artificial**. Una gran parte del software comercial sigue basándose esencialmente en programación lineal, programación por objetivos y otras técnicas de investigación operativa. Son herramientas matemáticas de enorme utilidad, pero no aprenden automáticamente de nuevos datos, no descubren por sí mismas relaciones biológicas desconocidas y no modifican su comportamiento salvo que cambien las reglas, las matrices o los parámetros introducidos por el usuario.

La inteligencia artificial aparece propiamente cuando el sistema incorpora capacidades predictivas, clasificatorias o adaptativas: estimar la digestibilidad real de un ingrediente a partir de datos espectrales; anticipar la ingestión de un animal; detectar patrones de respuesta no lineales; predecir el riesgo de una desviación sanitaria; actualizar necesidades nutricionales en función de datos individuales; o aprender de la relación histórica entre fórmulas, condiciones ambientales y resultados productivos.

La arquitectura técnicamente más sólida no consiste, por tanto, en sustituir completamente la formulación matemática tradicional por una red neuronal o por un modelo generativo. Consiste en **integrar modelos predictivos de inteligencia artificial con motores de optimización sujetos a restricciones nutricionales, tecnológicas, regulatorias y económicas explícitas**.

2.1. La estructura del problema clásico de formulación

En su representación más sencilla, la formulación de mínimo coste puede expresarse como:

$$\text{Minimizar } C = \sum_{i=1}^n c_i x_i$$

donde:

- (x_i) representa la cantidad o proporción del ingrediente (i);
- (c_i) representa su coste unitario;
- (n) es el número de ingredientes disponibles.

La solución debe respetar una serie de restricciones. Para cada nutriente (j):

$$L_j \leq \sum_{i=1}^n a_{ij} x_i \leq U_j$$

donde:

- (a_{ij}) es la concentración atribuida al nutriente (j) en el ingrediente (i);
- (L_j) es el nivel mínimo admisible;
- (U_j) es, cuando proceda, el nivel máximo tolerado o tecnológicamente conveniente.

A estas restricciones nutricionales se añaden límites de inclusión, disponibilidad, compatibilidad, fabricación y calidad. Puede establecerse, por ejemplo, una inclusión máxima de determinadas grasas, fibras, coproductos, minerales, fuentes proteicas o ingredientes de palatabilidad problemática. También pueden fijarse cantidades mínimas por razones tecnológicas, contractuales o comerciales.

La potencia de este sistema reside en su transparencia. El nutricionista puede conocer la composición asignada a cada materia prima, las restricciones aplicadas y el coste marginal de modificar una especificación. Cuando el modelo está correctamente construido, la solución puede ser reproducida y auditada.

Esta aparente simplicidad no debe infravalorarse. La programación lineal sigue siendo extraordinariamente eficaz cuando las relaciones que se pretenden modelizar pueden aproximarse razonablemente mediante coeficientes constantes y cuando el objetivo prioritario es satisfacer unos requerimientos conocidos al menor coste. El problema no es que el método sea antiguo, sino que puede resultar insuficiente cuando se le exige representar fenómenos biológicos dinámicos, incertidumbre analítica, interacciones entre nutrientes o múltiples objetivos contradictorios.

2.2. La diferencia entre formular una dieta y predecir su respuesta

La formulación clásica responde principalmente a la pregunta:

¿Qué combinación de ingredientes cumple las especificaciones definidas?

La inteligencia artificial intenta responder además a otra pregunta:

¿Qué respuesta cabe esperar de un animal o población concreta cuando reciba esa combinación en unas condiciones determinadas?

Ambas preguntas están relacionadas, pero no son equivalentes.

Una fórmula puede cumplir matemáticamente todos los límites de energía, aminoácidos, minerales, vitaminas y fibra, sin garantizar que la respuesta productiva real coincida con la prevista. Entre la composición calculada y la respuesta animal intervienen numerosos factores:

- variabilidad real de las materias primas;
- digestibilidad y biodisponibilidad;
- granulometría y tratamiento térmico;
- interacciones entre nutrientes;
- consumo voluntario;
- estado sanitario;
- microbiota;
- genética;
- edad y sexo;
- temperatura y humedad;
- densidad animal;
- calidad del agua;
- manejo y presentación física del pienso.

La formulación establece una **oferta nutricional teórica**. El modelo predictivo intenta estimar cómo esa oferta será ingerida, digerida, metabolizada y transformada en mantenimiento, crecimiento, reproducción, leche, huevos, tejidos o actividad.

La IA puede contribuir especialmente en esta segunda dimensión porque muchos de estos procesos presentan relaciones no lineales y dependen de combinaciones de variables difíciles de representar mediante ecuaciones simples. Sin embargo, el modelo predictivo no debe confundirse con una ley biológica. Sigue siendo una aproximación estadística construida a partir de las poblaciones, condiciones y mediciones presentes en sus datos de entrenamiento.

2.3. Las cinco limitaciones estructurales de la formulación de mínimo coste

2.3.1. El carácter determinista de la matriz nutricional

La programación lineal convencional utiliza normalmente un único valor para representar la concentración de cada nutriente en cada ingrediente. Así, una harina de soja, un maíz o un subproducto se introducen en la matriz con un contenido determinado de proteína, energía, aminoácidos, fibra, minerales o humedad.

En la realidad industrial, estas concentraciones son variables. Cambian con la variedad vegetal, la campaña, el origen geográfico, las condiciones agronómicas, el almacenamiento, el procesado y el proveedor. Dos partidas comercializadas bajo una misma denominación pueden presentar diferencias significativas en composición, digestibilidad y comportamiento tecnológico.

Cuando el formulador introduce exclusivamente el valor medio, el modelo trata ese valor como si fuera cierto. No representa adecuadamente la probabilidad de que el lote real se sitúe por debajo o por encima. La programación estocástica se desarrolló precisamente para incorporar distribuciones y probabilidades de cumplimiento, confrontando el coste de la fórmula con el riesgo de no alcanzar los niveles nutricionales previstos.

El problema puede corregirse parcialmente mediante márgenes de seguridad, pero estos generan una tensión conocida. Un margen insuficiente eleva el riesgo de deficiencia; uno excesivo aumenta el coste, la excreción de nutrientes y, en algunos casos, los riesgos derivados de sobredosificación.

2.3.2. La suposición de relaciones lineales

En un modelo lineal se presupone que el efecto de los ingredientes y nutrientes puede sumarse proporcionalmente. Sin embargo, la respuesta biológica no siempre es aditiva.

La digestión puede modificarse por interacciones entre fibra, grasa, minerales, enzimas, fitatos, taninos u otros componentes. El valor energético de una dieta no siempre equivale exactamente a la suma de los valores energéticos tabulados de sus ingredientes. La respuesta productiva a un aminoácido puede presentar una zona de deficiencia, una meseta de suficiencia y, eventualmente, efectos adversos o desequilibrios cuando existe exceso.

Los modelos no lineales pueden describir mejor determinadas curvas de respuesta, pero exigen más información y pueden resultar más sensibles a errores de especificación. Una ecuación más compleja no es necesariamente más exacta si sus parámetros no han sido estimados en animales, ingredientes y condiciones representativas.

2.3.3. La representación de un animal medio

Los requerimientos utilizados para formular una dieta suelen corresponder a un animal representativo de una categoría o a un percentil suficientemente elevado para evitar que una parte significativa del grupo quede subalimentada.

Esta estrategia implica que numerosos animales recibirán nutrientes por encima de sus necesidades reales. La variabilidad interindividual en crecimiento, consumo, eficiencia, estado sanitario y metabolismo hace que una misma dieta produzca excedentes en unos individuos y déficits relativos en otros.

La alimentación multifase redujo parcialmente este problema al dividir el ciclo productivo en etapas. La nutrición de precisión intenta ir más lejos, actualizando con mayor frecuencia la concentración nutricional y, cuando la infraestructura lo permite, adaptándola al individuo.

2.3.4. La reducción del problema al coste por tonelada

Una fórmula de menor coste por tonelada no es necesariamente la fórmula económicamente más eficiente.

Una dieta ligeramente más cara puede mejorar el índice de conversión, reducir la mortalidad, disminuir la dispersión de pesos, acortar el ciclo productivo o reducir incidencias digestivas. Inversamente, una formulación barata puede deteriorar el rendimiento o aumentar los costes veterinarios, energéticos, logísticos y ambientales.

El indicador relevante no debería ser exclusivamente:

Coste del pienso por tonelada

debería ser, según la especie y el sistema:

Coste alimentario por kilogramo de peso producido

e incluso:

Margen económico esperado por animal, lote o plaza

La dificultad radica en que estos indicadores dependen de respuestas biológicas futuras. Es precisamente aquí donde los modelos predictivos pueden complementar al optimizador.

2.3.5. La formulación como fotografía estática

Una fórmula se construye a partir de datos disponibles en un momento determinado. Sin embargo, el sistema productivo evoluciona continuamente. Cambian los precios, los ingredientes, el consumo, el peso, el estado fisiológico, la temperatura, la salud y los objetivos comerciales.

La formulación estática pierde precisión a medida que las condiciones reales se alejan de las presupuestas. La nutrición adaptativa pretende convertir ese cálculo puntual en un proceso de actualización periódica o continua.

2.4. Qué añade realmente la inteligencia artificial

La inteligencia artificial puede intervenir en la formulación mediante cuatro funciones diferentes que conviene separar.

Función predictiva

El modelo estima una variable desconocida o futura:

- composición química de una materia prima;
- digestibilidad;
- ingestión;
- ganancia de peso;
- conversión;
- producción de leche;
- respuesta a un nutriente;
- emisiones;
- riesgo de enfermedad;
- probabilidad de rechazo del alimento.

Función clasificatoria

El sistema asigna una muestra, animal o lote a una categoría:

- ingrediente conforme o no conforme;
- lote de alto o bajo riesgo;
- animal de elevada o reducida eficiencia;
- patrón de consumo normal o anómalo;
- materia prima perteneciente o no a una procedencia declarada.

Función de optimización

El algoritmo busca una combinación de ingredientes o decisiones que maximice o minimice uno o varios objetivos.

No toda optimización es IA. Los algoritmos genéticos, evolutivos y de enjambre suelen incluirse dentro de la inteligencia computacional, mientras que la programación lineal pertenece tradicionalmente a la investigación operativa. En la práctica, la frontera terminológica es menos importante que la función desempeñada y la posibilidad de auditarla.

Función adaptativa

El sistema actualiza la recomendación cuando recibe nuevos datos. Puede ajustar una mezcla diaria, revisar el consumo esperado, detectar una deriva productiva o modificar la estrategia de alimentación.

La combinación de estas cuatro funciones da lugar a una formulación verdaderamente inteligente. El sistema no se limita a calcular una receta, sino que estima las condiciones reales, proyecta la respuesta, propone alternativas, ejecuta o recomienda ajustes y evalúa posteriormente sus consecuencias.

2.5. La formulación multicriterio y el concepto de frontera de Pareto

La formulación moderna no tiene un único objetivo. Puede pretender simultáneamente:

- minimizar el coste;
- maximizar el rendimiento;
- reducir la variabilidad;
- limitar el número de ingredientes;
- mejorar la estabilidad industrial;
- disminuir la excreción de nitrógeno y fósforo;
- reducir la huella climática;
- controlar el riesgo de micotoxinas;
- proteger la salud intestinal;
- respetar restricciones de abastecimiento;
- mantener determinadas declaraciones comerciales.

Estos objetivos pueden ser incompatibles. Reducir al máximo el coste puede aumentar la variabilidad. Minimizar la huella ambiental puede requerir ingredientes más caros o menos disponibles. Disminuir la proteína bruta puede exigir mayor precisión en aminoácidos digestibles. Limitar el número de materias primas puede facilitar la fabricación, pero reducir la flexibilidad económica.

La optimización multiobjetivo no produce necesariamente una única respuesta. Genera un conjunto de soluciones eficientes o **frontera de Pareto**. Cada solución representa un compromiso diferente: no puede mejorarse un objetivo sin empeorar al menos otro.

Un estudio publicado en 2025 propuso para vacuno lechero un modelo con nueve objetivos simultáneos, incluyendo coste, peso total, número de ingredientes y desviaciones respecto de requerimientos de energía metabolizable, proteína metabolizable, metionina, lisina, calcio y fósforo. El trabajo mostró el valor de combinar algoritmos evolutivos, agrupación y visualizaciones para que el responsable pueda examinar los compromisos entre soluciones, aunque su aplicación práctica continúa dependiendo de la calidad de los datos y de la interpretación profesional.

Este enfoque corrige una debilidad frecuente en el discurso sobre IA. El algoritmo no descubre una fórmula universalmente “mejor”. Presenta alternativas que son mejores bajo diferentes prioridades. La selección final exige determinar qué compromiso es admisible para la empresa y para los animales.

2.6. El modelo híbrido: predicción más optimización

La arquitectura más razonable para una plataforma de formulación inteligente puede dividirse en cinco capas.

Tabla 1. Síntesis de capa, función principal y ejemplo.

Capa	Función principal	Ejemplo
Analítica	Medir o estimar las características de los ingredientes	Humedad, proteína, aminoácidos, fibra, digestibilidad
Predictiva	Estimar la respuesta animal o industrial	Consumo, crecimiento, conversión, calidad del gránulo
Optimización	Seleccionar combinaciones compatibles con los objetivos	Coste, rendimiento, emisiones, estabilidad
Control	Aplicar límites no negociables	Máximos legales, límites toxicológicos, restricciones nutricionales

Capa	Función principal	Ejemplo
Retroalimentación	Comparar predicción y resultado real	Desviación del consumo, peso, mortalidad o producción

La separación de capas es importante porque permite identificar dónde se produce un error.

Si el contenido proteico fue mal estimado, el fallo pertenece a la capa analítica. Si el contenido fue correcto pero la respuesta animal se predijo mal, el problema reside en el modelo biológico. Si la predicción fue razonable pero el optimizador seleccionó una combinación industrialmente inviable, el error se encuentra en las restricciones de formulación. Si la fórmula era correcta, pero se fabricó incorrectamente, el problema pertenece a la ejecución.

Un sistema opaco que integre todas estas funciones sin distinguirlas dificulta la investigación de desviaciones y la atribución de responsabilidades.

2.7. Modelización de respuestas no lineales

Una de las aplicaciones más prometedoras de la IA consiste en modelizar la relación entre el suministro de nutrientes y diferentes respuestas productivas.

En pollos de engorde, por ejemplo, pueden existir combinaciones de glicina, treonina y colina que optimicen de manera diferente la ganancia de peso y la eficiencia alimentaria. Un trabajo experimental empleó regresión por procesos gaussianos y un algoritmo genético para modelizar simultáneamente la ganancia diaria y la relación **ganancia/consumo**. El interés metodológico reside en que el modelo no trató ambos indicadores como si fueran equivalentes: cuantificó el compromiso entre maximizar crecimiento y mejorar eficiencia.

Este tipo de modelo puede ser más informativo que una regresión convencional, pero exige prudencia. La función aprendida es válida principalmente dentro del intervalo de nutrientes, edad, genética, condiciones experimentales y materias primas contemplados. Utilizarla fuera de ese dominio constituye una extrapolación.

La IA puede interpolar eficazmente entre situaciones similares a las conocidas. Su rendimiento es mucho menos seguro cuando encuentra materias primas novedosas, nuevas líneas genéticas, enfermedades emergentes o combinaciones nutricionales ausentes del entrenamiento.

2.8. Predicción de la ingestión: variable central y fuente de incertidumbre

La concentración de nutrientes de un pienso solo puede interpretarse correctamente en relación con la cantidad consumida. Un alimento perfectamente formulado no cubre necesidades si la ingestión real es inferior a la esperada. Por ello, la predicción del consumo constituye una pieza esencial de la nutrición de precisión.

Los modelos pueden utilizar peso, edad, sexo, genética, producción, temperatura, humedad, comportamiento, historial de consumo y otras variables. Un estudio de 2025 trabajó con 1.708 ovinos procedentes de 17 ensayos de ingestión y comparó regresiones lineales y no lineales, k vecinos más próximos, bosques aleatorios y máquinas de vectores soporte. Algunos modelos alcanzaron correlaciones elevadas en validación, pero los resultados dependieron del procedimiento de selección de variables y de la población analizada.

La importancia de este ejemplo no reside únicamente en la cifra de rendimiento. Muestra tres cuestiones generales.

La primera es que un modelo puede estimar una variable cuya medición directa resulta costosa. La segunda es que el resultado debe validarse en datos separados de los utilizados para entrenarlo. La tercera es que una precisión global aceptable no garantiza que el error sea igualmente bajo en todas las razas, pesos, condiciones o individuos.

Para utilizar una predicción de consumo en una decisión nutricional se requiere conocer no solo el valor estimado, sino también su incertidumbre. Un error de un 5 % puede ser irrelevante en determinadas situaciones y crítico en otras.

2.9. Nutrición individual y ajuste diario en porcino

El porcino representa uno de los casos mejor estudiados de alimentación individualizada. Los sistemas experimentales identifican al animal, registran su consumo y peso y mezclan en tiempo real dos o más dietas con diferente densidad nutricional. La proporción se ajusta para aproximar el aporte diario, especialmente de aminoácidos, a las necesidades estimadas.

En ensayos con cerdos en crecimiento y cebo, las dietas adaptadas diariamente a los requerimientos individuales de lisina digestible redujeron el consumo de lisina y la excreción estimada de nitrógeno sin deteriorar el rendimiento productivo. En uno de los estudios más citados, el ajuste al 100 % de las necesidades estimadas redujo aproximadamente un 26 % la ingestión de lisina digestible, un 30 % la excreción estimada de nitrógeno y un 10 % el coste alimentario respecto del sistema convencional por fases.

Estos resultados demuestran el potencial del ajuste individual, pero también señalan una limitación: la precisión de la alimentación no puede ser superior a la precisión del modelo que estima las necesidades.

La necesidad individual no se observa directamente. Se infiere a partir de consumo, peso, crecimiento esperado y parámetros metabólicos. Si el animal reduce la ingestión por calor, enfermedad, competencia o fallo del equipo, el sistema debe distinguir entre una modificación fisiológica real y un dato anómalo.

Los estudios realizados bajo estrés térmico muestran precisamente la importancia de adaptar la estrategia al ambiente. En estos modelos, los animales recibieron mezclas diarias personalizadas a partir de información individual de peso e ingestión, frente a dietas constantes por fases.

La nutrición de precisión no debe interpretarse como una mera reducción automática de nutrientes. Su objetivo es reducir el desajuste. En ocasiones implicará disminuir el aporte; en otras, aumentarlo o modificar la densidad para compensar una ingestión menor.

2.10. La caracterización inteligente de materias primas

La formulación solo puede ser tan precisa como la matriz de ingredientes que utiliza. La digitalización de la nutrición animal comienza, por tanto, antes del optimizador.

La espectroscopia de infrarrojo cercano permite obtener predicciones rápidas y no destructivas de numerosos componentes. Tradicionalmente se ha combinado con regresión de mínimos cuadrados parciales y otras técnicas quimiométricas. Los modelos de aprendizaje automático pueden capturar relaciones más complejas entre el espectro y la composición, siempre que se disponga de suficientes muestras de referencia analizadas mediante métodos fiables.

En alimentación animal se han utilizado redes neuronales y otros modelos no lineales para estimar la presencia o proporción de ingredientes en piensos compuestos. Un estudio desarrollado con una biblioteca de más de 7.500 muestras comerciales evaluó redes neuronales para predecir las proporciones de trigo y harina

de girasol, mostrando que los modelos podían superar determinados enfoques lineales en matrices heterogéneas.

Investigaciones posteriores han ampliado el uso de NIRS a componentes fibrosos de difícil determinación rápida. Un trabajo de 2026 desarrolló calibraciones para polisacáridos no amiláceos y lignina en ingredientes para monogástricos, obteniendo resultados sólidos para determinadas fracciones, especialmente en modelos específicos de harina de soja. Sin embargo, el rendimiento no fue uniforme para todos los ingredientes y analitos, lo que confirma que una calibración global no necesariamente sustituye a modelos específicos.

La utilización industrial exige controlar:

- representatividad de la biblioteca espectral;
- calidad del método analítico de referencia;
- transferencia entre equipos;
- cambios de origen o campaña;
- detección de muestras fuera del dominio;
- recalibración periódica;
- trazabilidad de versiones.

Una predicción rápida no es equivalente a un análisis de referencia. Su utilidad depende del uso. Puede ser excelente para clasificar lotes, ajustar matrices o priorizar controles, pero insuficiente para determinadas decisiones regulatorias o disputas contractuales.

2.11. El nutricionista no desaparece: cambia de función

El discurso comercial tiende a presentar la inteligencia artificial como sustituto del conocimiento experto. En formulación animal, esta sustitución completa sería técnicamente imprudente.

El nutricionista aporta competencias que el modelo no posee por sí mismo:

Interpretación biológica

El sistema puede detectar una asociación, pero no necesariamente explicar su mecanismo. El especialista debe valorar si la relación es fisiológicamente plausible o si refleja una correlación accidental.

Definición de restricciones

El algoritmo no sabe por sí mismo qué límites son innegociables. Deben introducirse restricciones de seguridad, salud, digestibilidad, palatabilidad, fabricación, legislación y bienestar.

Valoración de materias primas

Dos ingredientes con composición química aparentemente similar pueden presentar diferente variabilidad, estabilidad, riesgo microbiológico, palatabilidad, trazabilidad o comportamiento tecnológico.

Gestión de excepciones

Las situaciones más críticas suelen ser precisamente las menos frecuentes: contaminación, enfermedad, fallo de sensor, cambio brusco de proveedor, ola de calor o comportamiento atípico. Estos eventos están infrarrepresentados en los datos históricos.

Responsabilidad decisoria

El sistema puede recomendar, pero la organización debe asignar a una persona competente la responsabilidad de autorizar fórmulas, modificaciones y excepciones.

En la formulación inteligente, el nutricionista evoluciona desde el cálculo manual hacia la **supervisión de un sistema sociotécnico**. Debe comprender nutrición y producción, pero también calidad de datos, incertidumbre, validación, límites de uso y lectura crítica de modelos.

2.12. Las decisiones que no deberían delegarse completamente

Aunque el grado de automatización dependerá del contexto, determinadas funciones requieren un control humano reforzado:

1. Liberación de fórmulas que se aproximen a máximos legales o toxicológicos.
2. Modificación de límites de seguridad o márgenes nutricionales.
3. Incorporación de materias primas nuevas o insuficientemente caracterizadas.
4. Aceptación de lotes con señales analíticas contradictorias.
5. Cambios relevantes durante episodios sanitarios.
6. Recomendaciones que puedan afectar al bienestar animal.
7. Extrapolación del modelo a especies, genéticas o fases no validadas.
8. Anulación de alertas generadas por los sistemas de control.
9. Utilización de resultados generativos como sustituto de tablas, legislación o documentación técnica verificada.

La supervisión humana no debe convertirse en una firma rutinaria. Para ser efectiva, la persona debe disponer de información comprensible, autoridad para rechazar la recomendación y tiempo suficiente para examinarla.

2.13. Una propuesta de jerarquía de restricciones

No todos los objetivos de una formulación deben tratarse con el mismo rango. Un diseño responsable puede estructurarlos en cuatro niveles.

Nivel 1. Restricciones legales y de seguridad

Son límites no negociables:

- sustancias prohibidas;
- contenidos máximos;
- especies o categorías autorizadas;
- incompatibilidades;
- requisitos de etiquetado;
- dosis máximas de aditivos;
- riesgos microbiológicos, químicos o físicos.

El optimizador no puede intercambiar estas restricciones por ahorro económico.

Nivel 2. Restricciones fisiológicas y de bienestar

Incluyen niveles necesarios para prevenir deficiencias, toxicidades, trastornos metabólicos o deterioros previsibles del bienestar. Su flexibilización exige justificación científica y supervisión profesional.

Nivel 3. Restricciones tecnológicas y de calidad

Comprenden capacidad de molienda, mezclado, granulación, estabilidad, fluidez, segregación, dureza, durabilidad y compatibilidad con la instalación.

Nivel 4. Objetivos económicos y ambientales

Una vez satisfechos los niveles anteriores, pueden optimizarse coste, disponibilidad, emisiones, circularidad, proximidad o dependencia de proveedores.

Esta jerarquía evita que un algoritmo compense una restricción crítica con una mejora económica en otra variable.

2.14. Criterios mínimos de validación

Antes de utilizar un modelo en formulación real deberían responderse, como mínimo, las siguientes preguntas:

- ¿Qué población, especie, genética y fase productiva representa?
- ¿Con qué materias primas fue entrenado?
- ¿Qué condiciones ambientales estaban presentes?
- ¿Qué métodos analíticos se utilizaron como referencia?
- ¿Cómo se separaron entrenamiento, validación y prueba?
- ¿Se realizó validación externa en otra fábrica o explotación?
- ¿Cuál es el error medio y cuáles son los errores extremos?
- ¿Cómo se comporta en subgrupos minoritarios?
- ¿Detecta entradas fuera de dominio?
- ¿Qué sucede cuando faltan datos?
- ¿Existe una versión documentada y reproducible?
- ¿Puede reconstruirse la recomendación emitida?
- ¿Qué profesional puede bloquearla?

Una elevada correlación no basta. Un modelo puede mostrar buen ajuste general y cometer errores inaceptables en los casos de mayor impacto.

2.15. La formulación aumentada, no autónoma

El objetivo razonable para la industria no debería ser una formulación completamente autónoma, sino una **formulación aumentada**.

En este modelo:

1. Los sistemas analíticos actualizan la caracterización de las materias primas.
2. Los modelos predictivos estiman consumo, respuesta y riesgo.
3. El optimizador genera varias soluciones compatibles.
4. Las restricciones duras bloquean opciones inseguras.
5. El nutricionista selecciona o autoriza la solución.
6. La fabricación registra la ejecución real.
7. Los datos productivos permiten comparar predicción y resultado.
8. Las desviaciones se investigan y retroalimentan el sistema.

La inteligencia no se encuentra exclusivamente en el algoritmo. Reside en la combinación de datos fiables, modelos apropiados, reglas explícitas, conocimiento profesional, sistemas de calidad y aprendizaje organizativo.

La literatura reciente sobre nutrición de precisión insiste en la convergencia entre sensores, automatización, inteligencia artificial, optimización multiobjetivo y evaluación de sostenibilidad. También señala que la transparencia, la interoperabilidad, la representatividad de los datos y la validación siguen siendo condiciones necesarias para trasladar los resultados experimentales a sistemas productivos robustos.

La conclusión de este bloque es, por tanto, deliberadamente crítica: **la IA no convierte una matriz nutricional deficiente en una buena formulación, ni corrige automáticamente objetivos empresariales mal definidos**. Puede aumentar la precisión del sistema, pero también aumentar la velocidad y escala de sus errores.

La formulación inteligente comienza cuando la empresa deja de preguntar únicamente qué fórmula es más barata y empieza a preguntarse qué combinación es más segura, robusta, biológicamente adecuada, industrialmente reproducible y económicamente eficiente dentro de un intervalo de incertidumbre conocido.

3. La infraestructura de datos: materias primas, animales, proceso y ambiente

La inteligencia artificial aplicada a la alimentación animal no comienza con el algoritmo, sino con la construcción de una representación digital suficientemente fiel del sistema productivo. Antes de predecir, clasificar u optimizar, es necesario determinar qué datos se recopilan, cómo se obtienen, con qué frecuencia, mediante qué unidades y en qué condiciones de calidad.

Esta cuestión es más compleja de lo que suele sugerir el discurso tecnológico. Una explotación ganadera, una fábrica de piensos o una empresa integradora no genera un conjunto homogéneo de información. Produce datos analíticos, productivos, ambientales, sanitarios, económicos y logísticos procedentes de instrumentos, programas y responsables distintos. Algunos son continuos; otros se registran por lote, animal, nave o periodo. Algunos se miden directamente; otros son estimaciones. Algunos están suficientemente normalizados; otros permanecen en documentos, hojas de cálculo o anotaciones manuales.

La inteligencia artificial solo puede descubrir relaciones dentro de aquello que ha sido registrado. No conoce las variables omitidas, los cambios de manejo no documentados ni los errores sistemáticos de medición. Por ello, la calidad de un sistema de IA no debe evaluarse exclusivamente por su arquitectura matemática. Debe analizarse también la calidad de la infraestructura que convierte la realidad biológica e industrial en datos procesables.

Puede expresarse de forma simplificada:

Calidad de la decisión algorítmica f (calidad de los datos, representatividad, modelo, contexto, supervisión)

Un modelo técnicamente excelente, entrenado con datos sesgados o mal identificados, puede ofrecer recomendaciones muy precisas respecto de una realidad que nunca existió.

3.1. El dato no es la realidad: es una medición de la realidad

En un sistema de alimentación animal pueden coexistir al menos tres niveles diferentes:

1. **El fenómeno biológico o industrial real.**
2. **La variable que se decide utilizar para representarlo.**
3. **El valor concreto registrado por el sensor, laboratorio o usuario.**

Por ejemplo, el estado nutricional de un animal es un fenómeno complejo. Puede intentarse representar mediante peso, crecimiento, consumo, condición corporal, producción, composición de leche o determinados biomarcadores. Cada una de estas variables captura una parte del fenómeno, pero ninguna lo representa por completo.

El dato registrado añade otra capa de incertidumbre. El peso puede proceder de una báscula descalibrada; el consumo puede estar incorrectamente asignado cuando varios animales comparten comedero; la temperatura corporal puede variar según el dispositivo y el lugar de medición; la composición nutricional puede depender del procedimiento de muestreo.

La diferencia entre fenómeno, variable y medición es esencial para evitar una confianza excesiva en los resultados algorítmicos. La IA puede procesar con enorme eficacia datos numéricos, pero no puede corregir automáticamente una mala definición de aquello que se pretende medir.

3.2. Las cuatro grandes familias de datos

Una plataforma integral de nutrición animal puede alimentarse de cuatro grandes familias de información:

- datos de materias primas y piensos;
- datos de fabricación y logística;
- datos del animal y del grupo;
- datos ambientales, sanitarios y de manejo.

La utilidad real no depende solo de disponer de grandes volúmenes, sino de poder relacionarlos correctamente mediante identificadores, marcas temporales, unidades homogéneas y metadatos suficientes.

3.3. Datos de materias primas

Las materias primas constituyen el primer nivel de incertidumbre del sistema. Para cada lote deberían poder registrarse, según su relevancia:

- denominación y categoría;
- proveedor;
- país, zona y origen productivo;
- cosecha o campaña;
- fecha de recepción;
- número de lote;
- humedad;
- proteína bruta;
- grasa;
- fibra y sus fracciones;
- almidón y azúcares;
- cenizas;
- minerales;
- aminoácidos;
- digestibilidad o disponibilidad estimada;
- granulometría;
- densidad aparente;
- parámetros microbiológicos;
- micotoxinas y contaminantes;
- tratamientos tecnológicos;
- condiciones y duración del almacenamiento;
- precio, disponibilidad y plazo de reposición.

No todas estas variables deben analizarse con la misma frecuencia. La estrategia de muestreo debe depender de la variabilidad del ingrediente, el historial del proveedor, su nivel de inclusión, la gravedad del peligro y la capacidad real del método analítico.

Una materia prima de alta inclusión y elevada variabilidad nutricional puede justificar un control frecuente de humedad, proteína y energía estimada. Un ingrediente utilizado en dosis bajas, pero con riesgo toxicológico puede exigir controles dirigidos a contaminantes específicos.

El error más frecuente consiste en crear una matriz nutricional aparentemente sofisticada a partir de valores genéricos que no reflejan los lotes realmente empleados. En tal situación, la precisión matemática del formulador es ilusoria.

3.4. El muestreo como punto crítico

El laboratorio solo analiza la porción que recibe. Si la muestra no representa el lote, la exactitud analítica no garantiza la validez de la decisión.

Este problema es especialmente relevante en:

- micotoxinas;
- contaminaciones heterogéneas;
- ingredientes con segregación;
- grasas o líquidos mal homogeneizados;
- piensos con microingredientes;
- lotes grandes almacenados en silos;
- materiales con variaciones de humedad.

Una contaminación localizada puede no aparecer en una muestra insuficiente. Inversamente, una muestra tomada de una zona especialmente afectada puede sobreestimar el riesgo global.

La IA puede ayudar a diseñar estrategias de muestreo basadas en riesgo, pero no elimina la necesidad de un plan técnicamente correcto. Un modelo entrenado con resultados analíticos procedentes de muestras no representativas aprenderá patrones deformados.

Por ello, todo dato analítico crítico debería ir acompañado, al menos, por información sobre:

- fecha y lugar de toma;
- lote y cantidad representada;
- procedimiento de muestreo;
- número y distribución de incrementos;
- preparación y conservación;
- método analítico;
- laboratorio;
- límite de cuantificación;
- incertidumbre o desempeño del método, cuando resulte relevante.

Sin estos metadatos, dos valores numéricamente iguales pueden no tener el mismo significado.

3.5. Espectroscopia y sensores analíticos rápidos

La espectroscopia de infrarrojo cercano permite estimar rápidamente numerosos parámetros de materias primas y piensos. Los equipos pueden instalarse en laboratorio, recepción, líneas de proceso o dispositivos portátiles.

Su principal ventaja no es necesariamente superar la exactitud de un método de referencia, sino aumentar la frecuencia de medición. En lugar de trabajar con pocos análisis retardados, la empresa puede obtener una caracterización más próxima al flujo real de materiales.

Los sistemas micro-NIRS y otras soluciones portátiles están siendo investigados para analizar sobre el terreno la composición de ingredientes y alimentos para aves, favoreciendo potencialmente el ajuste de matrices y la alimentación de precisión. No obstante, estos sistemas dependen de calibraciones construidas con muestras y métodos de referencia adecuados.

Una calibración espectral debe considerarse un modelo en sí misma. Su mantenimiento exige:

- biblioteca representativa;
- muestras de referencia fiables;
- control de deriva instrumental;
- transferencia entre equipos;
- detección de espectros anómalos;
- actualización ante nuevos orígenes;
- validación por producto y rango.

El sistema debería poder señalar cuándo una muestra se encuentra fuera de su dominio de calibración. Emitir una cifra sin advertir que el espectro no se parece a los datos conocidos genera una falsa sensación de certeza.

3.6. Datos de fabricación

La fórmula teórica no equivale necesariamente al pienso fabricado. Entre ambas aparecen múltiples fuentes de desviación:

- errores de dosificación;
- tolerancias de básculas;
- restos de lotes anteriores;
- secuencia de fabricación;
- segregación;
- contaminación cruzada;
- molienda irregular;
- mezclado insuficiente;
- tratamiento térmico;
- humedad añadida;
- pérdidas de microingredientes;
- variaciones de granulación;
- recubrimiento incorrecto;
- almacenamiento inadecuado.

Una plataforma de datos industrial debería integrar, cuando sea posible:

- orden y versión de fabricación;
- cantidades teóricas y reales dosificadas;
- identificación de silos;
- tiempos de mezclado;
- consumo energético;
- temperatura y humedad;
- presión y vapor;
- granulometría;
- durabilidad y dureza del gránulo;
- finos;
 - rendimiento de línea;
 - alarmas;
 - paradas;
 - reprocesados;
 - limpiezas;

- liberación de calidad.

Esta información permite distinguir entre un problema de formulación y un problema de ejecución.

Si el lote presenta menor rendimiento productivo, el análisis no debe concluir automáticamente que la matriz nutricional era incorrecta. Puede haber existido una desviación en molienda, mezcla, granulación, dosificación de enzimas o aplicación de grasa.

3.7. Identidad digital del lote

La utilidad de los datos depende de poder reconstruir qué ingredientes entraron en cada fabricación, qué pienso se produjo, dónde fue enviado y qué animales lo consumieron.

La unidad básica no debería ser únicamente la “fórmula comercial”, sino el **lote físico efectivamente producido**.

Cada lote debería conservar vínculos verificables con:

- materias primas utilizadas;
- resultados analíticos;
- versión de la fórmula;
- parámetros reales de fabricación;
- operador o responsable;
- fecha y línea;
- destino;
- explotación, nave o tanque;
- periodo de consumo;
- incidencias y resultados.

El Reglamento (CE) N.º 183/2005 establece requisitos generales de higiene y mecanismos destinados a asegurar la trazabilidad en la cadena de piensos. La digitalización puede reforzar esta obligación, pero no sustituye la necesidad de conservar registros completos, coherentes y recuperables.

Una cadena digital fragmentada puede resultar menos útil que un sistema tradicional bien gestionado. La trazabilidad no consiste en acumular registros, sino en poder reconstruir la secuencia relevante con rapidez y fiabilidad.

3.8. Datos del animal

Los datos individuales o grupales pueden proceder de:

- identificación RFID;
- básculas;
- comederos y bebederos inteligentes;
- cámaras;
- micrófonos;
- acelerómetros;
- collares;
- podómetros;
- bolos ruminales;
- sensores de temperatura;

- robots de ordeño;
- analizadores de leche;
- sistemas de localización;
- registros veterinarios;
- matadero o planta de procesado.

Las tecnologías de ganadería de precisión permiten una monitorización continua difícil de alcanzar mediante observación convencional. Pueden detectar modificaciones de actividad, descanso, alimentación, rumia, vocalización o desplazamiento que precedan a una pérdida productiva o a una manifestación clínica. Sin embargo, la literatura sigue señalando problemas de interoperabilidad, escalabilidad, coste y validación en condiciones productivas diversas.

Entre las variables más relevantes para nutrición se encuentran:

- peso y crecimiento;
- consumo de pienso;
- consumo de agua;
- frecuencia y duración de visitas al comedero;
- velocidad de ingestión;
- rumia;
- condición corporal;
- producción;
- composición del producto;
- actividad;
- temperatura;
- signos de estrés térmico;
- incidencias sanitarias;
- tratamientos;
- mortalidad y causas.

La precisión aumenta cuando estas variables pueden asociarse al mismo individuo. En sistemas colectivos, es posible disponer de datos abundantes del grupo, pero no identificar qué animal produjo la señal.

3.9. El problema de la identidad

La nutrición individual requiere una identidad digital fiable. Si el sistema asigna un consumo, peso o comportamiento al animal incorrecto, el error puede propagarse a la estimación de necesidades.

Las pérdidas de identificación pueden deberse a:

- fallos de lectura;
- pérdida o sustitución de dispositivos;
- duplicación de códigos;
- errores en altas y bajas;
- movimientos entre corrales;
- asociación incorrecta entre bases de datos;
- dispositivos compartidos o mal instalados.

En animales identificados durante meses, incluso una tasa de error pequeña puede generar numerosas observaciones incorrectas.

Por ello, los sistemas deben contar con reglas de consistencia. Un registro debería marcarse como sospechoso si un animal aparece simultáneamente en dos ubicaciones, muestra una variación de peso fisiológicamente imposible o registra consumos incompatibles con su historial.

3.10. Datos de comportamiento: medir no equivale a interpretar

Una cámara o acelerómetro no mide directamente “bienestar”. Registra píxeles, movimiento, postura o aceleración. Posteriormente, un modelo traduce esos datos en categorías como descanso, alimentación, cojera, agresión o comportamiento anómalo.

Esta traducción requiere validación frente a observaciones de referencia. Además, el mismo comportamiento puede tener significados diferentes según especie, edad, ambiente y momento.

Una reducción de actividad podría reflejar:

- descanso normal;
- estrés térmico;
- enfermedad;
- lesión;
- saciedad;
- falta de espacio;
- fallo del sensor.

La interpretación debe integrar múltiples variables. Los sistemas multimodales, que combinan actividad, temperatura, ingestión, agua, ambiente y producción, pueden ofrecer una representación más robusta que una señal aislada. Aun así, requieren sincronización, interoperabilidad y modelos capaces de tratar datos incompletos.

3.11. Datos ambientales

La respuesta a un pienso no puede separarse del ambiente. Entre las variables relevantes se encuentran:

- temperatura;
- humedad relativa;
- índice temperatura-humedad;
- ventilación;
- velocidad del aire;
- concentración de gases;
- iluminación;
- ruido;
- densidad;
- calidad y temperatura del agua;
- cama;
- estación;
- exposición solar;
- condiciones exteriores.

El estrés térmico modifica el consumo, metabolismo, comportamiento, necesidades de mantenimiento y respuesta inmunitaria. Un sistema que compare lotes sin considerar el ambiente puede atribuir a la dieta diferencias causadas por una ola de calor o por una ventilación deficiente.

Los modelos deben incluir variables ambientales como covariables explicativas y no tratarlas como información secundaria. Las líneas actuales de investigación intentan combinar sensores de explotación, datos climáticos y marcadores fisiológicos, pero siguen existiendo limitaciones por falta de estandarización y de series longitudinales suficientemente amplias.

3.12. Datos sanitarios

La relación entre nutrición y salud es bidireccional. La dieta influye en el estado sanitario, pero la enfermedad modifica también el consumo y el metabolismo.

Un modelo puede interpretar una reducción de ingestión como señal de que debe aumentar la densidad nutricional. Sin embargo, si la causa es un proceso digestivo, metabólico o infeccioso, el ajuste automático puede resultar inadecuado.

Los datos sanitarios deberían incluir:

- diagnósticos;
- signos clínicos;
- tratamientos;
- vacunaciones;
- resultados laboratoriales;
- lesiones;
- decomisos;
- causas de baja;
- mortalidad;
- incidencia por lote;
- uso de antimicrobianos;
- cambios de manejo sanitario.

La integración requiere una terminología consistente. Expresiones como “diarrea”, “problema digestivo”, “enteritis” o “heces blandas” pueden representar fenómenos diferentes o el mismo fenómeno registrado de manera distinta.

Sin vocabularios comunes, el modelo fragmenta la información y reduce su capacidad de aprendizaje.

3.13. Datos históricos y cambio del sistema

Los modelos aprenden del pasado. Pero la producción animal cambia:

- nuevas genéticas;
- nuevas materias primas;
- modificaciones regulatorias;
- cambios de instalaciones;
- enfermedades emergentes;
- evolución climática;
- nuevos aditivos;
- mejoras de manejo;
- cambios comerciales.

Un conjunto histórico amplio no es necesariamente representativo del presente. Puede contener datos procedentes de una genética con menor velocidad de crecimiento, instalaciones antiguas o formulaciones que ya no se utilizan.

Este fenómeno se denomina **deriva de datos** o *data drift*. Se produce cuando cambia la distribución de las variables de entrada. También puede existir **deriva conceptual** cuando cambia la relación entre las variables y el resultado.

Por ejemplo, una misma ingestión puede asociarse a diferentes ganancias de peso después de un cambio genético o sanitario. El modelo conserva la relación antigua y empieza a perder precisión sin que necesariamente se produzca un fallo evidente.

La monitorización del modelo debe incluir:

- comparación entre datos actuales e históricos;
- revisión periódica del error;
- análisis por granja, especie o genética;
- detección de nuevas categorías;
- reentrenamiento controlado;
- conservación de versiones previas;
- criterios de retirada.

3.14. Datos ausentes

En sistemas reales siempre faltan datos. Un sensor deja de transmitir, un análisis no se realiza, un animal pierde el identificador o un operador no registra una incidencia.

Los datos ausentes no siempre aparecen al azar. Una cámara puede fallar precisamente con alta humedad; un sensor puede perder señal en una zona concreta; una explotación con peores resultados puede registrar menos información.

La imputación automática puede rellenar los huecos con valores medios o estimados, pero crea datos que nunca fueron observados. Si se utiliza de manera indiscriminada, reduce artificialmente la variabilidad y puede ocultar incidencias.

Cada variable crítica debería contar con reglas explícitas:

- porcentaje máximo de ausencia;
- método de imputación permitido;
- indicador de dato estimado;
- imposibilidad de decidir sin medición;
- activación de revisión humana.

En determinados casos, la ausencia de información debe conducir a una decisión conservadora y no a una predicción forzada.

3.15. Limpieza de datos

La limpieza de datos no consiste en eliminar todo valor extraño. Los valores extremos pueden representar errores, pero también episodios biológicamente importantes.

Una caída brusca del consumo puede deberse a un sensor averiado o al inicio de una enfermedad. Eliminarla automáticamente como *outlier* puede destruir precisamente la señal que el sistema debería detectar.

Las guías sobre limpieza de datos de sensores ganaderos insisten en que el procedimiento debe definirse según la finalidad del análisis y el contexto de generación de la información. No existe un filtro universal aplicable a todas las variables y usos.

Una estrategia sólida distingue:

- error físicamente imposible;
- valor improbable pero posible;
- evento real confirmado;
- cambio de dispositivo;
- ausencia;
- medición duplicada;
- dato corregido manualmente.

Toda modificación debería quedar registrada. El conjunto “limpio” no debería sustituir al dato bruto, sino coexistir con él y con el historial de transformaciones.

3.16. Sincronización temporal

La nutrición de precisión exige relacionar eventos producidos en momentos diferentes:

- recepción de una materia prima;
- fabricación;
- entrega;
- inicio del consumo;
- respuesta productiva;
- aparición de una patología;
- cambio ambiental.

Un error temporal puede generar asociaciones falsas. Si el sistema atribuye a una dieta un efecto ocurrido antes de su introducción, el aprendizaje queda contaminado.

Las fuentes deben sincronizar relojes, zonas horarias y frecuencias de muestreo. También deben definirse ventanas biológicamente plausibles. Un cambio de fórmula puede afectar al consumo rápidamente, mientras que determinados efectos sobre composición corporal o reproducción aparecen después de periodos más largos.

El modelo no debe asumir que correlación simultánea equivale a causalidad.

3.17. Interoperabilidad

Uno de los principales obstáculos prácticos es que los datos están distribuidos entre plataformas propietarias:

- programa de formulación;
- ERP;
- software de fábrica;
- laboratorio;

- sistema veterinario;
- comederos automáticos;
- robots de ordeño;
- plataforma ambiental;
- matadero;
- proveedores tecnológicos.

Cada sistema puede utilizar formatos, códigos y unidades diferentes. Un animal puede identificarse mediante varios números; un ingrediente puede recibir denominaciones distintas; el contenido de un nutriente puede expresarse sobre materia fresca o seca.

La interoperabilidad exige no solo conexión técnica, sino también interoperabilidad semántica: que dos sistemas atribuyan el mismo significado a una variable.

Las revisiones sobre digitalización ganadera identifican la falta de estándares interoperables como una barrera persistente para integrar datos y trasladar soluciones entre explotaciones.

Una arquitectura empresarial debería incluir:

- catálogo maestro de ingredientes;
- unidades normalizadas;
- identificadores únicos;
- diccionario de variables;
- formatos de intercambio;
- reglas de validación;
- interfaces documentadas;
- control de versiones.

3.18. Granularidad y agregación

Un dato puede registrarse por segundo, minuto, día, lote o ciclo. La granularidad elegida influye en el resultado.

Un promedio diario de consumo puede ocultar que el animal dejó de comer durante varias horas. Un promedio de temperatura de nave puede ocultar zonas de calor. Un resultado medio de peso puede esconder una dispersión creciente.

Pero conservar todos los datos con máxima frecuencia aumenta el coste y la complejidad. Es necesario decidir qué información debe mantenerse en bruto y qué agregaciones son suficientes para cada finalidad.

La agregación debe ser reversible en los casos críticos. Si una alerta se basa en un promedio, debería ser posible acceder a la serie original para investigarla.

3.19. Sesgos de selección

Los datos disponibles no representan necesariamente toda la producción animal.

Las explotaciones altamente digitalizadas suelen ser más grandes, tecnificadas y homogéneas. Los ensayos experimentales se realizan bajo condiciones controladas. Los animales con sensores válidos durante todo el estudio pueden diferir de aquellos cuyos dispositivos fallaron o fueron retirados.

Un modelo entrenado en estas condiciones puede rendir peor en:

- explotaciones pequeñas;
- sistemas extensivos;
- razas locales;
- climas extremos;
- instalaciones antiguas;
- animales enfermos;
- sistemas con menor conectividad.

La precisión media debe desglosarse por subgrupos y contextos. De lo contrario, la tecnología puede funcionar especialmente bien allí donde ya existen mejores recursos y peor donde más apoyo sería necesario.

3.20. Sesgo de supervivencia

En producción animal, los datos suelen concentrarse en los animales que completan el ciclo. Los animales muertos, sacrificados anticipadamente o retirados por enfermedad pueden quedar excluidos de determinados análisis.

Esto genera sesgo de supervivencia. El modelo aprende principalmente de animales que toleraron el sistema y puede infraestimar los factores asociados a fracaso, enfermedad o mortalidad.

Los registros de bajas no deben eliminarse como observaciones incompletas. Constituyen información crítica para evaluar seguridad, salud y bienestar.

3.21. Fugas de información

Existe fuga de información cuando el modelo utiliza durante el entrenamiento datos que no estarían disponibles en el momento real de emitir la predicción.

Por ejemplo, un sistema que pretende anticipar enfermedad no puede entrenarse utilizando variables registradas después del diagnóstico sin distinguirlas adecuadamente. Del mismo modo, no debe predecir el rendimiento de un lote usando información final de matadero.

La fuga puede producir resultados aparentemente extraordinarios en validación y un fracaso severo en producción.

La división de los conjuntos de entrenamiento y prueba debe respetar la estructura temporal y productiva. No basta con separar filas al azar cuando varias observaciones pertenecen al mismo animal, explotación o lote.

3.22. Propiedad y control de los datos

La digitalización introduce una cuestión empresarial sensible: ¿quién controla los datos generados en la explotación o fábrica?

Pueden intervenir:

- ganadero;
- integradora;
- fabricante de piensos;

- veterinario;
- laboratorio;
- proveedor de sensores;
- desarrollador de software;
- proveedor de servicios en la nube.

Los contratos deben determinar:

- titularidad o derechos de uso;
- finalidad permitida;
- acceso;
- reutilización para entrenamiento;
- anonimización;
- transferencia a terceros;
- exportación;
- conservación;
- eliminación;
- portabilidad al terminar el contrato.

Una empresa puede depender progresivamente de una plataforma que almacena el historial necesario para formular o gestionar la explotación. La imposibilidad de exportarlo en un formato utilizable crea dependencia tecnológica.

La portabilidad debe considerarse un requisito estratégico, no solo informático.

3.23. Datos comerciales y confidencialidad

Las matrices nutricionales, precios, rendimientos, conversiones, incidencias sanitarias y estrategias de formulación pueden constituir información comercialmente sensible.

Su exposición puede revelar:

- costes;
- proveedores;
- márgenes;
- composición aproximada de productos;
- debilidades sanitarias;
- rendimiento por explotación;
- estrategia de compras.

Los sistemas de IA generativa alojados externamente plantean un riesgo particular cuando los usuarios introducen fórmulas, certificados, resultados o incidencias sin conocer las condiciones de tratamiento de la información.

La organización debería clasificar los datos y definir qué información puede utilizarse en cada plataforma.

3.24. Ciberseguridad y continuidad operativa

La conexión entre datos, formulación y equipos físicos transforma un incidente informático en un posible riesgo productivo.

Un ataque, error de configuración o fallo del proveedor podría:

- modificar fórmulas;
- alterar dosificaciones;
- bloquear comederos;
- borrar trazabilidad;
- manipular alertas;
- impedir acceso a datos;
- detener producción;
- degradar la calidad sin detección.

Los sistemas críticos requieren:

- control de accesos;
- autenticación reforzada;
- segregación de redes;
- copias de seguridad;
- registro de cambios;
- restauración probada;
- funcionamiento degradado;
- procedimientos manuales alternativos.

La eficiencia obtenida mediante automatización no debe comprarse al precio de perder la capacidad de operar de forma segura cuando la tecnología falla.

3.25. Calidad del dato como responsabilidad organizativa

La calidad de los datos no puede delegarse exclusivamente al departamento informático. Intervienen:

- compras;
- laboratorio;
- calidad;
- producción;
- nutrición;
- veterinaria;
- granja;
- logística;
- dirección.

Cada variable crítica necesita un propietario funcional que conozca su significado y pueda responder por su mantenimiento.

Una matriz mínima de gobierno podría incluir:

Tabla 2. Síntesis de elemento y pregunta de control.

Elemento	Pregunta de control
Propietario	¿Quién responde por la variable?
Fuente	¿Dónde y cómo se genera?
Unidad	¿En qué base se expresa?

Elemento	Pregunta de control
Frecuencia	¿Cada cuánto se actualiza?
Validación	¿Qué límites y controles se aplican?
Uso	¿Qué decisiones dependen de ella?
Criticidad	¿Qué ocurre si falta o es incorrecta?
Conservación	¿Cuánto tiempo debe mantenerse?
Acceso	¿Quién puede verla o modificarla?
Trazabilidad	¿Se conserva el historial de cambios?

3.26. El expediente de datos del modelo

Cada modelo relevante debería disponer de un expediente propio que describa:

- finalidad;
- variables de entrada;
- fuentes;
- periodo cubierto;
- población;
- exclusiones;
- limpieza;
- transformaciones;
- imputaciones;
- etiquetas;
- versión;
- limitaciones;
- sesgos conocidos;
- frecuencia de actualización;
- responsable.

Este expediente permite diferenciar entre modelos que parecen realizar la misma función, pero se apoyan en realidades distintas.

Dos sistemas de predicción de consumo pueden utilizar variables diferentes, estar entrenados en especies o condiciones distintas y presentar errores no comparables.

3.27. La arquitectura del dato mínimo viable

No toda empresa necesita implantar simultáneamente sensores, cámaras, ómicas y gemelos digitales. La acumulación indiscriminada de datos puede generar costes sin utilidad.

Una arquitectura inicial razonable debería priorizar:

1. identidad fiable de materias primas y lotes;
2. composición analítica relevante;
3. versión exacta de las fórmulas;
4. cantidades reales fabricadas;
5. destino y periodo de consumo;
6. consumo y rendimiento productivo;

7. incidencias sanitarias;
8. condiciones ambientales básicas;
9. datos económicos;
10. registro de decisiones y modificaciones.

Sobre esta base pueden incorporarse progresivamente sensores o modelos avanzados cuando exista una pregunta empresarial o biológica concreta.

La pregunta adecuada no es “¿qué más podemos medir?”, sino:

¿Qué decisión queremos mejorar, qué variable la condiciona y qué calidad de dato necesitamos para hacerlo de forma segura?

3.28. Principio de proporcionalidad

La exigencia de datos debe ser proporcional al impacto de la decisión.

Un modelo utilizado para sugerir una revisión comercial puede tolerar mayor incertidumbre que otro que modifique automáticamente la dosificación de un micronutriente o descarte una alerta toxicológica.

A mayor potencial de daño deberían exigirse:

- datos más fiables;
- validación independiente;
- menor automatización;
- mayor explicabilidad;
- supervisión reforzada;
- registros más completos;
- límites conservadores.

3.29. Cuadro de riesgos de datos

Tabla 3. Síntesis de riesgo, ejemplo, consecuencia y control principal.

Riesgo	Ejemplo	Consecuencia	Control principal
Muestra no representativa	Micotoxina localizada no detectada	Falso negativo	Plan de muestreo validado
Sensor descalibrado	Consumo infraestimado	Ajuste nutricional incorrecto	Calibración y contraste
Identidad errónea	Datos asignados a otro animal	Necesidad individual falsa	Controles de consistencia
Unidad incorrecta	Materia seca confundida con producto fresco	Error de formulación	Diccionario y validación
Dato ausente imputado	Se rellena una caída real de consumo	Pérdida de alerta	Indicador de imputación
Deriva	Nueva genética	Pérdida progresiva de precisión	Seguimiento del desempeño
Fuga de información	Uso de datos posteriores	Validación artificialmente alta	Diseño temporal correcto
Falta de interoperabilidad	Ingredientes duplicados	Historial fragmentado	Catálogos maestros
Cambio no registrado	Ajuste manual de fórmula	Trazabilidad incompleta	Registro de versiones

Riesgo	Ejemplo	Consecuencia	Control principal
Ciberincidente	Modificación de parámetros	Riesgo productivo o sanitario	Seguridad y contingencia

3.30. Del “big data” al dato suficiente y defendible

La alimentación animal no necesita necesariamente más datos, sino datos que puedan ser interpretados y defendidos.

Un sistema técnicamente maduro debe poder contestar:

- de dónde procede cada dato;
- qué representa;
- con qué incertidumbre;
- qué transformaciones ha sufrido;
- qué decisión alimentó;
- quién podía modificarlo;
- durante cuánto tiempo se conserva.

Esta capacidad es esencial tanto para la mejora técnica como para una auditoría, reclamación, retirada de producto o investigación sanitaria.

La conclusión es inequívoca: **la infraestructura de datos constituye una parte del sistema de seguridad de los piensos**. No es un elemento accesorio del proyecto de IA. Cuando una decisión nutricional o de control depende de información digital, la integridad de esa información se convierte en una condición de seguridad, eficacia y responsabilidad.

La empresa que implanta inteligencia artificial sin gobierno del dato no está digitalizando verdaderamente la nutrición. Está automatizando sus incertidumbres.

4. Materias primas inteligentes: de la matriz nutricional estática a la caracterización dinámica por lote

La formulación animal tradicional se apoya en una representación simplificada de las materias primas. Cada ingrediente aparece en la matriz con una denominación, un precio, unos límites de inclusión y una serie de valores nutricionales que se consideran suficientemente estables para resolver el problema de formulación. Sin embargo, el maíz, el trigo, la cebada, la harina de soja, las harinas de colza o girasol, los forrajes, las grasas, los coproductos y los subproductos no son sustancias químicamente constantes. Son matrices biológicas e industriales cuya composición varía de manera significativa.

Esta variabilidad afecta tanto al contenido analítico como al valor nutricional efectivo. Dos lotes con una concentración semejante de proteína bruta pueden presentar perfiles aminoacídicos, digestibilidad, tratamiento térmico o contenido en factores antinutricionales diferentes. Del mismo modo, materias primas que cumplen formalmente una especificación comercial pueden comportarse de forma distinta durante la molienda, el mezclado, la granulación, el almacenamiento o la digestión.

La inteligencia artificial ofrece la posibilidad de sustituir progresivamente la matriz fija por una **matriz dinámica de materias primas**, actualizada a partir de datos analíticos, espectrales, históricos, geográficos, agronómicos, industriales y logísticos. No obstante, este avance solo es real cuando el sistema distingue entre medición, estimación y predicción, y cuando las incertidumbres asociadas a cada valor son conocidas.

4.1. La materia prima nominal y la materia prima real

En la documentación comercial puede utilizarse una única categoría —por ejemplo, harina de soja— para materiales procedentes de diferentes países, campañas, variedades, sistemas de cultivo y condiciones de procesado. La denominación es útil para la contratación, pero nutricionalmente insuficiente.

La materia prima real puede estar condicionada por:

- variedad o genética vegetal;
- suelo y fertilización;
- disponibilidad hídrica;
- temperatura durante el cultivo;
- fecha de recolección;
- madurez;
- secado;
- almacenamiento;
- procesado térmico;
- extracción de aceite;
- descascarillado;
- contaminación;
- tiempo transcurrido desde la producción.

Estas variables afectan a la concentración y disponibilidad de nutrientes. Por ello, la precisión de una fórmula no puede ser mayor que la precisión con que se conoce el lote utilizado.

La matriz estática asigna:

$$a_{ij} = \text{valor fijo del nutriente } j \text{ en el ingrediente } i$$

Una matriz dinámica debería representar:

$$a_{ij,l,t} = f(\text{lote}, \text{origen}, \text{campaña}, \text{procesado}, \text{tiempo})$$

donde el valor del nutriente deja de depender únicamente del nombre del ingrediente y pasa a depender del lote (l) y del momento (t).

4.2. Variabilidad química frente a variabilidad nutricional

La variabilidad química puede observarse mediante diferencias en:

- humedad;
- proteína;
- aminoácidos;
- grasa;
- almidón;
- fibra;
- cenizas;
- minerales;
- azúcares;
- compuestos antinutricionales.

Pero la variabilidad nutricional incluye, además:

- digestibilidad;
- degradabilidad ruminal;
- disponibilidad de aminoácidos;
- valor energético;
- fermentabilidad;
- velocidad de tránsito;
- palatabilidad;
- capacidad de consumo;
- respuesta productiva.

La composición proximal no describe por completo el comportamiento biológico de la materia prima. Una harina proteica sometida a tratamiento térmico insuficiente puede conservar factores antinutricionales; un tratamiento excesivo puede reducir la disponibilidad de aminoácidos mediante reacciones de Maillard. En ambos casos, la proteína bruta puede permanecer aparentemente dentro de especificación.

La inteligencia artificial puede encontrar asociaciones entre variables químicas, espectrales, de proceso y digestibilidad. Sin embargo, estas asociaciones deben entrenarse contra medidas biológicas o analíticas de referencia suficientemente fiables. El modelo no puede descubrir la digestibilidad real si nunca se le proporcionan datos representativos sobre ella.

4.3. El error de tratar los valores tabulados como hechos observados

Las tablas nutricionales son instrumentos indispensables. Permiten formular cuando no existen datos específicos y proporcionan referencias consolidadas. Su limitación aparece cuando se utilizan como si representaran exactamente el lote adquirido.

Un valor tabulado es normalmente:

- una media;
- una mediana;
- una estimación derivada;
- un resultado procedente de una población de muestras;
- una referencia obtenida bajo determinadas condiciones.

No es necesariamente el valor del material almacenado en un silo concreto.

El problema se agrava cuando una empresa actualiza los precios de las materias primas diariamente, pero mantiene durante años los mismos valores nutricionales. El optimizador reacciona con gran sensibilidad a la variación económica y con escasa sensibilidad a la variación biológica.

Una formulación verdaderamente dinámica requiere que la actualización de la matriz nutricional tenga una frecuencia proporcional a la variabilidad y al impacto del ingrediente.

4.4. La espectroscopia como herramienta de alta frecuencia

La espectroscopia de infrarrojo cercano, NIRS, es una de las tecnologías más extendidas para la caracterización rápida de materias primas y piensos. Su interés industrial reside en la posibilidad de realizar determinaciones no destructivas, con poca preparación y en plazos mucho menores que numerosos métodos químicos convencionales.

La evidencia disponible muestra que NIRS puede utilizarse para estimar diferentes parámetros de calidad de dietas e ingredientes, pero su rendimiento depende de la matriz, el analito, la preparación de la muestra, el instrumento, la calibración y la calidad de los métodos de referencia. Una revisión sistemática publicada en 2024 destacó su utilidad creciente en la evaluación de dietas ganaderas, al tiempo que señaló heterogeneidad metodológica y limitaciones de transferibilidad entre estudios y condiciones.

La espectroscopia no mide directamente proteína, fibra o digestibilidad. Registra la interacción de la radiación con la muestra. Posteriormente, un modelo matemático relaciona el espectro con resultados analíticos conocidos.

Puede expresarse como:

$$\hat{y} = f(S)$$

donde:

- (S) es el espectro;
- (f) es el modelo de calibración;
- ($\hat{y}$) es la propiedad estimada.

El resultado depende tanto del espectro como de la función aprendida. Por ello, NIRS debe considerarse un sistema combinado de instrumento, preparación, biblioteca de calibración y modelo.

4.5. Modelos lineales, aprendizaje automático y aprendizaje profundo

La quimiometría clásica utiliza con frecuencia métodos como:

- análisis de componentes principales;
- regresión por mínimos cuadrados parciales;

- análisis discriminante;
- regresión lineal múltiple.

Estos métodos siguen siendo robustos y útiles, especialmente cuando existe una relación aproximadamente lineal y un conjunto de datos moderado.

Los modelos de aprendizaje automático pueden añadir:

- máquinas de vectores soporte;
- bosques aleatorios;
- potenciación de gradiente;
- k vecinos más próximos;
- redes neuronales;
- aprendizaje profundo.

Su principal ventaja potencial es la capacidad para representar relaciones no lineales e interacciones complejas. Su principal riesgo es el sobreajuste y la pérdida de interpretabilidad.

No debe asumirse que una red neuronal superará necesariamente a un modelo quimiométrico clásico. El resultado depende de:

- número y diversidad de muestras;
- relación señal-ruido;
- preprocesado;
- distribución de los datos;
- selección de variables;
- validación externa.

Los estudios sobre calibraciones de piensos han mostrado que los modelos globales pueden perder precisión en matrices heterogéneas, y que enfoques locales o específicos pueden mejorar determinados resultados al seleccionar muestras más próximas al espectro analizado.

4.6. Modelo global o modelo específico

Una empresa puede intentar desarrollar una única calibración para todos los ingredientes o calibraciones diferenciadas por categoría, origen o producto.

El modelo global presenta ventajas operativas:

- simplifica el mantenimiento;
- amplía el rango aparente;
- permite procesar muestras diversas;
- reduce el número de modelos.

Pero también puede perder precisión porque intenta explicar matrices muy diferentes con una sola función.

Los modelos específicos pueden ofrecer mayor exactitud en una población más estrecha, aunque presentan riesgo de quedar rápidamente obsoletos o no reconocer una muestra nueva.

Una arquitectura avanzada puede utilizar un sistema jerárquico:

1. identificación o clasificación inicial de la muestra;
2. detección de muestras anómalas;
3. selección del modelo más apropiado;
4. estimación del parámetro;
5. cálculo de incertidumbre;
6. decisión sobre confirmación analítica.

El objetivo no es obtener siempre una cifra, sino saber cuándo la cifra es confiable.

4.7. La detección de muestras fuera del dominio

Uno de los mayores riesgos de los modelos espectrales es que produzcan resultados incluso cuando la muestra no se parece a las utilizadas durante el entrenamiento.

Una calibración construida con maíces de determinadas campañas puede recibir una muestra procedente de:

- otro origen;
- una variedad nueva;
- un tratamiento diferente;
- contaminación;
- deterioro;
- adulteración;
- humedad extrema.

El programa puede generar una predicción numérica sin advertir que se trata de una extrapolación.

Un sistema industrial debería incorporar una métrica de distancia respecto del dominio de calibración. Cuando la muestra exceda el umbral, la respuesta correcta será:

Predicción no válida o insuficientemente respaldada. Requiere análisis de referencia.

Esta capacidad de abstención es una característica de seguridad. Un modelo que siempre responde no es necesariamente más útil; puede ser más peligroso.

4.8. Predicción de aminoácidos

El análisis individual de aminoácidos es más lento y costoso que la determinación de proteína bruta. Por ello, las calibraciones NIRS han sido investigadas como herramientas para estimar perfiles aminoacídicos en cereales y otros ingredientes.

Existen trabajos que demostraron la posibilidad de predecir aminoácidos esenciales en trigo, cebada, maíz, triticale, salvados, arroz y sorgo mediante calibraciones específicas, aunque la exactitud varía entre aminoácidos y matrices.

Desde el punto de vista de la formulación, este avance es relevante porque la proteína bruta constituye un indicador demasiado agregado. Las necesidades de monogástricos se expresan cada vez más en términos de aminoácidos digestibles y relaciones respecto de un aminoácido de referencia.

Sin embargo, predecir concentración no equivale a predecir digestibilidad. Dos muestras con cantidades similares de lisina total pueden diferir en lisina reactiva o disponible cuando el procesado térmico ha sido diferente.

La caracterización inteligente debería separar:

- aminoácido total;
- aminoácido digestible estimado;
- indicador de daño térmico;
- incertidumbre de la predicción.

4.9. Predicción de digestibilidad

La digestibilidad es una propiedad especialmente valiosa y difícil de medir de forma rutinaria. Puede estimarse mediante ensayos in vivo, métodos in vitro, ecuaciones, marcadores o aproximaciones espectrales.

NIRS ha mostrado utilidad para predecir composición y determinadas medidas de digestibilidad en raciones completas, aunque el comportamiento del modelo depende de la variabilidad de las muestras y de la solidez de la referencia biológica.

La inteligencia artificial puede integrar:

- composición química;
- espectro;
- origen;
- procesado;
- granulometría;
- temperatura;
- datos históricos de ensayos;
- respuesta productiva.

No obstante, existe un riesgo de circularidad. Si el modelo se entrena con digestibilidades que ya fueron estimadas mediante ecuaciones, aprenderá a reproducir esas ecuaciones y no una verdad biológica independiente.

Para mejorar realmente el conocimiento se necesitan datos de referencia obtenidos mediante procedimientos adecuados y representativos de la especie y fase productiva.

4.10. Valor energético dinámico

La energía es una de las variables con mayor impacto económico en la formulación. Sin embargo, su valor depende del sistema utilizado:

- energía digestible;
- energía metabolizable;
- energía neta;
- unidades específicas por especie.

Las ecuaciones energéticas suelen derivarse de componentes químicos. Un sistema de IA puede añadir información de origen, procesado y respuesta real, pero debe respetar la estructura fisiológica del sistema energético.

El valor energético dinámico podría expresarse como una distribución:

$$E_i \sim \mathcal{D}(\mu_i, \sigma_i)$$

donde:

- (μ_i) es el valor esperado;
- (σ_i) representa su variabilidad;
- $(\mathcal{D})$ es una distribución estimada.

La formulación puede entonces valorar no solo el valor medio, sino la probabilidad de incumplimiento.

4.11. Actualización bayesiana de matrices

Una forma conceptualmente sólida de actualizar la matriz consiste en combinar conocimiento previo con nuevos resultados.

El valor tabulado funciona como información inicial:

$$P(\theta)$$

Los análisis del lote aportan nueva evidencia:

$$P(D|\theta)$$

La distribución actualizada será:

$$P(\theta|D) \propto P(D|\theta)P(\theta)$$

Este enfoque permite que un único resultado no sustituya automáticamente todo el conocimiento previo. La actualización dependerá de:

- precisión del análisis;
- tamaño de muestra;
- historial del proveedor;
- variabilidad conocida;
- consistencia con otros datos.

La matriz dinámica no debería reaccionar de forma desproporcionada a cualquier medición aislada, especialmente cuando la representatividad del muestreo es incierta.

4.12. Origen y campaña como variables nutricionales

La procedencia geográfica y la campaña pueden funcionar como variables predictivas porque resumen factores agronómicos y de procesado.

En harina de soja, por ejemplo, la composición, el contenido de fibra, el perfil de azúcares, la calidad del procesado y el valor energético pueden variar entre orígenes. La información espectral y nutricional puede utilizarse para segregar lotes y asignar valores económicos diferenciados. Un análisis publicado en 2024 mostró el valor potencial de combinar procedencia y NIRS para valorar harinas de soja en formulaciones

avícolas, aunque la rentabilidad final dependía de los precios relativos y de los supuestos nutricionales utilizados.

La IA puede aprender patrones asociados al origen, pero no debería convertirlo en un sustituto permanente del análisis. Una misma región puede producir lotes diferentes, y una campaña puede alterar relaciones históricas.

4.13. Segregación inteligente de materias primas

Una aplicación industrial de alto valor consiste en separar lotes según su calidad nutricional real.

En lugar de mezclar todas las partidas bajo una única categoría, la empresa puede clasificarlas, por ejemplo, en:

- alta energía;
- estándar;
- alta proteína;
- elevada fibra;
- mayor riesgo;
- uso restringido;
- pendiente de confirmación.

La segregación permite asignar cada lote a la fórmula donde produce mayor valor. Un ingrediente de mayor calidad puede destinarse a fases sensibles o dietas de alta densidad; otro con menor valor energético puede utilizarse donde su efecto sea menos crítico.

Esta estrategia transforma el control de calidad en una función económica. El análisis deja de ser únicamente un mecanismo de rechazo y se convierte en una herramienta de asignación óptima.

4.14. Predicción de comportamiento industrial

Las materias primas no solo aportan nutrientes. También influyen en:

- molienda;
- capacidad de mezcla;
- fluidez;
- formación de puentes;
- consumo de energía;
- calidad del gránulo;
- durabilidad;
- producción de finos;
- estabilidad;
- conservación.

Un modelo puede relacionar características de los ingredientes con parámetros de proceso y calidad final. Por ejemplo, contenido de almidón, fibra, grasa, humedad y granulometría pueden afectar a la granulación.

La formulación inteligente debería incorporar restricciones tecnológicas. Una solución nutricionalmente válida puede provocar:

- reducción de capacidad;

- mayor consumo de vapor;
- baja durabilidad;
- segregación;
- problemas de almacenamiento.

El coste real de una materia prima incluye su efecto sobre la fábrica.

4.15. Coproductos y economía circular

La alimentación animal utiliza numerosos coproductos procedentes de industrias:

- cerealistas;
- oleaginosas;
- azucareras;
- cerveceras;
- lácteas;
- alimentarias;
- biotecnológicas;
- de fermentación.

Estos materiales pueden reducir costes, aprovechar nutrientes y mejorar la circularidad. Sin embargo, suelen presentar mayor variabilidad, menor estandarización y riesgos específicos de conservación o contaminación.

La IA puede facilitar su utilización mediante:

- clasificación de lotes;
- predicción de composición;
- cálculo de digestibilidad;
- optimización de límites;
- evaluación de estabilidad;
- análisis de riesgo;
- estimación de valor económico.

Pero existe un error conceptual frecuente: asumir que todo coproducto es automáticamente sostenible. La sostenibilidad depende de:

- procesamiento necesario;
- secado;
- transporte;
- estabilidad;
- sustitución efectiva;
- emisiones;
- pérdidas;
- efectos productivos.

Un ingrediente circular que exige gran cantidad de energía para estabilizarse o que reduce significativamente la eficiencia puede ofrecer un beneficio ambiental menor del esperado.

4.16. Ingredientes emergentes

La innovación incorpora materias primas como:

- proteínas de insectos;
- algas;
- microorganismos;
- proteínas unicelulares;
- biomasa fermentativa;
- subproductos transformados;
- nuevas oleaginosas;
- ingredientes obtenidos mediante biorrefinería.

Los modelos históricos disponen de pocos datos sobre estos materiales. Esto limita la aplicación directa de IA.

La similitud química con ingredientes convencionales no garantiza equivalencia nutricional. Pueden existir diferencias en:

- estructura celular;
- digestibilidad;
- palatabilidad;
- factores antinutricionales;
- minerales;
- nucleótidos;
- contaminantes;
- estabilidad;
- interacción con el procesado.

La incorporación de un ingrediente nuevo debe tratarse como una expansión del dominio del modelo. Requiere datos específicos, validación y límites iniciales prudentes.

4.17. Adulteración y fraude

Las materias primas para alimentación animal están expuestas a riesgos de fraude económico:

- sustitución;
- dilución;
- falsificación de origen;
- adición de materiales de menor valor;
- manipulación analítica;
- etiquetado incorrecto.

La espectroscopia, la imagen hiperespectral, Raman, cromatografía y otras técnicas pueden combinarse con aprendizaje automático para detectar patrones incompatibles con productos auténticos.

Estos sistemas son especialmente útiles para cribado. Pueden seleccionar muestras sospechosas y concentrar los análisis confirmatorios. Sin embargo, una clasificación algorítmica no debería ser la única base para acusar fraude o rechazar definitivamente un lote cuando existen consecuencias contractuales o jurídicas importantes.

La secuencia responsable sería:

1. detección de anomalía;
2. revisión de datos;
3. repetición o nueva muestra;
4. análisis confirmatorio;
5. evaluación contractual y regulatoria;
6. decisión documentada.

4.18. Fraude frente a variabilidad natural

Un desafío importante consiste en distinguir adulteración de variabilidad legítima.

Un lote puede alejarse del patrón conocido por:

- campaña excepcional;
- variedad nueva;
- diferente procesamiento;
- almacenamiento;
- origen no representado.

El modelo puede clasificarlo como sospechoso, aunque sea auténtico. Por ello, las herramientas de detección deben manejar tres categorías:

- compatible;
- no compatible;
- indeterminado.

La categoría indeterminada evita convertir toda novedad en fraude.

4.19. Detección de deterioro

Las materias primas pueden deteriorarse durante almacenamiento por:

- humedad;
- calentamiento;
- oxidación;
- insectos;
- hongos;
- actividad microbiana;
- enranciamiento.

El deterioro altera el valor nutricional y puede generar riesgos sanitarios.

La IA puede integrar:

- temperatura de silos;
- humedad;
- CO₂;
- tiempo;
- aireación;

- imágenes;
- olores;
- resultados analíticos;
- clima exterior.

El objetivo será anticipar condiciones de riesgo antes de que el daño sea irreversible.

Un sistema predictivo de almacenamiento no debe limitarse a detectar un valor fuera de rango. Debe evaluar tendencia y velocidad de cambio.

4.20. Granos y semillas como sistemas heterogéneos

Los lotes de grano contienen unidades individuales con diferente madurez, humedad, daño y contaminación. Un promedio químico puede ocultar una pequeña fracción problemática.

La visión artificial y la imagen hiperespectral permiten analizar grano por grano o zonas espaciales, identificando:

- roturas;
- daño por insectos;
- decoloración;
- impurezas;
- mohos;
- cuerpos extraños.

La ventaja principal es detectar heterogeneidad. Su limitación es que muchas propiedades internas o contaminantes no son directamente visibles y requieren confirmación.

4.21. Grasas y aceites

Las grasas presentan riesgos particulares:

- variación de perfil lipídico;
- oxidación;
- hidrólisis;
- contaminantes;
- mezclas no declaradas;
- interacción con antioxidantes;
- dificultad de muestreo.

Un modelo puede integrar:

- acidez;
- índice de peróxidos;
- anisidina;
- perfil de ácidos grasos;
- espectros;
- origen;
- tiempo y temperatura;
- oxígeno;
- historial del tanque.

La formulación debería utilizar no solo el porcentaje de grasa, sino su calidad energética y oxidativa. Una grasa deteriorada puede mantener parte de su valor analítico y producir efectos negativos sobre palatabilidad, estabilidad y salud.

4.22. Proteínas procesadas y daño térmico

En las harinas proteicas, el procesamiento determina parte importante del valor nutricional.

El sistema debe evitar dos extremos:

- tratamiento insuficiente;
- sobreprocesado.

Pueden utilizarse indicadores analíticos, espectrales y de proceso para predecir:

- inhibidores residuales;
- solubilidad;
- dispersibilidad;
- proteína ligada;
- lisina reactiva;
- digestibilidad.

La IA puede combinar señales débiles que aisladamente no son concluyentes. Pero debe validarse frente a métodos adecuados y no limitarse a reproducir la clasificación histórica del proveedor.

4.23. Forrajes y ensilados

Los forrajes presentan una variabilidad especialmente elevada por:

- especie vegetal;
- madurez;
- corte;
- clima;
- suelo;
- conservación;
- fermentación;
- muestreo.

La composición puede cambiar dentro de una misma parcela, silo o periodo de suministro.

En materiales húmedos, la preparación de la muestra tiene gran influencia sobre las calibraciones NIRS. Un estudio de 2024 comparó mediciones en muestras húmedas sin procesar frente a muestras secas y molidas, mostrando que la elección de la base y el tratamiento previo puede modificar la capacidad predictiva.

Para nutrición de precisión en rumiantes, el sistema debe considerar:

- materia seca real;
- variación diaria;
- tamaño de partícula;
- fermentación;
- estabilidad aeróbica;

- digestibilidad de fibra;
- selección en pesebre.

Formular con una materia seca incorrecta altera simultáneamente la concentración real de todos los nutrientes.

4.24. Pet food y matrices complejas

En alimentos para animales de compañía, la caracterización rápida resulta también relevante por la diversidad de ingredientes, formulaciones y procesos.

Un trabajo de 2024 evaluó equipos NIR de sobremesa y portátiles para predecir la composición química de alimentos para animales de compañía, mostrando el potencial de estas tecnologías para control rápido, aunque con diferencias de desempeño entre instrumentos y parámetros.

Las matrices de pet food añaden complejidad por:

- formulaciones multicomponente;
- extrusión;
- recubrimientos;
- grasas superficiales;
- ingredientes de origen animal;
- palatantes;
- claims;
- exigencias de uniformidad.

La IA puede apoyar autenticidad, composición y consistencia, pero no debe sustituir la comprobación reglamentaria de declaraciones nutricionales y seguridad.

4.25. Del valor nutricional al valor económico real

El precio por tonelada no representa por sí solo el coste nutricional de un ingrediente.

Puede calcularse un valor sombra o precio máximo admisible en función de:

- nutrientes aportados;
- sustitución de otros ingredientes;
- restricciones activas;
- variabilidad;
- efecto productivo;
- procesado;
- logística;
- riesgo.

Una materia prima barata y variable puede requerir:

- mayores márgenes;
- más análisis;
- segregación;
- formulaciones conservadoras;
- mayor inventario.

Su coste ajustado al riesgo será superior al precio de compra.

Puede expresarse:

$$C_{\text{real}} = C_{\text{compra}} + C_{\text{proceso}} + C_{\text{control}} + C_{\text{variabilidad}} + C_{\text{riesgo}}$$

La IA puede estimar algunos de estos componentes utilizando datos históricos.

4.26. Puntuación multidimensional del proveedor

La gestión de proveedores no debería basarse exclusivamente en precio y conformidad puntual.

Un sistema puede generar una puntuación dinámica a partir de:

- variabilidad nutricional;
- incumplimientos;
- micotoxinas;
- puntualidad;
- documentación;
- reclamaciones;
- estabilidad entre lotes;
- desviaciones de origen;
- capacidad de respuesta;
- impacto productivo.

Sin embargo, debe evitarse una puntuación opaca que impida al proveedor conocer y discutir los datos relevantes.

La evaluación automatizada debe ser:

- trazable;
- revisable;
- basada en variables justificadas;
- corregible;
- proporcional.

4.27. Matriz nutricional probabilística

La matriz avanzada debería sustituir el valor único por, al menos:

- valor esperado;
- desviación;
- intervalo de confianza;
- número de muestras;
- fecha;
- origen;
- método;
- calidad de la predicción.

Ejemplo:

Tabla 4. Síntesis de parámetro, valor esperado, variabilidad, fuente y confianza.

Parámetro	Valor esperado	Variabilidad	Fuente	Confianza
Proteína bruta	46,8 %	±0,9	NIRS + laboratorio	Alta
Lisina total	2,86 %	±0,12	Modelo NIRS	Media
Lisina digestible	2,55 %	±0,15	Ecuación actualizada	Media
Energía metabolizable	2.420 kcal/kg	±90	Modelo combinado	Media
Fibra neutro detergente	9,6 %	±1,1	NIRS	Alta

Esta presentación evita que el formulador trate todas las cifras como igualmente ciertas.

4.28. Criterios de actualización de la matriz

La actualización puede activarse cuando:

- llega una nueva campaña;
- cambia el origen;
- cambia el proveedor;
- se modifica el proceso;
- aparece una desviación analítica;
- aumenta la variabilidad;
- cambia el método;
- se detecta deriva;
- existen resultados productivos incompatibles.

No toda actualización debe aplicarse automáticamente. Las variables críticas requieren revisión.

Una buena práctica consiste en mantener:

- matriz corporativa;
- matriz por proveedor;
- matriz por origen;
- matriz por campaña;
- valor específico de lote.

El sistema seleccionará el nivel más preciso disponible y documentará la fuente.

4.29. Confirmación analítica basada en riesgo

La IA puede decidir qué muestras merecen análisis más costosos.

El muestreo adaptativo puede priorizar lotes con:

- proveedor nuevo;
- origen nuevo;
- espectro atípico;
- alta inclusión;
- historial de contaminación;
- campaña de riesgo;

- precio anómalo;
- documentación incompleta;
- efecto crítico sobre la fórmula.

Esta estrategia no reduce necesariamente el control; lo concentra donde produce mayor valor.

No obstante, debe conservarse una frecuencia basal aleatoria. Si solo se analizan muestras que el modelo considera sospechosas, el sistema dejará de detectar peligros nuevos que no se parecen a los históricos.

4.30. Diseño de una plataforma de materias primas inteligentes

Una arquitectura funcional podría incluir:

Módulo de recepción

- identificación;
- proveedor;
- origen;
- documentos;
- inspección;
- muestreo;
- espectro;
- aceptación provisional.

Módulo analítico

- laboratorio;
- métodos rápidos;
- resultados;
- incertidumbre;
- comparación histórica.

Módulo predictivo

- composición;
- digestibilidad;
- energía;
- riesgo;
- anomalías.

Módulo de formulación

- actualización de matriz;
- valoración;
- segregación;
 - restricciones;
 - uso recomendado.

Módulo de seguimiento

- fabricación;

- destino;
- respuesta animal;
- reclamaciones;
- retroalimentación.

4.31. Límites de la caracterización algorítmica

La IA no puede solucionar por sí sola:

- un muestreo deficiente;
- métodos de referencia incorrectos;
- ausencia de muestras extremas;
- cambios no registrados;
- contaminación localizada;
- adulterantes desconocidos;
- relaciones causales no observadas;
- falta de conocimiento biológico.

Tampoco debe confundirse una buena predicción de composición con una evaluación integral de seguridad. Una muestra puede presentar valores nutricionales normales y contener un peligro no incluido en el modelo.

4.32. Principio de doble lectura

Toda materia prima crítica debe analizarse simultáneamente desde dos perspectivas:

Lectura nutricional

¿Qué aporta y con qué variabilidad?

Lectura de seguridad

¿Qué peligros puede introducir y con qué probabilidad?

La misma información puede tener significados diferentes. La humedad puede afectar al valor nutricional y al riesgo de deterioro; el origen puede influir en energía y en exposición a micotoxinas; el procesado puede mejorar digestibilidad y generar daño térmico.

El sistema no debe optimizar la primera lectura ignorando la segunda.

4.33. Conclusión: conocer el ingrediente antes de optimizarlo

La mayor contribución de la IA en la gestión de materias primas no consiste en producir un número más sofisticado, sino en transformar la forma en que la empresa representa la incertidumbre.

La matriz clásica afirma:

Este ingrediente contiene este valor.

La matriz inteligente debería expresar:

Este lote probablemente contiene este intervalo, según estas mediciones, este modelo y este nivel de confianza, y su utilización implica estos riesgos.

Ese cambio modifica la formulación, la compra, la calidad, el almacenamiento y la trazabilidad.

La inteligencia artificial permite aumentar la frecuencia de caracterización, reconocer patrones, segregar lotes, detectar anomalías y actualizar el valor económico. Pero no convierte una predicción en una medición ni una correlación en una certeza biológica.

La materia prima inteligente no es aquella que posee más datos asociados, sino aquella cuyo valor nutricional, tecnológico y sanitario puede ser estimado, actualizado y defendido con un grado de incertidumbre explícito.

5. Micotoxinas, contaminantes y sistemas predictivos de alerta: de la detección puntual a la gestión dinámica del riesgo

La seguridad de la alimentación animal no puede reducirse a comprobar si una muestra cumple o incumple un límite numérico. Las materias primas y los piensos forman parte de una cadena abierta, sometida a variaciones agronómicas, climáticas, industriales, logísticas y biológicas. Los peligros pueden originarse antes de la cosecha, durante el almacenamiento, en el transporte, en la fabricación o mediante contaminaciones cruzadas. Algunos presentan una distribución relativamente homogénea; otros aparecen concentrados en focos que dificultan enormemente su detección.

La inteligencia artificial puede mejorar la vigilancia mediante modelos de predicción, clasificación y priorización del control. Puede combinar procedencia, condiciones meteorológicas, historial del proveedor, resultados analíticos, humedad, temperatura de almacenamiento, características espectrales y datos productivos para estimar la probabilidad de contaminación o deterioro.

Sin embargo, un sistema predictivo no transforma un peligro heterogéneo en un peligro homogéneo ni elimina el error asociado al muestreo. Tampoco convierte la ausencia de detección en ausencia de contaminación. En materia de micotoxinas, la principal amenaza no es únicamente el falso positivo que inmoviliza un lote conforme, sino el **falso negativo que permite introducir en la cadena un material peligroso bajo una apariencia estadística de normalidad**.

El modelo debe concebirse, por tanto, como una capa adicional del sistema preventivo y no como sustituto del muestreo, el análisis, las buenas prácticas o el juicio toxicológico.

5.1. Las micotoxinas como problema biológico, estadístico y regulatorio

Las micotoxinas son metabolitos producidos por determinadas especies fúngicas capaces de contaminar cultivos y productos almacenados. Su presencia está condicionada por factores como temperatura, humedad, estrés de la planta, daños por insectos, prácticas agrícolas, secado y conservación. Muchas de ellas son relativamente estables y pueden persistir después del procesado.

Entre las micotoxinas de mayor relevancia para la alimentación animal se encuentran:

- aflatoxinas;
- deoxinivalenol;
- zearalenona;
- ocratoxina A;
- fumonisinas;
- toxinas T-2 y HT-2;
- alcaloides del cornezuelo;
- otras toxinas emergentes o modificadas.

No todas presentan la misma toxicidad, distribución, susceptibilidad por especie ni potencial de transferencia a productos de origen animal. Tampoco todas están sometidas al mismo tipo de valor regulatorio.

En la Unión Europea, la Directiva 2002/32/CE establece el marco para las sustancias indeseables en los productos destinados a la alimentación animal y fija contenidos máximos para diversas sustancias. La Recomendación 2006/576/CE establece valores orientativos para deoxinivalenol, zearalenona, ocratoxina A y fumonisinas, y fue posteriormente modificada para incorporar orientaciones relativas a T-2 y HT-2.

Esta diferencia entre límite máximo y valor orientativo no es meramente terminológica. Afecta a la naturaleza de la decisión, a la evaluación del riesgo y a las medidas de gestión. Un sistema automatizado no debería tratar todos los umbrales como reglas equivalentes de aceptación o rechazo.

5.2. La heterogeneidad de la contaminación

La distribución de micotoxinas en un lote puede ser extremadamente irregular. Un número reducido de granos o zonas contaminadas puede concentrar una parte sustancial de la carga total. Esta heterogeneidad explica por qué el error de muestreo puede superar al error analítico.

Puede expresarse:

$$E_{\text{total}} = E_{\text{muestreo}} + E_{\text{preparación}} + E_{\text{análisis}}$$

En numerosas situaciones, el primer término es el dominante.

Aumentar la sofisticación del método analítico sin mejorar la toma de muestra ofrece una seguridad engañosa. Un resultado con elevada precisión instrumental puede describir perfectamente una muestra que no representa el lote.

Las orientaciones técnicas de FAO subrayan que la precisión de la determinación de aflatoxinas mejora aumentando el tamaño y el número de muestras y submuestras, precisamente por la distribución heterogénea del peligro.

La IA puede ayudar a definir dónde y cuándo muestrear, pero no debe utilizarse para justificar una reducción indiscriminada de incrementos, masa o frecuencia.

5.3. Muestreo dirigido y muestreo aleatorio

Un sistema avanzado debería combinar dos estrategias.

Muestreo dirigido por riesgo

Prioriza:

- proveedores con historial desfavorable;
- orígenes asociados a campañas de riesgo;
- lotes con humedad elevada;
- materiales almacenados durante periodos prolongados;
- espectros o imágenes anómalas;
- condiciones climáticas favorables al desarrollo fúngico;
- ingredientes de elevada inclusión;
- materias primas destinadas a especies especialmente sensibles.

Muestreo basal aleatorio

Mantiene una proporción de controles no condicionados por el modelo.

Esta segunda capa es imprescindible. Si se analizan únicamente los lotes que el algoritmo considera sospechosos, el sistema deja de observar peligros nuevos, cambios epidemiológicos y patrones distintos de aquellos con los que fue entrenado.

El muestreo aleatorio cumple una función de vigilancia del propio modelo.

5.4. De la predicción climática a la alerta de campaña

Las condiciones meteorológicas y agronómicas influyen de forma decisiva sobre el desarrollo fúngico y la producción de toxinas. La temperatura y la humedad son variables fundamentales, y EFSA considera que el cambio climático puede modificar la presencia y distribución de micotoxinas en Europa. La institución ha impulsado modelos dirigidos a predecir el riesgo de aflatoxina B1 en cereales bajo diferentes escenarios climáticos.

Un modelo de alerta de campaña puede integrar:

- temperatura;
- precipitaciones;
- humedad del suelo;
- estrés hídrico;
- fase fenológica;
- daños por insectos;
- fecha de siembra y cosecha;
- variedad;
- prácticas de riego;
- antecedentes regionales.

La salida no debería interpretarse como concentración esperada exacta, sino como nivel de riesgo relativo:

$$P(\text{contaminación} > \tau \mid X)$$

donde:

- (X) representa las condiciones observadas;
- (τ) es un nivel de interés;
- (P) es la probabilidad estimada.

La utilidad principal reside en adaptar:

- compras;
- origen;
- frecuencia de muestreo;
- almacenamiento;
- segregación;
- cobertura contractual;
- análisis confirmatorios.

5.5. Cambio climático y pérdida de validez histórica

Los modelos entrenados con décadas anteriores pueden perder precisión si cambian las zonas de distribución de los hongos, la frecuencia de sequías, las temperaturas o los regímenes de lluvias.

Esta situación constituye una forma de deriva conceptual. Una región históricamente considerada de bajo riesgo puede dejar de serlo. Del mismo modo, la relación entre una variable climática y una toxina concreta puede cambiar si aparecen nuevas especies fúngicas, plagas o prácticas agronómicas.

Por ello, el origen geográfico nunca debe funcionar como etiqueta fija de seguridad. Debe actualizarse según campaña y condiciones reales.

El cambio climático añade además un problema regulatorio y asegurador: los eventos extremos pueden hacer que los patrones históricos de frecuencia de contaminación pierdan capacidad predictiva. La evaluación del riesgo deberá utilizar ventanas temporales móviles y reentrenamientos periódicos, no promedios invariables.

5.6. Modelos de predicción en almacenamiento

La contaminación no finaliza en la cosecha. Durante el almacenamiento pueden producirse crecimiento fúngico y generación adicional de toxinas cuando concurren:

- humedad elevada;
- actividad de agua suficiente;
- temperatura favorable;
- condensación;
- mala aireación;
- insectos;
- zonas de compactación;
- entrada de agua;
- tiempo prolongado.

Los silos pueden instrumentarse mediante sensores de temperatura, humedad, CO₂ y otros parámetros. La IA puede analizar la evolución espacial y temporal para detectar focos de calentamiento o fermentación.

La variable crítica no es solo el valor absoluto, sino la tendencia:

$$\Delta T/\Delta t, \quad \Delta H/\Delta t, \quad \Delta CO_2/\Delta t$$

Un incremento sostenido puede ser más informativo que una lectura aislada todavía situada dentro de límites generales.

El sistema debería generar alertas graduadas:

1. desviación leve;
2. tendencia persistente;
3. foco probable;
4. riesgo de deterioro;
5. necesidad de intervención inmediata.

5.7. Visión artificial e imagen hiperespectral

La imagen puede utilizarse para identificar:

- decoloraciones;
- granos rotos;
- daños por insectos;
- mohos visibles;
- impurezas;
- cuerpos extraños;

- patrones superficiales anómalos.

La imagen hiperespectral añade información espectral a cada zona de la muestra y puede identificar alteraciones no apreciables mediante visión convencional.

Su valor reside en analizar gran cantidad de unidades y captar heterogeneidad espacial. Sin embargo, no todas las toxinas producen una señal visible o espectral suficientemente específica. La presencia de hongo tampoco implica necesariamente presencia de toxina, y la ausencia visible de hongo no garantiza su inexistencia.

Por ello, estas tecnologías deben utilizarse como cribado y no como sustituto universal de métodos confirmatorios.

5.8. Espectroscopia y detección indirecta

Los modelos espectroscópicos pueden relacionar señales de la matriz con contaminación conocida. La dificultad es que la toxina puede encontrarse en concentraciones muy bajas respecto de la masa total y su señal directa quedar enmascarada.

En muchos casos, el modelo detecta alteraciones asociadas:

- crecimiento fúngico;
- daño del grano;
- cambios de composición;
- humedad;
- degradación.

Esto puede ser útil, pero debe describirse correctamente. Un modelo que identifica “lotes compatibles con contaminación” no equivale necesariamente a un método cuantitativo específico para una micotoxina.

La documentación debe indicar si el sistema:

- detecta la toxina directamente;
- detecta el hongo;
- detecta daño;
- clasifica riesgo;
- estima concentración.

Confundir estas funciones incrementa la probabilidad de decisiones incorrectas.

5.9. Narices electrónicas y compuestos volátiles

El crecimiento fúngico puede generar perfiles de compuestos orgánicos volátiles. Las narices electrónicas utilizan conjuntos de sensores para reconocer patrones de olor asociados a deterioro o contaminación.

La IA puede clasificar estos patrones y generar alertas rápidas en almacenamiento o recepción.

Las limitaciones incluyen:

- interferencias ambientales;
- humedad;

- temperatura;
- envejecimiento de sensores;
- variabilidad entre matrices;
- dificultad para identificar una toxina concreta;
- necesidad de recalibración.

Su utilidad principal se encuentra en la detección temprana de anomalías, no en la determinación jurídica definitiva de conformidad.

5.10. Métodos rápidos y métodos confirmatorios

Un sistema de vigilancia puede estructurarse en niveles:

Nivel 1. Predicción de riesgo

Datos climáticos, históricos, logísticos y de proveedor.

Nivel 2. Cribado rápido

NIRS, imagen, inmunoensayos, biosensores o métodos portátiles.

Nivel 3. Confirmación

Métodos analíticos validados, habitualmente cromatográficos y, cuando proceda, espectrométricos.

Nivel 4. Evaluación del riesgo y decisión

Interpretación por especie, edad, destino, concentración, duración de exposición y marco normativo.

La IA puede intervenir en todos los niveles, pero no debe borrar las diferencias de fuerza probatoria entre ellos.

5.11. El problema de los falsos negativos

En seguridad de piensos, los errores no tienen el mismo coste.

Supongamos:

- falso positivo: se bloquea un lote que era conforme;
- falso negativo: se acepta un lote peligroso.

El primer error genera coste económico, retraso y conflicto comercial. El segundo puede generar enfermedad, mortalidad, residuos, retirada de producto o transferencia a alimentos.

Por ello, el umbral de decisión no debería fijarse únicamente para maximizar la exactitud global:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Una métrica más relevante es la sensibilidad:

$$\text{Sensibilidad} = \frac{TP}{TP + FN}$$

También debe valorarse el valor predictivo negativo:

$$VPN = \frac{TN}{TN + FN}$$

En peligros graves, el modelo debe optimizarse para minimizar falsos negativos, aunque aumente el número de análisis confirmatorios.

5.12. Matriz de coste del error

La decisión puede formalizarse mediante una función:

$$C = c_{FP} \cdot FP + c_{FN} \cdot FN$$

donde normalmente:

$$c_{FN} \gg c_{FP}$$

Pero el coste del falso negativo varía según:

- toxina;
- concentración;
- especie;
- edad;
- tiempo de exposición;
- destino productivo;
- potencial de transferencia;
- tamaño del lote.

Un falso negativo de aflatoxina B1 en un pienso destinado a ganado lechero puede tener implicaciones adicionales por la posible presencia de metabolitos en leche. La evaluación no puede limitarse al rendimiento animal.

5.13. Especies y categorías sensibles

La susceptibilidad a las micotoxinas varía entre especies y etapas fisiológicas.

Pueden existir diferencias por:

- metabolismo;
- capacidad de detoxificación;
- microbiota;
- edad;
- estado inmunitario;
- nivel productivo;
- duración de exposición.

El modelo de decisión debe utilizar el destino exacto del pienso. No es suficiente conocer la concentración del lote; es necesario saber quién lo consumirá.

La fórmula de riesgo puede representarse como:

$$R = f(H, E, S, D, V)$$

donde:

- (H) es la peligrosidad de la toxina;
- (E) es la exposición;
- (S) es la especie;
- (D) es la duración;
- (V) es la vulnerabilidad.

5.14. Multimicotoxinas y efectos combinados

Las micotoxinas aparecen frecuentemente en mezclas. Las condiciones que favorecen una especie fúngica pueden coexistir con otras, y las materias primas pueden combinar diferentes perfiles de contaminación.

EFSA reconoce que las micotoxinas pueden presentarse en mezclas y que su interacción complica la evaluación del riesgo.

La evaluación individual puede infraestimar:

- efectos aditivos;
- sinergias;
- interacciones inmunológicas;
- alteraciones intestinales;
- efectos reproductivos.

Una suma simple de concentraciones tampoco es correcta porque las toxinas presentan potencias y mecanismos diferentes.

Una aproximación inicial puede utilizar cocientes de peligro:

$$HQ_i = \frac{E_i}{T_i}$$

y un índice acumulado:

$$HI = \sum_{i=1}^n HQ_i$$

donde:

- (E_i) es la exposición estimada;
- (T_i) es el valor de referencia.

Pero este modelo solo es apropiado cuando existe una base toxicológica razonable para agregar efectos. La IA no debe crear índices sintéticos opacos sin justificación mecanística.

5.15. Micotoxinas modificadas y enmascaradas

Las plantas, los hongos o los procesos pueden transformar micotoxinas en derivados conjugados o modificados. Algunos métodos dirigidos no detectan todas estas formas, aunque puedan reconvertirse o contribuir a la exposición.

EFSA ha evaluado específicamente los riesgos de formas modificadas de determinadas micotoxinas en alimentos y piensos.

Los conjuntos de datos históricos basados solo en formas parentales pueden infraestimar la carga total. Un modelo predictivo entrenado contra esos datos reproducirá esa limitación.

La tecnología no puede compensar aquello que el método analítico de referencia no ha observado.

5.16. Toxinas emergentes

Además de las micotoxinas reguladas o habitualmente monitorizadas, existen metabolitos emergentes cuya toxicidad, prevalencia o exposición todavía no están completamente caracterizadas.

La vigilancia algorítmica puede ayudar a identificar:

- patrones analíticos inusuales;
- aumentos regionales;
- asociaciones con signos clínicos;
- desviaciones productivas no explicadas.

Pero la ausencia de valores normativos no significa ausencia de riesgo. Tampoco permite a una empresa inventar automáticamente umbrales de seguridad.

Las decisiones deberán apoyarse en:

- literatura científica;
- evaluación veterinaria;
- organismos competentes;
- principio de precaución;
- análisis caso por caso.

5.17. Contaminantes más allá de las micotoxinas

La alimentación animal puede contener otros peligros químicos:

- metales y metaloides;
- dioxinas y PCB;
- plaguicidas;
- contaminantes de proceso;
- residuos;
- toxinas vegetales;
- impurezas botánicas;
- sustancias procedentes de materiales de envasado;
- contaminación ambiental.

La Directiva 2002/32/CE establece el marco europeo para distintas sustancias indeseables y prohíbe la dilución de productos no conformes con productos conformes para evitar los límites establecidos.

Esta prohibición tiene una importancia directa para los sistemas de optimización. Un algoritmo no puede sugerir mezclar un lote contaminado con otro limpio para obtener una concentración media inferior al máximo cuando la normativa prohíbe esa práctica.

La regla debe implementarse como restricción dura, no como preferencia.

5.18. Predicción de metales y contaminantes persistentes

Para metales, dioxinas o PCB, la predicción puede utilizar:

- origen geográfico;
- historial industrial de la zona;
- tipo de suelo;
- especie vegetal;
- procesos de secado;
- contaminación ambiental;
- proveedor;
- resultados precedentes.

Sin embargo, la relación entre estos factores y la concentración puede ser débil o cambiante. Los modelos sirven para priorizar, pero no para sustituir controles cuando el riesgo y la regulación exigen análisis.

Los contaminantes persistentes presentan además implicaciones acumulativas. Un lote individual con baja concentración puede contribuir a una exposición prolongada.

5.19. Plaguicidas

La presencia de residuos de plaguicidas depende de:

- cultivo;
- tratamientos;
- país;
- límites autorizados;
- degradación;
- almacenamiento;
- mezclas de materias primas.

Un sistema de IA puede cruzar:

- origen;
- historial;
- sustancias autorizadas;
- alertas;
- cultivo;
- campaña.

Su función más útil es seleccionar analitos y diseñar paneles dirigidos. Analizar siempre todos los residuos posibles resulta costoso; analizar solo lo esperado puede omitir usos irregulares o contaminaciones cruzadas.

Por ello, los planes deberían combinar paneles dirigidos y cribados amplios periódicos.

5.20. Alertas rápidas y fuentes externas

Los modelos pueden incorporar:

- alertas oficiales;
- notificaciones de proveedores;
- rechazos fronterizos;
- datos meteorológicos;
- información de cosecha;
- resultados internos;
- reclamaciones;
- incidencias veterinarias.

Pero una alerta externa no debe convertirse automáticamente en rechazo de todo un país o proveedor. Debe aumentar la vigilancia de forma proporcional.

Un sistema responsable diferencia:

- señal;
- evidencia;
- confirmación;
- decisión.

5.21. Riesgo de automatización reputacional

Las puntuaciones automáticas de riesgo pueden clasificar regiones o proveedores como peligrosos a partir de historiales incompletos.

Este enfoque puede introducir sesgos:

- mayor número de controles produce mayor número de detecciones;
- proveedores pequeños generan menos datos;
- ausencia de resultados no equivale a conformidad;
- una incidencia antigua puede seguir penalizando indefinidamente.

La puntuación debe incluir:

- volumen;
- frecuencia de control;
- gravedad;
- recencia;
- respuesta correctiva;
- incertidumbre.

El proveedor debe poder revisar datos erróneos.

5.22. Integración con APPCC

La IA no sustituye el análisis de peligros. Puede reforzarlo en:

- identificación de peligros emergentes;
- evaluación de probabilidad;
- selección de puntos de control;
- establecimiento de frecuencias;
- análisis de tendencias;
- verificación;
- revisión del plan.

Sin embargo, la categorización como PCC, punto de control o prerequisite operativo debe seguir una metodología técnica.

Una alerta algorítmica puede funcionar como:

- medida de vigilancia;
- indicador de tendencia;
- criterio de muestreo;
- desencadenante de confirmación.

No debe convertirse automáticamente en límite crítico salvo que exista justificación científica, validación y capacidad de medición suficientemente fiable.

5.23. Diferencia entre límite legal, límite interno y umbral algorítmico

Estos tres conceptos deben separarse:

Límite legal

Valor establecido normativamente.

Límite interno

Criterio corporativo más conservador, adaptado a especie, producto o cliente.

Umbral algorítmico

Punto a partir del cual el modelo genera una alerta o clasifica un lote.

El umbral algorítmico puede situarse antes del límite interno para aumentar sensibilidad. No debe presentarse como límite legal ni utilizarse sin documentación.

5.24. Acciones ante un resultado positivo

Un sistema de decisión debería distinguir:

1. resultado preliminar;
2. resultado confirmado;
3. superación de límite;
4. aproximación al límite;
5. mezcla de toxinas;
6. exposición acumulada;
7. presencia en especie sensible.

Las acciones pueden incluir:

- inmovilización;
- nueva toma de muestra;
- confirmación;
- segregación;
- cambio de destino permitido;
- devolución;
- destrucción;
- comunicación;
- investigación de causa;
- aumento de vigilancia.

La IA puede recomendar acciones, pero la decisión debe respetar el marco legal y estar autorizada por responsables competentes.

5.25. Uso de agentes reductores o secuestrantes

La gestión de micotoxinas incluye productos destinados a reducir su biodisponibilidad o efectos. No todos funcionan del mismo modo ni frente a todas las toxinas.

Pueden actuar mediante:

- adsorción;
- biotransformación;
- degradación enzimática;
- protección de órganos;
- soporte antioxidante.

El sistema de IA no debería recomendar automáticamente un producto por la mera detección de “micotoxinas”. Debe considerar:

- toxina;
- concentración;
- especie;
- dosis;
- evidencia;
- autorización;
- compatibilidad;
- eficacia demostrada.

Una solución que adsorbe aflatoxinas no puede presumirse eficaz frente a deoxinivalenol o zearalenona.

La adición de un producto mitigador tampoco convierte necesariamente un lote no conforme en conforme.

5.26. Señales productivas como indicadores secundarios

Las micotoxinas pueden provocar:

- reducción de consumo;
- menor crecimiento;

- peor conversión;
- inmunosupresión;
- problemas reproductivos;
- alteraciones digestivas;
- mayor susceptibilidad a enfermedad.

La IA puede detectar patrones compatibles con exposición. Pero estas señales son inespecíficas y suelen aparecer después de que el pienso haya sido consumido.

Los datos productivos deben utilizarse para:

- detectar incidentes;
- reforzar investigación;
- validar modelos;
- identificar exposiciones crónicas.

No deben sustituir el control preventivo.

5.27. Riesgo de causalidad espuria

Supongamos que un modelo encuentra asociación entre un proveedor y bajo rendimiento. La causa podría ser:

- micotoxinas;
- menor energía;
- daño térmico;
- granulometría;
- cambio de fórmula;
- explotación de destino;
- estación.

La asociación no demuestra que el proveedor sea la causa. Las decisiones comerciales graves requieren análisis causal y evidencia adicional.

La IA debe generar hipótesis, no sentencias.

5.28. Digital twin del riesgo de contaminación

Un gemelo digital puede representar el recorrido del lote desde el campo hasta el animal:

cultivo → cosecha → secado → almacenamiento → transporte → fábrica → granja

En cada etapa se actualiza la probabilidad de riesgo.

El valor potencial reside en simular escenarios:

- retraso de cosecha;
- humedad elevada;
- fallo de aireación;
- mezcla de lotes;
- incremento de temperatura;

- cambio de destino.

Pero el gemelo será tan fiable como los datos que lo alimentan. No debe convertirse en una representación visual sofisticada de supuestos no verificados.

5.29. Modelo de alerta explicable

Una alerta debería incluir:

- peligro;
- lote;
- probabilidad;
- principales variables;
- comparación histórica;
- incertidumbre;
- acción propuesta;
- responsable;
- plazo.

Ejemplo:

Riesgo elevado de deoxinivalenol. Factores principales: origen, precipitación durante floración, humedad de recepción y dos resultados históricos del proveedor. Recomendación: muestreo reforzado y análisis confirmatorio antes de liberación.

Esto es superior a una puntuación aislada de “87/100”.

5.30. Validación temporal y geográfica

Un modelo de micotoxinas debe validarse:

- en campañas distintas;
- en regiones diferentes;
- con proveedores no incluidos;
- en condiciones extremas;
- con lotes negativos y positivos;
- frente a métodos de referencia.

La separación aleatoria de muestras de una misma campaña puede sobreestimar el rendimiento, porque entrenamiento y prueba comparten clima, origen y patrones.

La validación real debe simular el futuro:

Entrenar con campañas anteriores y evaluar en una campaña posterior.

5.31. Trazabilidad probatoria

Toda decisión debe conservar:

- muestra;
- método;

- resultado;
- versión del modelo;
- variables utilizadas;
- alerta;
- responsable;
- acción;
- confirmación;
- destino final.

Esta trazabilidad permite reconstruir por qué se aceptó o rechazó un lote.

No basta con almacenar el resultado actual del modelo. Si el algoritmo cambia, debe conservarse la versión que operaba en el momento de la decisión.

5.32. Propuesta de flujo de decisión

Tabla 5. Síntesis de etapa, resultado y acción.

Etapa	Resultado	Acción
Evaluación previa	Riesgo bajo	Muestreo basal
Evaluación previa	Riesgo medio	Muestreo reforzado
Evaluación previa	Riesgo alto	Inmovilización preventiva y análisis
Cribado	Negativo con alta confianza	Liberación condicionada al plan
Cribado	Negativo con baja confianza	Confirmación
Cribado	Positivo	Inmovilización y confirmación
Confirmación	Conforme	Liberación documentada
Confirmación	Zona interna de precaución	Restricción de destino
Confirmación	No conforme	Gestión legal y contractual

5.33. Indicadores de desempeño del sistema

La empresa debe medir:

- tasa de detección;
- falsos negativos conocidos;
- falsos positivos;
- tiempo de respuesta;
- coste por hallazgo;
- porcentaje de lotes analizados;
- incidencias posteriores;
- precisión por proveedor;
- desempeño por campaña;
- alertas anuladas;
- causas de anulación.

Una reducción del número de análisis no constituye por sí sola un éxito. Puede significar eficiencia o pérdida de vigilancia.

5.34. Principio de precaución algorítmica

Cuando concurren:

- peligro grave;
- incertidumbre elevada;
- datos incompletos;
- especie vulnerable;
- dificultad de reversión;

la decisión debe inclinarse hacia:

- inmovilización;
- confirmación;
- revisión humana;
- restricción temporal.

La automatización debe ser más conservadora cuanto mayor sea la asimetría entre los costes del falso positivo y del falso negativo.

5.35. Conclusión: predecir no equivale a garantizar

La inteligencia artificial puede mejorar sustancialmente la vigilancia de micotoxinas y contaminantes. Permite integrar variables que antes se analizaban de forma separada, anticipar campañas problemáticas, detectar tendencias de almacenamiento, priorizar muestras y encontrar patrones difíciles de observar manualmente.

Pero no modifica la naturaleza del peligro. Las micotoxinas siguen siendo heterogéneas, las mezclas siguen planteando incertidumbre y los métodos rápidos siguen necesitando confirmación en decisiones críticas.

La función correcta de la IA es reducir incertidumbre, no ocultarla.

El sistema responsable no afirma:

Este lote es seguro porque el modelo no ha detectado riesgo.

Afirma:

Con los datos disponibles, el modelo estima este nivel de riesgo; se han aplicado este plan de muestreo, este método analítico, estas restricciones y esta revisión para fundamentar la decisión.

Esa diferencia separa un sistema preventivo de una automatización temeraria.

La seguridad algorítmica en alimentación animal no se mide por el número de alertas evitadas, sino por la capacidad de detectar a tiempo los peligros relevantes, explicar la decisión y conservar pruebas suficientes para defenderla.

6. Alimentación de precisión y adaptación en tiempo real: del animal medio a la decisión individual

La alimentación de precisión representa el punto en el que la formulación deja de ser exclusivamente una actividad previa a la fabricación y se convierte en un proceso continuo de observación, estimación, suministro y corrección. Su finalidad no consiste simplemente en producir dietas más complejas, sino en reducir la distancia entre los nutrientes aportados y las necesidades efectivas del animal durante un intervalo temporal determinado.

En los sistemas convencionales, las dietas se diseñan para grupos relativamente amplios definidos por especie, edad, peso, fase productiva o nivel de producción. La fórmula debe cubrir las necesidades de una proporción suficientemente elevada de la población, lo que inevitablemente conduce a que numerosos animales reciban determinados nutrientes por encima de sus requerimientos reales.

La alimentación multifase reduce parcialmente este desajuste al incrementar el número de dietas utilizadas durante el ciclo. La alimentación de precisión intenta avanzar un nivel adicional: aumentar la frecuencia de actualización y, cuando la identificación y el equipamiento lo permiten, adaptar la dieta al individuo.

Su lógica puede sintetizarse mediante la relación:

$$\text{Aporte nutricional}_{i,t} \approx \text{Necesidad estimada}_{i,t}$$

donde:

- (i) identifica al animal o unidad productiva;
- (t) representa el momento o periodo de decisión;
- la necesidad es una estimación, no una observación directa.

La palabra “estimada” es decisiva. Ningún sensor mide directamente las necesidades de lisina, energía metabolizable, proteína metabolizable o fósforo disponible de un animal en un momento concreto. El sistema las infiere a partir de variables observables como peso, crecimiento, ingestión, producción, estado fisiológico, temperatura o historial reciente.

Por ello, la alimentación de precisión debe considerarse un sistema de control biológico bajo incertidumbre, no una simple automatización de la distribución de pienso.

6.1. La cadena funcional de la alimentación de precisión

Un sistema completo requiere cinco funciones encadenadas:

1. Medición del estado actual.
2. Estimación de necesidades.
3. Selección de la dieta o mezcla.
4. Suministro físico.
5. Verificación de la respuesta.

Puede representarse como un bucle cerrado:

Animal → Sensores → Modelo → Decisión → Alimentador → Animal

La precisión global será inferior a la de su eslabón más débil. Un modelo nutricional avanzado no compensa una báscula defectuosa, una identificación errónea o una mezcladora incapaz de reproducir las proporciones ordenadas.

En consecuencia:

$$P_{\text{sistema}} \leq \min(P_{\text{medición}}, P_{\text{modelo}}, P_{\text{dosificación}}, P_{\text{identidad}})$$

La alimentación de precisión no es, por tanto, un algoritmo aislado. Es una infraestructura ciberfísica en la que software, sensores, animales, mecanismos de distribución y personas deben funcionar de manera coordinada.

6.2. De la alimentación por fases a la alimentación individual

En un programa convencional pueden utilizarse dos, tres o varias fases:

- iniciación;
- crecimiento;
- acabado;
- transición;
- lactación temprana;
- lactación media;
- lactación tardía.

Cada cambio de fase reduce el exceso medio de nutrientes respecto de una única dieta. Sin embargo, dentro de cada fase continúan coexistiendo animales con diferentes necesidades.

La alimentación individualizada puede utilizar dos dietas de base:

- una dieta de alta densidad;
- una dieta de baja densidad.

El sistema modifica diariamente la proporción entre ambas:

$$D_{i,t} \alpha_{i,t} D_{\text{alta}} + (1 - \alpha_{i,t}) D_{\text{baja}}$$

donde:

$$0 \leq \alpha_{i,t} \leq 1$$

El parámetro $(\alpha_{i,t})$ se calcula para aproximar el aporte al requerimiento estimado del animal.

Esta estrategia resulta industrialmente atractiva porque evita fabricar una fórmula distinta para cada individuo. La personalización se obtiene mediante mezcla variable de un número limitado de dietas.

6.3. Estimación diaria de necesidades

La necesidad nutricional individual puede descomponerse en mantenimiento y producción:

$$R_{i,t} R_{m,i,t} + R_{p,i,t}$$

En animales en crecimiento:

$$R_{p,i,t}f(\text{ganancia esperada, composición corporal, eficiencia})$$

En vacuno lechero:

$$R_{p,i,t}f(\text{producción de leche, grasa, proteína, estado fisiológico})$$

El modelo puede utilizar una ventana móvil de observaciones recientes:

$$X_{i,t-k:t}x_{i,t-k}, \dots, x_{i,t}$$

A partir de ella estima la trayectoria futura:

$$\hat{y}_{i,t+1}f(X_{i,t-k:t})$$

El sistema no debería reaccionar excesivamente a una única medición. Una caída puntual de peso o consumo puede deberse a ruido, error de lectura o variación diaria normal. Para evitar oscilaciones se utilizan medias móviles, filtros y límites a la velocidad de cambio.

6.4. Alimentación de precisión en porcino

El porcino constituye uno de los escenarios más desarrollados para la alimentación individual. El animal puede ser identificado en el comedero, pesado periódicamente y asociado a registros de consumo. El sistema estima su trayectoria de crecimiento y ajusta la concentración de nutrientes.

La lógica nutricional se basa en que los requerimientos relativos disminuyen progresivamente durante el crecimiento y difieren entre animales del mismo lote. Alimentar a todos con una dieta diseñada para cubrir a los individuos de mayor demanda implica un exceso para una parte importante del grupo.

La literatura sobre alimentación de precisión en porcino muestra que ajustar el aporte de aminoácidos con mayor frecuencia puede reducir su consumo y la excreción de nitrógeno sin perjudicar necesariamente el crecimiento, siempre que el modelo y el equipo funcionen adecuadamente. Las revisiones recientes destacan la integración progresiva de sensores, modelos matemáticos, algoritmos y equipos capaces de producir mezclas individualizadas.

El beneficio potencial puede adoptar varias formas:

- menor consumo de aminoácidos;
- menor proteína bruta;
- reducción de nitrógeno excretado;
- menor coste;
- mejora de uniformidad;
- identificación temprana de animales desviados.

Un sistema de apoyo a la decisión evaluado en condiciones comerciales en 2026 utilizó datos de crecimiento e ingestión para adaptar estrategias de alimentación y observó mejoras especialmente relevantes en los animales inicialmente más pequeños, reduciendo el riesgo de que individuos con alto potencial quedaran nutricionalmente limitados.

Este resultado introduce una precisión importante: la alimentación de precisión no beneficia únicamente a la eficiencia media. También puede utilizarse para gestionar la dispersión del lote.

6.5. Uniformidad y valor económico del lote

En muchos sistemas de producción, el valor económico no depende solo del peso medio, sino de la distribución de pesos.

Una elevada variabilidad puede producir:

- más animales fuera del rango comercial;
- mayor número de días de ocupación;
- sacrificios escalonados;
- menor utilización de instalaciones;
- penalizaciones;
- costes logísticos adicionales.

La función objetivo puede incorporar:

$$\text{Minimizar } \sigma_W^2$$

donde (σ_W^2) representa la varianza de peso final.

Pero reducir la dispersión no significa alimentar automáticamente más a todos los animales pequeños. Algunos pueden ser pequeños por enfermedad, genética, competencia o problemas de ingestión. Aumentar la densidad nutricional sin identificar la causa puede ser ineficiente o contraproducente.

El sistema debería distinguir:

- animal pequeño con elevado potencial;
- animal pequeño con consumo insuficiente;
- animal enfermo;
- animal con mala eficiencia;
- error de identificación o pesaje.

Esta clasificación requiere integrar datos nutricionales, sanitarios y conductuales.

6.6. Alimentación de precisión en vacuno lechero

En vacuno lechero, el principio de personalización se aplica con frecuencia a la suplementación individual de concentrado sobre una ración parcialmente mezclada o una ración base común.

La asignación puede considerar:

- producción de leche;
- composición de leche;
- días en lactación;
- número de parto;
- condición corporal;
- peso;
- consumo estimado;

- respuesta histórica al suplemento.

La creciente automatización de las explotaciones permite ensayar estrategias en las que la respuesta anterior de cada vaca ayuda a predecir qué suplemento o cantidad puede ser más favorable. Un estudio publicado en 2025 evaluó respuestas productivas a modificaciones de suplementación de corta duración y comparó estrategias de precisión basadas en el rendimiento individual previo.

Otros trabajos han utilizado modelos de aprendizaje automático combinados con optimización para proponer asignaciones individuales de concentrado. En un estudio de 2025, un modelo de bosque aleatorio y un procedimiento de optimización determinaron cantidades individualizadas dentro del rango estudiado y se observó un incremento de producción a escala de rebaño; no obstante, los propios resultados deben interpretarse dentro de las condiciones y relaciones observadas en esa explotación.

La principal dificultad es separar asociación de respuesta causal. Una vaca de alta producción recibe normalmente más concentrado. Un modelo retrospectivo podría concluir que aumentar el concentrado eleva siempre la producción, cuando parte de la asociación existe porque la asignación ya respondía al rendimiento.

Para estimar la respuesta marginal real se necesitan:

- diseños experimentales;
- cambios controlados;
- modelos causales;
- comparación contrafactual;
- control de variables de confusión.

6.7. La ingestión individual en vacuno

La ingestión de materia seca es una variable central y, al mismo tiempo, difícil de medir de forma rutinaria en explotaciones comerciales.

La producción de leche puede medirse por vaca, pero la ración mezclada suele ofrecerse al grupo. Esto crea una asimetría: se conoce la producción individual, pero no con igual precisión el consumo individual.

Se han desarrollado sistemas de visión artificial para estimar la ingestión de cada vaca a partir de imágenes y comportamiento en el pesebre. Un trabajo publicado en 2022 describió un sistema de visión en tiempo real adaptable a distintos tipos de alimento para predecir consumo individual.

La utilidad de estas herramientas depende de:

- identificación correcta del animal;
- visibilidad de la zona;
- solapamiento entre animales;
- cambios de iluminación;
- desplazamiento del alimento;
- capacidad para reconocer diferentes raciones;
- validación frente a consumo realmente medido.

El modelo no debería tratar la ingestión estimada por cámara como equivalente a una medición directa sin conservar su intervalo de error.

6.8. Ración parcialmente mezclada y concentrado individual

Una arquitectura frecuente combina:

- ración base disponible para el grupo;
- suplemento individual administrado en robot, estación o sala de ordeño.

El aporte total será:

$$N_{i,t}N_{\text{base},i,t} + N_{\text{sup},i,t}$$

El problema es que la ingestión de la ración base puede variar entre individuos. Si se desconoce, la suplementación se calcula sobre una estimación.

Una vaca que consume menos ración base de la prevista puede recibir una cantidad de concentrado aparentemente correcta y seguir en déficit. Otra con ingestión elevada puede quedar sobrealimentada.

La precisión exige mejorar la estimación del primer término, no solo automatizar el segundo.

6.9. Respuesta marginal decreciente

La relación entre suplemento y producción no es indefinidamente lineal. Puede existir una respuesta marginal decreciente:

$$\frac{\partial Y}{\partial S} > 0$$

pero:

$$\frac{\partial^2 Y}{\partial S^2} < 0$$

donde:

- (Y) es la producción;
- (S) es el suplemento.

En niveles altos, una unidad adicional de concentrado puede producir una respuesta muy reducida o desplazar consumo de forraje.

La decisión económicamente óptima no coincide necesariamente con la producción máxima:

$$\max[P_Y \cdot Y(S) - P_S \cdot S]$$

donde:

- (P_Y) es el valor del producto;
- (P_S) es el coste del suplemento.

El modelo debe optimizar margen y no solo rendimiento.

6.10. Alimentación de precisión en avicultura

En producción avícola, la individualización presenta dificultades por el gran número de animales y la alimentación colectiva. Las estrategias pueden actuar a diferentes escalas:

- nave;
- sección;
- corral;
- sexo;
- curva de crecimiento;
- periodo del día;
- individuo, en sistemas experimentales.

La alimentación de precisión puede apoyarse en:

- cámaras para estimar peso;
- consumo de pienso y agua;
- distribución espacial;
- temperatura;
- actividad;
- uniformidad;
- evolución del lote.

La revisión conceptual de precisión alimentaria en ganadería señala que la finalidad es suministrar la cantidad y composición adecuadas al animal correcto y en el momento oportuno, pero reconoce que la integración entre modelos animales y maquinaria inteligente todavía requiere desarrollo.

En avicultura pueden utilizarse mezclas secuenciales o cambios más frecuentes en la concentración de aminoácidos y energía. También puede adaptarse la dieta a:

- ritmo de crecimiento;
- condiciones térmicas;
- sexo;
- objetivo de canal;
- ingestión real.

La escala colectiva obliga a trabajar con distribuciones. El sistema debe decidir qué percentil de necesidad pretende cubrir y qué nivel de variabilidad es aceptable.

6.11. Alimentación secuencial y temporal

La precisión no se refiere únicamente a la composición media diaria. Puede incluir el momento de suministro.

La demanda de nutrientes y el comportamiento de ingestión varían durante el día. En aves ponedoras, por ejemplo, la necesidad y utilización de calcio están relacionadas con el ciclo de formación de la cáscara. En rumiantes, la distribución temporal de carbohidratos y nitrógeno puede influir en la sincronización ruminal.

Una estrategia temporal puede utilizar:

$$D_t = f(\text{hora, fase fisiológica, actividad, temperatura})$$

Sin embargo, aumentar la complejidad horaria puede producir:

- competencia;
- selección;
- alteración del comportamiento;
- errores de suministro;
- mayor dependencia tecnológica.

La mejora teórica debe validarse en condiciones reales.

6.12. Pequeños rumiantes

La ganadería ovina y caprina presenta desafíos adicionales:

- sistemas extensivos;
- conectividad limitada;
- pastoreo;
- dificultad de medir ingestión;
- heterogeneidad de recursos;
- menor margen económico por animal.

Las tecnologías de precisión pueden utilizar identificación electrónica, básculas, collares, acelerómetros y sistemas de ordeño. Las revisiones recientes muestran un crecimiento de estas aplicaciones, aunque su implantación práctica sigue siendo desigual y depende especialmente del coste, la robustez y la adaptación a sistemas extensivos.

En animales en pastoreo, la formulación de precisión debe estimar primero la cantidad y calidad del forraje realmente ingerido. Esta variable presenta gran incertidumbre.

La suplementación individual puede resultar útil en:

- lactación;
- gestación;
- animales de alta producción;
- recuperación de condición corporal;
- fases críticas.

Pero el modelo debe evitar trasladar directamente ecuaciones desarrolladas en estabulación intensiva a condiciones extensivas.

6.13. Acuicultura

La acuicultura ofrece un escenario especialmente relevante para la alimentación automatizada porque el pienso representa una proporción importante del coste y el desperdicio tiene impacto económico y ambiental directo.

Los sistemas pueden integrar:

- cámaras;
- hidroacústica;
- sensores de oxígeno;

- temperatura;
- comportamiento;
- velocidad de consumo;
- pellets no ingeridos;
- biomasa estimada.

La decisión debe determinar:

- cantidad;
- frecuencia;
- velocidad;
- punto de distribución;
- interrupción.

Puede expresarse:

$$F_t = f(B_t, T_t, O_t, A_t, R_t)$$

donde:

- (B_t) es biomasa;
- (T_t) temperatura;
- (O_t) oxígeno;
- (A_t) actividad;
- (R_t) respuesta alimentaria.

El riesgo principal es que el sistema confunda una reducción de respuesta con saciedad cuando puede deberse a hipoxia, enfermedad o estrés.

6.14. El agua como variable nutricional

La alimentación de precisión suele centrarse en el pienso, pero el agua es el nutriente de mayor consumo.

Los sistemas deberían integrar:

- consumo;
- caudal;
- presión;
- temperatura;
- calidad;
- relación agua:pienso;
- patrones horarios.

Una reducción de agua puede preceder a la reducción de pienso. También puede indicar:

- fallo de suministro;
- obstrucción;
- enfermedad;
- alteración ambiental.

La relación:

$$\frac{\text{agua}}{\text{pienso}}$$

puede ser más informativa que cualquiera de los dos valores por separado.

Un algoritmo que incremente la densidad nutricional por caída de consumo sin detectar un problema de agua actuará sobre la variable equivocada.

6.15. Estrés térmico y adaptación dinámica

La temperatura modifica la ingestión, el mantenimiento y el metabolismo. En situaciones de calor, el animal puede reducir el consumo para limitar la producción de calor metabólico.

La respuesta nutricional no debería ser una regla universal. Puede incluir:

- aumento de densidad energética;
- modificación de proteína;
- ajuste de aminoácidos;
- electrolitos;
- cambio de horarios;
- mayor frecuencia de suministro;
- control de agua.

Pero las necesidades dependen de especie, intensidad, duración y adaptación.

Un sistema avanzado puede integrar el índice temperatura-humedad y variables individuales:

$$D_{i,t} f \left(THIt, consumo_i, t, producción_{i,t} \right)$$

La adaptación automática debe limitarse porque una caída de consumo durante calor intenso puede coexistir con alteraciones sanitarias que requieren intervención distinta.

6.16. Alimentación y salud

La disminución de consumo es una señal temprana de numerosas patologías. En un sistema de precisión, el mismo dato puede desencadenar dos interpretaciones:

- ajuste nutricional;
- alerta sanitaria.

La secuencia segura debería ser:

1. detectar la desviación;
2. verificar sensor y suministro;
3. revisar agua y ambiente;
4. evaluar señales sanitarias;
5. decidir si procede ajuste nutricional.

No debería aplicarse automáticamente una dieta más concentrada ante cualquier reducción de ingestión.

La salud actúa como variable de exclusión. Cuando el patrón sea compatible con enfermedad, el sistema debe transferir la decisión al circuito veterinario.

6.17. El problema del animal enfermo en modelos productivos

Los modelos suelen optimizar crecimiento, producción o conversión. Un animal enfermo puede recibir recomendaciones inadecuadas porque su comportamiento se aleja del patrón de entrenamiento.

El modelo debería contar con un estado:

$$z_{i,t} \in \text{normal, sospechoso, enfermo, recuperación}$$

La estrategia nutricional dependerá de ese estado.

Un sistema sin esta diferenciación puede intentar “corregir” mediante alimento una desviación causada por enfermedad y retrasar el diagnóstico.

6.18. Control en bucle abierto y cerrado

Bucle abierto

El sistema calcula una dieta y la aplica durante un periodo sin utilizar continuamente la respuesta observada.

Bucle cerrado

El sistema mide la respuesta y actualiza la decisión.

El bucle cerrado parece superior, pero puede volverse inestable cuando responde demasiado rápido al ruido.

Ejemplo:

1. el consumo disminuye ligeramente;
2. el sistema aumenta densidad;
3. cambia palatabilidad;
4. disminuye más el consumo;
5. el sistema vuelve a ajustar.

Esto genera oscilaciones.

La estabilidad requiere:

- límites de cambio;
- ventanas mínimas;
- filtros;
- zonas muertas;
- revisión humana;
- reglas de bloqueo.

6.19. Frecuencia óptima de actualización

Una mayor frecuencia no siempre produce mayor precisión.

Actualizar cada minuto puede ser absurdo para variables fisiológicas que cambian lentamente. Actualizar una vez al mes puede ser insuficiente para animales de crecimiento rápido.

La frecuencia debe adaptarse a:

- velocidad del fenómeno;
- calidad de la medición;
- capacidad del equipo;
- riesgo de sobrecorrección;
- coste.

Puede establecerse:

Tabla 6. Síntesis de variable y frecuencia orientativa.

Variable	Frecuencia orientativa
Consumo y agua	Continua o diaria
Peso	Diaria o periódica
Producción de leche	Por ordeño o diaria
Composición de leche	Por ordeño, diaria o periódica
Fórmula individual	Diaria o por ventana
Matriz de ingredientes	Por lote
Parámetros metabólicos	Periódica
Revisión del modelo	Mensual, trimestral o por deriva

La frecuencia real debe validarse para cada sistema.

6.20. Exactitud de dosificación

Una recomendación con diferencias pequeñas carece de valor si el equipo no puede reproducirlas.

Si el sistema ordena:

$$\alpha = 0,473$$

pero el alimentador tiene una tolerancia amplia, la mezcla efectiva puede diferir significativamente.

La capacidad física debe evaluarse mediante:

- exactitud;
- repetibilidad;
- homogeneidad;
- tiempo de respuesta;
- residuo;

- contaminación cruzada;
- tamaño mínimo de dosis;
- comportamiento con diferentes densidades.

La precisión algorítmica debe expresarse dentro de la resolución real del equipo.

6.21. Calibración de comederos y básculas

Los equipos requieren:

- calibración inicial;
- verificación periódica;
- control con pesos o volúmenes conocidos;
- mantenimiento;
- registro de incidencias.

Una deriva lenta puede pasar inadvertida porque el sistema sigue produciendo datos plausibles.

Puede utilizarse una regla de balance:

$$\text{Inventario inicial} + \text{entradas} - \text{inventario final} \approx \sum \text{consumos registrados} + \text{mermas}$$

Las discrepancias sostenidas indican errores de medición, pérdidas o asignación incorrecta.

6.22. Fallos físicos y modo degradado

El sistema debe prever:

- fallo de identificación;
- pérdida de conexión;
- sensor averiado;
- atasco;
- silo vacío;
- error de mezcla;
- corte eléctrico;
- caída del servidor.

Ante el fallo, debe existir una dieta segura por defecto.

Puede definirse:

$$D_{\text{fallback}} \text{dieta convencional validada}$$

El paso al modo degradado debe ser automático cuando no se cumplan las condiciones mínimas de datos.

La alternativa nunca debería ser mantener indefinidamente la última orden si las circunstancias pueden haber cambiado.

6.23. Límites de seguridad

El sistema debe incluir restricciones sobre:

- concentración mínima;
- concentración máxima;
- variación diaria máxima;
- cantidad máxima por visita;
- intervalo mínimo entre suministros;
- consumo acumulado;
- máximos legales;
- incompatibilidades.

Ejemplo:

$$|\alpha_{i,t} - \alpha_{i,t-1}| \leq \delta$$

donde (δ) limita cambios abruptos.

También pueden aplicarse reglas:

- no reducir más de un porcentaje por día;
- no modificar durante una alerta sanitaria;
- no actuar con identificación incompleta;
- no utilizar un ingrediente fuera de dominio;
- bloquear fórmulas no liberadas.

6.24. Función de abstención

La IA debe poder abstenerse de decidir.

La salida puede ser:

$$\hat{y} = \begin{cases} f(X), & \text{si confianza} \geq c \\ \text{revisión humana}, & \text{si confianza} < c \end{cases}$$

La abstención procede cuando:

- faltan datos;
- existen contradicciones;
- el animal está fuera del rango;
- aparece una enfermedad;
- el equipo presenta errores;
- la incertidumbre es elevada.

Un sistema que fuerza una recomendación en todas las situaciones no es autónomo: es incapaz de reconocer sus límites.

6.25. Aprendizaje por refuerzo

El aprendizaje por refuerzo puede plantearse como una secuencia de decisiones en la que el sistema recibe una recompensa asociada a la respuesta.

Estado:

$$s_t$$

Acción:

$$a_t$$

Recompensa:

$$r_t$$

El algoritmo intenta maximizar:

$$\sum_{t=0}^T \gamma^t r_t$$

En alimentación animal, la recompensa podría combinar:

- producción;
- coste;
- salud;
- emisiones;
- uniformidad.

El problema es que experimentar directamente con animales puede generar decisiones nutricionales inadecuadas. La exploración libre, habitual en ciertos entornos de aprendizaje por refuerzo, no resulta aceptable cuando puede afectar al bienestar o la seguridad.

Antes de una aplicación real se requieren:

- simulación;
- límites duros;
- datos históricos;
- validación;
- supervisión;
- espacios de acción restringidos.

El algoritmo no debe “aprender” probando dosis potencialmente inseguras.

6.26. Gemelos digitales

Un gemelo digital intenta reproducir el estado y evolución de un animal, lote o explotación.

Puede integrar:

- crecimiento;
- metabolismo;
- consumo;
- ambiente;
- salud;
- dieta;
- producción.

El gemelo permite simular:

- cambio de fórmula;
- variación de precio;
- estrés térmico;
- reducción de proteína;
- distinta estrategia de fases.

Pero no debe confundirse con una réplica exacta. Es un modelo actualizado con datos.

Su utilidad depende de la capacidad para cuantificar la diferencia entre predicción y realidad:

$$e_t = y_t - \hat{y}_t$$

El error debe monitorizarse. Un gemelo que se actualiza visualmente pero no registra su desempeño es una interfaz, no una herramienta científica validada.

6.27. Objetivos múltiples

La alimentación de precisión puede optimizar simultáneamente:

$$J = w_1C + w_2N + w_3P + w_4E + w_5W$$

donde:

- (C): coste;
- (N): excreción de nitrógeno;
- (P): desviación productiva;
- (E): emisiones;
- (W): indicador de bienestar;
- (w_i): ponderaciones.

El riesgo aparece cuando las ponderaciones son decididas sin transparencia. Un pequeño cambio puede priorizar ahorro sobre robustez o producción sobre bienestar.

Los objetivos de seguridad y bienestar no deberían incluirse como simples términos compensables. Determinados límites deben funcionar como restricciones duras.

6.28. Sostenibilidad y reducción de nutrientes excedentarios

Una de las ventajas mejor fundamentadas de la alimentación de precisión es la posibilidad de reducir nutrientes suministrados por encima de las necesidades.

El nitrógeno no retenido se excreta. Reducir el desajuste puede disminuir la carga ambiental sin perjudicar la producción. La literatura reciente sigue señalando la precisión alimentaria como herramienta relevante para mejorar la eficiencia de uso de nutrientes y reducir la excreción, especialmente en porcino, aves y vacuno lechero.

No obstante, el beneficio ambiental debe evaluarse considerando:

- energía del equipamiento;
- fabricación de dietas múltiples;
- sensores;

- infraestructura;
- composición de ingredientes;
- transporte;
- respuesta productiva real.

La sostenibilidad no puede deducirse únicamente de una reducción teórica de proteína.

6.29. Coste económico total

La inversión puede incluir:

- equipos de alimentación;
- identificación;
- básculas;
- sensores;
- software;
- integración;
- mantenimiento;
- comunicaciones;
- formación;
- calibración;
- soporte.

El retorno depende de:

$$ROI = \frac{\text{beneficios} - \text{costes}}{\text{costes}}$$

Los beneficios pueden proceder de:

- ahorro de pienso;
- menor uso de aminoácidos;
- mejora productiva;
- menor variabilidad;
- reducción de bajas;
- liberación de capacidad;
- menor excreción.

Las revisiones económicas sobre tecnologías ganaderas digitales muestran beneficios potenciales, pero también una gran dependencia de escala, coste de adquisición, interoperabilidad y capacidad de convertir los datos en decisiones operativas.

6.30. Pequeñas explotaciones y brecha tecnológica

Los sistemas de alimentación individual pueden ser más accesibles para explotaciones grandes con:

- alto número de animales;
- personal especializado;
- conectividad;
- capacidad de inversión.

Esto puede ampliar la brecha entre modelos productivos.

Una implantación proporcional puede utilizar:

- ajustes por lote;
- básculas compartidas;
- sensores ambientales básicos;
- análisis periódico;
- software de apoyo;
- servicios externos.

La precisión no exige necesariamente individualización completa. Puede mejorar progresivamente:

rebaño → grupo → subgrupo → individuo

6.31. Bienestar animal

La personalización puede beneficiar al bienestar si:

- evita deficiencias;
- detecta cambios de consumo;
- identifica animales rezagados;
- reduce competencia;
- facilita intervención temprana.

Pero también puede generar riesgos:

- restricción excesiva;
- competencia por estaciones;
- condicionamiento conductual;
- acceso desigual;
- errores de identificación;
- retraso de atención humana.

Una dieta matemáticamente óptima no es aceptable si el sistema de acceso provoca frustración o exclusión.

La evaluación debe observar:

- tiempo de espera;
- visitas rechazadas;
- agresiones;
- animales sin acceso;
- patrones anómalos;
- adaptación.

6.32. Supervisión humana efectiva

La persona responsable debe poder conocer:

- qué datos se utilizaron;

- qué necesidad se estimó;
- qué cambio se propuso;
- qué restricciones estaban activas;
- cuál era la confianza;
- cómo respondió el animal.

La interfaz debe destacar excepciones, no inundar de información.

La supervisión efectiva exige:

- autoridad para intervenir;
- formación;
- alertas priorizadas;
- trazabilidad;
- carga de trabajo razonable.

Una aprobación automática por fatiga de alertas no constituye verdadero control humano.

6.33. Validación experimental y comercial

Un sistema debe validarse en varias etapas:

Validación técnica

¿Mide y dosifica correctamente?

Validación nutricional

¿La recomendación cubre necesidades?

Validación productiva

¿Mantiene o mejora resultados?

Validación sanitaria

¿No incrementa incidencias?

Validación económica

¿Genera retorno?

Validación operacional

¿Funciona con fallos, suciedad, humedad y variabilidad real?

La validación experimental en condiciones controladas no basta. Las revisiones de inteligencia artificial en ganadería de precisión siguen identificando la integración de sistemas, la calidad de los datos, la validación externa y la escalabilidad como obstáculos centrales para la adopción.

6.34. Diseño de ensayo

Una evaluación sólida debería comparar:

- estrategia convencional;
- multifase;
- precisión por grupo;
- precisión individual.

Los resultados deberían incluir:

- consumo;
- crecimiento o producción;
- conversión;
- mortalidad;
- morbilidad;
- uniformidad;
- excreción;
- coste;
- fallos del equipo;
- horas de trabajo.

La unidad estadística debe definirse correctamente. Cuando animales comparten comedero o tratamiento, no siempre pueden tratarse como observaciones totalmente independientes.

6.35. Indicadores de desempeño

Tabla 7. Síntesis de dimensión y indicador.

Dimensión	Indicador
Nutrición	Diferencia entre aporte y necesidad estimada
Producción	Ganancia, leche, huevos o biomasa
Eficiencia	Conversión o eficiencia residual
Uniformidad	Coefficiente de variación
Ambiente	Nitrógeno y fósforo excretados
Economía	Margen sobre alimentación
Equipo	Error de dosificación
Datos	Porcentaje de lecturas válidas
Salud	Incidencias y mortalidad
Bienestar	Acceso, competencia y comportamiento

6.36. Alarmas críticas

El sistema debería alertar cuando:

- consumo cae de forma abrupta;
- agua y pienso divergen;

- peso cambia de forma imposible;
- dosificación no coincide con orden;
- animal no accede;
- fórmula supera límites;
- sensor queda fuera de calibración;
- modelo pierde precisión;
- existe alerta sanitaria;
- se activa el modo degradado.

Las alarmas deben clasificarse:

- informativa;
- advertencia;
- crítica;
- bloqueo.

No toda desviación debe detener el sistema, pero las condiciones de bloqueo deben estar definidas antes de la implantación.

6.37. Registro de la decisión

Para cada ajuste deberían conservarse:

- animal o grupo;
- fecha;
- datos de entrada;
- versión del modelo;
- necesidad estimada;
- fórmula o mezcla ordenada;
- cantidad suministrada;
- desviaciones;
- alertas;
- intervención humana;
- respuesta posterior.

Este registro permite diferenciar entre:

- recomendación incorrecta;
- ejecución incorrecta;
- respuesta biológica inesperada.

6.38. La alimentación de precisión como sistema adaptativo, no como reducción automática

Existe el riesgo de presentar la alimentación de precisión exclusivamente como estrategia para reducir proteína, aminoácidos o coste.

Su finalidad real es ajustar.

Cuando el modelo detecte una necesidad superior, deberá aumentar el aporte. Cuando la ingestión disminuya, puede ser necesario elevar la concentración. Cuando el animal se recupere, puede requerir una transición gradual.

Por tanto:

precisión $\neq$ restricción

La reducción de excedentes es una consecuencia posible, no la definición del sistema.

6.39. Principios de diseño seguro

Un sistema de alimentación de precisión debería cumplir:

1. Identidad fiable.
2. Datos suficientes y actualizados.
3. Modelo validado en la población de destino.
4. Restricciones nutricionales no negociables.
5. Dosificación verificable.
6. Modo seguro ante fallos.
7. Capacidad de abstención.
8. Supervisión humana real.
9. Trazabilidad completa.
10. Revisión continua del desempeño.

6.40. Conclusión: alimentar al animal real sin convertirlo en un dato abstracto

La alimentación de precisión ofrece una oportunidad de enorme relevancia: dejar de formular únicamente para un animal promedio y aproximar el aporte a las necesidades de animales, grupos y momentos concretos.

Puede mejorar la eficiencia, reducir nutrientes excedentarios, disminuir excreciones y gestionar mejor la variabilidad. Las investigaciones y revisiones publicadas entre 2025 y 2026 muestran avances en porcino, vacuno, ovino y sistemas de monitorización, pero también confirman que la integración plena entre datos en tiempo real, predicción individual y suministro automatizado todavía no está completamente resuelta en todos los sectores.

El mayor error sería interpretar la individualización como una licencia para reducir márgenes hasta desaparecer. La variabilidad biológica no se elimina porque el animal lleve un identificador y el comedero esté conectado.

La precisión responsable no consiste en suministrar exactamente el valor calculado, sino en mantener al animal dentro de una zona nutricional segura y eficiente, incorporando la incertidumbre del modelo, del sensor, del equipo y de la respuesta biológica.

El objetivo final no debe ser que el algoritmo controle al animal, sino que el sistema productivo comprenda antes sus necesidades, detecte sus desviaciones y responda de forma más proporcionada, explicable y segura.

7. Microbiota, salud intestinal e inteligencia artificial: de la correlación ómica a la intervención nutricional plena y validada

La salud intestinal se ha convertido en uno de los conceptos más utilizados y, al mismo tiempo, más imprecisos de la nutrición animal contemporánea. En torno a ella convergen digestión, absorción, integridad epitelial, inmunidad, microbiota, inflamación, resistencia a patógenos, eficiencia alimentaria y respuesta al estrés. Esta amplitud explica su relevancia, pero también facilita que productos, modelos o biomarcadores heterogéneos se presenten bajo una misma denominación sin demostrar necesariamente el mecanismo o el beneficio declarado.

La inteligencia artificial puede contribuir a ordenar esta complejidad. Los algoritmos permiten integrar datos microbiológicos, metabolómicos, transcriptómicos, inmunológicos, nutricionales, productivos y ambientales. Pueden identificar patrones, clasificar animales, predecir respuestas o seleccionar combinaciones de ingredientes y aditivos. Sin embargo, el volumen de variables no elimina las dificultades fundamentales de la inferencia biológica.

La presencia de una determinada bacteria puede asociarse con mayor crecimiento sin ser la causa de ese crecimiento. Una dieta puede modificar simultáneamente el microbioma, la digestibilidad y el consumo, haciendo difícil determinar qué cambio produjo la mejora. Del mismo modo, dos animales con perfiles taxonómicos diferentes pueden conservar funciones metabólicas semejantes debido a la redundancia funcional de las comunidades microbianas.

Por ello, la aplicación de IA a la salud intestinal requiere distinguir cuidadosamente entre:

- descripción de la comunidad;
- predicción de un fenotipo;
- identificación de un mecanismo;
- demostración de causalidad;
- recomendación de una intervención.

La capacidad para predecir no implica necesariamente capacidad para intervenir con éxito.

7.1. El intestino como ecosistema funcional

El tracto gastrointestinal no es únicamente un conducto para la digestión. Constituye un ecosistema en el que interactúan:

- células del hospedador;
- microorganismos;
- nutrientes;
- metabolitos;
- secreciones;
- mucina;
- células inmunitarias;
- compuestos bioactivos;
- patógenos y oportunistas.

La microbiota participa en la fermentación de sustratos, producción de metabolitos, desarrollo inmunitario, exclusión competitiva y mantenimiento de la barrera intestinal. Las publicaciones recientes

continúan situando la microbiota como un componente central de la relación entre nutrición, metabolismo, inmunidad y eficiencia productiva en animales de granja.

Pero el ecosistema no es estático. Está condicionado por:

- especie;
- genética;
- edad;
- parto;
- ambiente;
- dieta;
- tratamiento;
- estrés;
- antibióticos;
- patógenos;
- instalación;
- manejo;
- procedencia.

La comparación entre animales requiere controlar estas variables. De lo contrario, el algoritmo puede atribuir a la dieta diferencias que en realidad proceden de la edad, el alojamiento o la explotación.

7.2. Microbiota y microbioma

Aunque ambos términos se utilizan a menudo como equivalentes, conviene diferenciarlos.

Microbiota

Conjunto de microorganismos presentes en un entorno.

Microbioma

Conjunto de microorganismos, material genético, funciones, metabolitos e interacciones asociados a ese ecosistema.

Esta distinción es importante porque una clasificación taxonómica describe quién parece estar presente, mientras que una aproximación funcional intenta determinar qué capacidades metabólicas existen y cuáles se expresan.

La nutrición animal necesita avanzar desde la pregunta:

¿Qué microorganismos aparecen?

hacia preguntas más útiles:

¿Qué funciones realizan, qué metabolitos producen, cómo responden a la dieta y qué consecuencias tienen para el animal?

7.3. El problema de “microbiota sana”

No existe una composición universal que defina una microbiota sana para todas las especies, edades, sistemas y dietas.

Una comunidad adecuada para:

- un lechón recién destetado;
- una cerda gestante;
- una gallina ponedora;
- un pollo de crecimiento rápido;
- una vaca en transición;
- un pez carnívoro;

no tiene por qué compartir la misma estructura.

Incluso dentro de una especie, la salud puede coexistir con diferentes configuraciones microbianas. Por ello, conceptos como “equilibrio”, “diversidad” o “eubiosis” deben utilizarse con prudencia.

Una mayor diversidad no siempre es beneficiosa. En determinadas etapas tempranas, una comunidad menos diversa puede ser fisiológicamente normal. Del mismo modo, una mayor diversidad puede incluir microorganismos indeseables.

La interpretación debe vincular la comunidad con:

- función;
- estabilidad;
- resistencia;
- producción de metabolitos;
- integridad intestinal;
- ausencia de enfermedad;
- desempeño productivo.

7.4. Disbiosis: concepto útil, diagnóstico difícil

La disbiosis se utiliza para describir una alteración desfavorable de la comunidad microbiana. Pero rara vez existe un umbral único y validado.

Puede manifestarse mediante:

- pérdida de microorganismos beneficiosos;
- expansión de oportunistas;
- reducción de funciones protectoras;
- aumento de metabolitos perjudiciales;
- pérdida de estabilidad;
- alteración de la barrera.

El riesgo aparece cuando cualquier diferencia respecto de un grupo control se etiqueta como disbiosis.

Un algoritmo puede clasificar una muestra como “disbiótica” porque se aleja de su conjunto de entrenamiento, pero esa distancia puede reflejar:

- dieta distinta;
- genética;
- edad;
- instalación;
- tratamiento;
- método de laboratorio.

Por ello, la clasificación debe estar asociada a un desenlace clínico o funcional claramente definido.

7.5. Niveles de análisis ómico

La caracterización del ecosistema puede abordarse mediante distintas capas:

Tabla 8. Síntesis de capa y pregunta principal.

Capa	Pregunta principal
Metagenómica	¿Qué genes y microorganismos están presentes?
Metatranscriptómica	¿Qué genes se expresan?
Metaproteómica	¿Qué proteínas se producen?
Metabolómica	¿Qué metabolitos aparecen?
Transcriptómica del hospedador	¿Cómo responde el animal?
Epigenómica	¿Qué modificaciones regulatorias se producen?
Inmunómica	¿Qué respuesta inmunitaria se activa?

La integración de estas capas promete una representación más completa, pero también multiplica:

- dimensionalidad;
- coste;
- dificultad estadística;
- variabilidad técnica;
- riesgo de hallazgos espurios.

La investigación reciente en nutrición animal está incorporando metabolómica y enfoques multi-ómicos para relacionar dieta, respuesta fisiológica y productividad, especialmente en avicultura y otros sistemas intensivos.

7.6. El problema “p pequeño, variables grandes”

En estudios de microbioma es frecuente disponer de:

- pocos animales;
- miles de taxones;
- decenas de miles de genes;
- numerosos metabolitos.

Esto puede expresarse como:

$$p \gg n$$

donde:

- (p) es el número de variables;
- (n) es el número de observaciones.

Esta estructura favorece el sobreajuste. Un modelo puede separar perfectamente los grupos experimentales y fracasar al aplicarse a otra granja.

Además, muchos datos microbiológicos son:

- composicionales;
- dispersos;
- con abundancia de ceros;
- no independientes;
- sensibles al procesamiento bioinformático.

La IA no elimina estas propiedades estadísticas. Debe diseñarse específicamente para ellas.

7.7. Datos composicionales

Los resultados de secuenciación suelen expresarse como abundancias relativas:

$$\sum_{j=1}^p x_j = 1$$

Si aumenta la proporción de un microorganismo, la proporción de otros debe disminuir, aunque su cantidad absoluta no haya cambiado.

Esto puede crear asociaciones artificiales.

Por ejemplo, una bacteria puede parecer reducida porque otra creció de manera intensa. Sin cuantificación absoluta, no puede saberse si realmente disminuyó.

Los modelos deberían considerar:

- transformaciones logarítmicas apropiadas;
- ratios;
- cuantificación absoluta;
- carga microbiana total;
- métodos específicos para datos composicionales.

Aplicar algoritmos convencionales directamente sobre porcentajes puede generar interpretaciones erróneas.

7.8. Ceros biológicos y ceros técnicos

La ausencia de lectura puede significar:

- microorganismo realmente ausente;
- presencia por debajo del límite;

- fallo de extracción;
- profundidad insuficiente;
- sesgo de cebadores;
- error de clasificación.

Los modelos deben diferenciar, en la medida de lo posible, entre ausencia real y no detección.

La sustitución automática de todos los ceros por un valor pequeño puede ser necesaria para ciertos análisis, pero modifica la estructura del conjunto y debe documentarse.

7.9. Variabilidad preanalítica

Antes de entrenar un modelo existen múltiples fuentes de variación:

- tipo de muestra;
- lugar anatómico;
- momento de recogida;
- tiempo desde la alimentación;
- conservación;
- temperatura;
- extracción;
- kit;
- cebadores;
- plataforma;
- profundidad;
- base taxonómica;
- tubería bioinformática.

Una muestra fecal no representa exactamente la microbiota adherida a la mucosa ni la comunidad de segmentos intestinales proximales. En rumiantes, una muestra de líquido ruminal puede diferir de la fracción sólida o de la comunidad asociada al epitelio.

Las revisiones recientes sobre estandarización en porcino muestran que la mayor parte de los estudios sigue utilizando secuenciación de 16S, mientras una proporción mucho menor emplea metagenómica completa; esta heterogeneidad metodológica limita la comparación directa.

7.10. 16S frente a metagenómica *shotgun*

Secuenciación 16S

Ventajas:

- menor coste;
- alto rendimiento;
- amplia disponibilidad;
- útil para descripción taxonómica.

Limitaciones:

- resolución limitada;
- sesgo de cebadores;

- inferencia funcional indirecta;
- dificultad para especies próximas;
- escasa información sobre virus y hongos.

Metagenómica shotgun

Ventajas:

- mayor resolución;
- análisis de genes;
- potencial funcional;
- detección más amplia.

Limitaciones:

- mayor coste;
- complejidad computacional;
- necesidad de bases de datos;
- contaminación con ADN del hospedador;
- dificultad de interpretación funcional.

La elección debe depender de la pregunta. Utilizar metagenómica avanzada no compensa un diseño experimental débil.

7.11. *Machine learning* para clasificar salud intestinal

Un modelo puede intentar distinguir:

- animales sanos y enfermos;
- alta y baja eficiencia;
- buena y mala conversión;
- respuesta y no respuesta a un aditivo;
- diferentes dietas;
- distintos niveles de inflamación.

La función puede expresarse:

$$\hat{y} = f(M, H, D, E)$$

donde:

- (M): microbioma;
- (H): variables del hospedador;
- (D): dieta;
- (E): ambiente.

La inclusión de dieta y ambiente es esencial. Un modelo basado únicamente en microbiota puede aprender diferencias de alimentación en lugar de diferencias sanitarias.

7.12. Predicción de eficiencia alimentaria

La microbiota ruminal influye en la degradación de nutrientes, la producción de ácidos grasos volátiles y la generación de metano. Por ello, se han utilizado técnicas de aprendizaje automático para explorar su capacidad predictiva respecto de eficiencia alimentaria y producción.

Un estudio publicado en 2024 aplicó ingeniería de variables y métodos de conjunto para evaluar la contribución del microbioma ruminal a la predicción de eficiencia alimentaria y producción lechera. El trabajo mostró que la información microbiana puede aportar señal predictiva, aunque su utilidad depende del fenotipo, del tratamiento de los datos y de la validación del modelo.

La existencia de señal predictiva no demuestra que modificar los taxones seleccionados produzca automáticamente una mejora de eficiencia.

7.13. Predicción no es mecanismo

Supongamos que un modelo identifica tres microorganismos asociados a mejor conversión.

Pueden existir varias explicaciones:

1. contribuyen causalmente a la eficiencia;
2. proliferan porque la dieta es más digestible;
3. reflejan menor inflamación;
4. son marcadores de otro microorganismo;
5. aparecen por una variable no registrada;
6. la asociación es accidental.

Para avanzar desde la predicción hacia el mecanismo se necesitan:

- estudios longitudinales;
- intervención dietética;
- transferencia microbiana;
- cultivo;
- metabolitos;
- pruebas funcionales;
- validación externa.

La selección de variables por un algoritmo es una herramienta de priorización, no una prueba causal.

7.14. Modelos longitudinales

El microbioma cambia con el tiempo. Una muestra aislada no permite conocer:

- estabilidad;
- dirección;
- velocidad;
- recuperación;
- respuesta transitoria.

Los modelos longitudinales pueden analizar:

$$M_{i,t} = f(M_{i,t-1}, D_{i,t}, H_{i,t}, E_t)$$

La variación respecto de la línea basal individual puede ser más útil que la comparación con una media poblacional.

Un animal puede presentar una comunidad diferente del promedio pero estable y funcional. Una alteración brusca respecto de su propio patrón puede tener mayor relevancia.

7.15. Ventanas críticas

Existen etapas en las que la microbiota es especialmente susceptible a modificación:

- nacimiento;
- destete;
- cambios de dieta;
- entrada en cebo;
- transición periparto;
- tratamiento antibiótico;
- traslado;
- estrés térmico.

La intervención puede tener efectos distintos según el momento. Un probiótico administrado después de consolidarse la comunidad puede responder de manera diferente al mismo producto utilizado durante una fase temprana.

Los modelos deberían incluir:

- edad;
- tiempo desde el evento;
- dieta previa;
- tratamientos;
- historial microbiano.

7.16. Destete

El destete representa una perturbación intensa en porcino y otras especies por la combinación de:

- separación;
- cambio alimentario;
- estrés;
- modificación ambiental;
- inmadurez digestiva;
- exposición a patógenos.

La IA puede integrar consumo, crecimiento, heces, temperatura, microbiota, metabolitos e inflamación para identificar animales con mayor riesgo.

Pero el sistema no debería reducir la salud intestinal a una firma microbiana. El riesgo puede depender de:

- calidad de ingredientes;

- proteína no digerida;
- estructura física;
- higiene;
- densidad;
- agua;
- manejo;
- inmunidad maternal.

La microbiota es una parte del sistema.

7.17. Rumen y fermentación

En rumiantes, la microbiota ruminal convierte materiales fibrosos en metabolitos aprovechables por el hospedador.

Las funciones centrales incluyen:

- degradación de fibra;
- fermentación de carbohidratos;
- metabolismo de nitrógeno;
- producción de ácidos grasos volátiles;
- síntesis microbiana;
- biohidrogenación;
- metanogénesis.

El modelo nutricional puede incorporar información microbiana para predecir:

- digestibilidad;
- eficiencia;
- riesgo de acidosis;
- metano;
- respuesta a aditivos.

Pero el rumen es un ecosistema con redundancia funcional. Diferentes comunidades pueden producir resultados metabólicos semejantes.

Por ello, el análisis funcional y metabolómico puede ser más útil que una simple lista taxonómica.

7.18. Metabolitos como puente causal

Los metabolitos permiten aproximarse al efecto funcional.

Pueden incluir:

- ácidos grasos volátiles;
- lactato;
- aminas;
- indoles;
- fenoles;
- ácidos biliares;
- compuestos derivados del triptófano;

- productos de fermentación proteica.

Una asociación entre microorganismo y salud resulta más plausible cuando se demuestra una cadena coherente:

dieta → microorganismo → metabolito → respuesta del hospedador

La IA puede integrar estas capas y seleccionar rutas relevantes. Aun así, la plausibilidad no sustituye la intervención experimental.

7.19. Salud intestinal y marcadores del hospedador

La evaluación debe incluir, cuando sea posible:

- morfología intestinal;
- permeabilidad;
- proteínas de unión estrecha;
- mucinas;
- citocinas;
- inmunoglobulinas;
- estrés oxidativo;
- lesiones;
- digestibilidad;
- consistencia fecal;
- rendimiento.

Un producto puede modificar la microbiota sin mejorar ninguna variable del hospedador. Esa modificación no debe presentarse automáticamente como beneficio.

7.20. Índices compuestos de salud intestinal

Puede construirse un índice:

$$I = w_1B + w_2M + w_3I + w_4P + w_5F$$

donde:

- (B): barrera;
- (M): microbiota;
- (I): inflamación;
- (P): producción;
- (F): función digestiva.

El peligro reside en que las ponderaciones oculten compensaciones. Una mejora productiva podría contrarrestar matemáticamente un empeoramiento inflamatorio.

Los componentes críticos deben conservarse por separado. El índice puede servir como resumen, no como única evidencia.

7.21. Probióticos

Los probióticos son microorganismos vivos que, administrados adecuadamente, pretenden producir un beneficio.

Su eficacia depende de:

- cepa;
- dosis;
- viabilidad;
- matriz;
- estabilidad;
- especie;
- edad;
- dieta;
- ambiente;
- estado sanitario.

No puede extrapolarse automáticamente un efecto de una especie microbiana a otra cepa.

La IA puede ayudar a:

- seleccionar candidatos;
- analizar genomas;
- predecir funciones;
- estudiar compatibilidad;
- segmentar respondedores;
- optimizar combinaciones.

Pero la predicción genómica de una función no garantiza que se exprese en el animal.

7.22. Prebióticos

Los prebióticos son sustratos destinados a ser utilizados selectivamente por microorganismos y producir un beneficio.

En nutrición animal se investigan:

- oligosacáridos;
- fibras;
- polisacáridos;
- coproductos;
- fracciones vegetales.

La respuesta depende de la microbiota inicial. Un sustrato puede beneficiar a unos animales y no a otros.

La investigación reciente ha destacado el interés de residuos agroindustriales como fuentes de compuestos prebióticos, aunque su composición, fermentabilidad y seguridad deben caracterizarse antes de asumir equivalencia funcional.

La IA puede predecir qué comunidad utilizará un sustrato, pero necesita datos funcionales y no solo taxonómicos.

7.23. Sinbióticos

Los sinbióticos combinan microorganismos y sustratos.

Su lógica es que el sustrato favorezca:

- la cepa administrada;
- microorganismos complementarios;
- una función determinada.

El número de combinaciones posibles es muy elevado. La IA puede reducir el espacio experimental mediante:

- predicción metabólica;
- redes de interacción;
- cribado in silico;
- optimización multiobjetivo.

Sin embargo, las interacciones reales pueden cambiar en el intestino respecto de un cultivo o simulación.

7.24. Postbióticos y productos de fermentación

Los postbióticos y productos de fermentación contienen células inactivadas, componentes celulares o metabolitos.

Presentan ventajas potenciales de:

- estabilidad;
- seguridad;
- procesabilidad;
- menor dependencia de viabilidad.

Los productos bioactivos, incluidos postbióticos, fitogénicos y materiales fermentados, están recibiendo una atención creciente como herramientas para apoyar digestibilidad, salud intestinal y sostenibilidad. La evidencia, no obstante, es heterogénea y debe evaluarse por producto, composición y condición de uso.

La IA puede caracterizar perfiles químicos complejos, pero un producto no definido dificulta la reproducibilidad.

7.25. Fitogénicos

Los fitogénicos pueden contener múltiples moléculas:

- aceites esenciales;
- polifenoles;
- terpenos;
- alcaloides;
- extractos.

Su composición varía según:

- especie vegetal;
- origen;
- cosecha;
- extracción;
- almacenamiento;
- estandarización.

Los modelos pueden relacionar perfiles químicos con:

- actividad antimicrobiana;
- inflamación;
- digestibilidad;
- respuesta productiva.

Pero la actividad in vitro no se traduce necesariamente al animal debido a:

- absorción;
- metabolismo;
- dosis;
- interacción con el pienso;
- palatabilidad.

7.26. Enzimas

Las enzimas exógenas actúan sobre sustratos específicos.

La IA puede apoyar:

- predicción de respuesta;
- selección de enzima;
- ajuste de dosis;
- diseño de cócteles;
- evaluación de matriz;
- estabilidad térmica.

Las variables relevantes incluyen:

- concentración de sustrato;
- accesibilidad;
- pH;
- temperatura;
- tiempo;
- procesado;
- microbiota;
- especie.

Una enzima no produce el mismo valor de matriz en todas las dietas. El sistema debería modelar la respuesta como función del sustrato real.

7.27. Ácidos orgánicos y acidificantes

Los acidificantes pueden influir en:

- pH;
- conservación;
- microbiología;
- digestión;
- barrera.

La respuesta depende de:

- tipo de ácido;
- forma libre o protegida;
- capacidad tampón;
- dosis;
- sitio de liberación;
- dieta.

Un modelo puede predecir combinación y dosis, pero debe diferenciar entre:

- acción en pienso;
- acción gástrica;
- acción intestinal;
- efecto antimicrobiano;
- efecto metabólico.

7.28. Bacteriófagos, péptidos y soluciones dirigidas

Las tecnologías más específicas incluyen:

- bacteriófagos;
- péptidos antimicrobianos;
- enzimas líticas;
- bacteriocinas;
- microorganismos diseñados.

La IA puede utilizarse para descubrir:

- secuencias;
- receptores;
- rango de hospedador;
- resistencia;
- estabilidad.

Pero la especificidad crea nuevos desafíos:

- evolución;
- resistencia;
- transferencia;
- impacto ecológico;

- persistencia.

Una intervención dirigida no debe validarse únicamente por la reducción del microorganismo objetivo. Debe evaluarse el efecto global sobre el ecosistema.

7.29. Selección algorítmica de aditivos

Una plataforma puede intentar recomendar el aditivo óptimo según:

- especie;
- edad;
- dieta;
- patógeno;
- microbiota;
- clima;
- coste;
- objetivo.

Puede expresarse:

$$a^* = \operatorname{argmax}_a U(a|X)$$

donde (U) representa la utilidad esperada.

Pero el conjunto de datos suele proceder de ensayos heterogéneos en:

- dosis;
- duración;
- condiciones;
- variables;
- productos;
- calidad metodológica.

Una IA entrenada con literatura no depurada puede confundir productos que comparten una categoría comercial pero no una composición equivalente.

7.30. Meta-análisis asistido por IA

La IA puede ayudar a:

- localizar estudios;
- extraer variables;
- clasificar diseños;
- estimar efectos;
- identificar heterogeneidad;
- construir modelos de respuesta.

Pero la automatización de la revisión no sustituye la valoración crítica.

Deben distinguirse:

- estudios aleatorizados;
- ensayos comerciales;
- estudios in vitro;
- modelos animales;
- estudios observacionales;
- comunicaciones comerciales.

El efecto medio no debe aplicarse sin valorar la población de destino.

7.31. Respuesta heterogénea

Un aditivo puede mostrar efecto medio modesto y beneficio importante en un subgrupo.

El modelo puede identificar respondedores según:

- microbiota basal;
- genética;
- dieta;
- edad;
- nivel sanitario;
- ambiente.

Esta aproximación puede transformar la nutrición funcional:

$$P(\text{respuesta}|X)$$

en lugar de asumir una respuesta universal.

Pero la segmentación posterior al estudio puede producir hallazgos accidentales. Los subgrupos deben validarse prospectivamente.

7.32. Biomarcadores predictivos

Un biomarcador útil debe cumplir:

- asociación reproducible;
- medición fiable;
- relación temporal;
- capacidad predictiva;
- utilidad decisional;
- validación externa.

No basta con que una bacteria presente una diferencia estadísticamente significativa.

La pregunta práctica es:

¿La medición cambia una decisión y mejora el resultado?

Si el biomarcador es costoso, lento o inestable, puede carecer de utilidad comercial.

7.33. Causalidad y diseños de intervención

Para demostrar que una modificación microbiana causa un efecto pueden utilizarse:

- dietas controladas;
- inoculación;
- trasplante;
- gnotobiosis;
- antibióticos;
- metabolitos;
- bloqueo de rutas;
- series temporales.

En producción animal, muchos diseños son difíciles o costosos. Por ello, la evidencia debe construirse progresivamente:

1. asociación;
2. temporalidad;
3. plausibilidad;
4. intervención;
5. reproducción;
6. validación comercial.

La IA puede acelerar las etapas, pero no eliminarlas.

7.34. Redes microbianas

Los microorganismos interactúan mediante:

- competencia;
- cooperación;
- intercambio de metabolitos;
- inhibición;
- dependencia.

Los modelos de redes intentan identificar nodos clave.

Sin embargo, una correlación entre dos microorganismos no demuestra interacción directa. Ambos pueden responder al mismo nutriente.

Las redes deben interpretarse como hipótesis ecológicas.

7.35. Modelos metabólicos

Los modelos metabólicos basados en genomas pueden simular:

- utilización de sustratos;
- producción de metabolitos;
- competencia;
- intercambio.

La IA puede ayudar a construir, completar y seleccionar estos modelos. Los avances en aprendizaje profundo y modelos de lenguaje aplicados a secuencias microbianas están ampliando la anotación funcional y el descubrimiento de genes y rutas, aunque siguen existiendo problemas de interpretabilidad, datos de referencia y validación.

La simulación es especialmente valiosa para reducir combinaciones experimentales, pero debe contrastarse con resultados reales.

7.36. Predicción de metano

En rumiantes, la modulación microbiana puede utilizarse para reducir metano.

Los modelos pueden integrar:

- dieta;
- microbioma;
- producción;
- consumo;
- aditivos;
- emisiones.

Un estudio de 2025 validó un modelo de IA destinado a predecir el efecto de aditivos mitigadores sobre el metano entérico en vacuno lechero, ilustrando la capacidad de combinar múltiples variables para estimar respuesta.

No obstante, una reducción de metano debe evaluarse junto con:

- consumo;
- digestibilidad;
- leche;
- salud;
- persistencia;
- coste;
- posibles residuos.

7.37. Resistencia antimicrobiana

La nutrición funcional se presenta con frecuencia como herramienta para reducir antimicrobianos.

Los aditivos pueden contribuir mediante:

- barrera;
- competencia;
- reducción de patógenos;
- inmunomodulación;
- mejora digestiva.

Pero no deben presentarse como sustitutos universales del tratamiento veterinario.

La IA puede apoyar:

- vigilancia de genes de resistencia;
- predicción de riesgo;
- selección de intervenciones;
- análisis de brotes.

El resistoma debe evaluarse con cautela. La presencia de un gen no demuestra expresión, transferencia ni riesgo clínico inmediato.

7.38. Seguridad de cepas

La selección de microorganismos debe evaluar:

- identidad;
- virulencia;
- resistencia;
- genes transferibles;
- producción de toxinas;
- estabilidad genética.

La IA puede acelerar el análisis genómico, pero la clasificación depende de:

- bases de datos;
- anotación;
- umbrales;
- conocimiento disponible.

La ausencia de un gen conocido no garantiza ausencia de riesgo desconocido.

7.39. Del laboratorio a la fábrica

La eficacia de un aditivo puede perderse durante:

- granulación;
- extrusión;
- almacenamiento;
- mezcla;
- oxidación;
- humedad.

El modelo de selección debe incluir estabilidad tecnológica.

Para probióticos:

$\text{dosis efectiva} = \text{dosis añadida} \times \text{supervivencia}$

Para enzimas o compuestos bioactivos, debe considerarse actividad residual.

La formulación basada en la dosis nominal puede sobreestimar el aporte real.

7.40. Palatabilidad y consumo

Un aditivo puede mejorar indicadores intestinales y reducir consumo por sabor u olor.

El valor final depende de la respuesta integrada:

beneficiof (eficacia biológica, ingestión, estabilidad, coste)

La IA debe incluir datos de palatabilidad y no limitarse a biomarcadores.

7.41. Interacciones entre aditivos

Las combinaciones pueden ser:

- aditivas;
- sinérgicas;
- antagonistas;
- redundantes.

Una enzima puede liberar sustratos para determinados microorganismos. Un ácido puede reducir la viabilidad de una cepa. Un adsorbente puede fijar compuestos bioactivos.

La optimización combinatoria es un campo adecuado para IA, pero requiere diseños experimentales eficientes.

7.42. Diseño experimental adaptativo

Los algoritmos pueden seleccionar la siguiente combinación a ensayar según resultados anteriores.

Un enfoque bayesiano puede equilibrar:

- explotación de combinaciones prometedoras;
- exploración de combinaciones inciertas.

Pero el espacio debe restringirse por seguridad, regulación y plausibilidad.

El algoritmo no debe probar combinaciones sin límites biológicos.

7.43. Desarrollo de nuevos aditivos

La IA puede participar en:

- selección de cepas;
- búsqueda de moléculas;
- predicción de estabilidad;
- formulación;
- dosis;
- segmento de destino.

La secuencia responsable es:

1. descubrimiento;
2. caracterización;
3. seguridad;
4. mecanismo;
5. prueba in vitro;
6. prueba in vivo;
7. validación comercial;
8. vigilancia poscomercial.

La predicción acorta etapas de selección, no sustituye la evidencia requerida.

7.44. Claims y lenguaje comercial

Existe una distancia frecuente entre:

- modulación del microbioma;
- mejora de salud intestinal;
- mejora de inmunidad;
- prevención de enfermedad.

Estos efectos no son equivalentes.

Un producto que modifica abundancias relativas no ha demostrado necesariamente mejorar salud. Un producto que reduce un patógeno in vitro no ha demostrado prevenir una enfermedad en granja.

La IA generativa puede aumentar el riesgo de extrapolación comercial si transforma resultados preliminares en afirmaciones contundentes.

La revisión científico-regulatoria debe comprobar:

- población;
- dosis;
- producto;
- variable;
- significación;
- relevancia;
- reproducibilidad.

7.45. Modelos explicables

La explicabilidad es especialmente importante cuando el sistema recomienda un aditivo o clasifica riesgo intestinal.

La salida debería indicar:

- variables principales;
- dirección del efecto;
- incertidumbre;
- población de referencia;
- evidencia disponible;
- límites.

Pero técnicas como SHAP explican cómo el modelo utilizó una variable, no por qué esa variable causa el resultado.

La explicación algorítmica no es explicación biológica.

7.46. Validación externa

Un modelo microbiológico debería evaluarse en:

- otra granja;
- otra campaña;
- otra dieta;
- otra genética;
- otro laboratorio;
- otro sistema de secuenciación.

Si la precisión cae, debe determinarse si el problema es:

- deriva biológica;
- variación técnica;
- sobreajuste;
- cambio de población.

La portabilidad es uno de los mayores obstáculos para convertir biomarcadores ómicos en herramientas comerciales.

7.47. Validación prospectiva

La prueba más relevante consiste en usar el modelo para decidir antes de conocer el resultado.

Ejemplo:

1. se toma muestra basal;
2. el modelo predice respuesta;
3. se asigna intervención;
4. se mide el resultado;
5. se compara con la predicción.

Los análisis retrospectivos pueden sobreestimar el valor.

7.48. Coste y proporcionalidad

Las técnicas multi-ómicas pueden ser útiles en:

- investigación;
- selección de biomarcadores;
- validación;
- animales de alto valor.

Pero pueden resultar poco viables para uso rutinario masivo.

Una estrategia escalonada sería:

1. ómicas para descubrir;
2. panel reducido para validar;
3. biomarcador económico para operar.

La IA debe ayudar a reducir complejidad y no crear dependencia permanente de mediciones costosas.

7.49. Biomarcadores indirectos de uso comercial

En lugar de secuenciar continuamente, pueden utilizarse:

- consumo;
- agua;
- heces;
- gases;
- temperatura;
- metabolitos;
- marcadores inflamatorios;
- visión.

El modelo relaciona estas señales con estados intestinales previamente caracterizados.

El resultado será una predicción indirecta y debe describirse como tal.

7.50. Integración con nutrición de precisión

La salud intestinal puede incorporarse a la formulación como una restricción o estado.

Por ejemplo:

$$D_{i,t}f(R_{i,t}, G_{i,t})$$

donde:

- ($R_{i,t}$): necesidades productivas;
- ($G_{i,t}$): estado gastrointestinal.

Un animal con riesgo intestinal puede necesitar:

- menor proteína fermentable;
- cambio de fibra;
- transición;
- aditivo;
- ajuste de partícula;
- revisión veterinaria.

La recomendación debe ser multidisciplinar.

7.51. Estado de confianza

El sistema podría clasificar:

Tabla 9. Síntesis de estado, evidencia y acción.

Estado	Evidencia	Acción
Normal	Señales estables	Mantener
Desviación leve	Cambio no específico	Vigilar
Riesgo probable	Varias señales concordantes	Ajuste prudente
Riesgo alto	Evidencia consistente	Revisión técnica
Enfermedad posible	Signos clínicos o caída grave	Intervención veterinaria
Datos insuficientes	Información incompleta	No automatizar

7.52. Trazabilidad del dato ómico

Cada análisis debería conservar:

- muestra;
- segmento;
- momento;
- conservación;
- extracción;
- plataforma;
- secuencia;
- pipeline;
- base de datos;
- versión;
- filtros;
- modelo;
- resultado.

Una misma secuencia puede clasificarse de forma diferente al actualizar la base de datos. Por ello, debe conservarse la versión utilizada.

7.53. Gobernanza de biobancos

Los biobancos de muestras permiten reanalizar:

- ADN;
- ARN;
- metabolitos;
- tejidos;
- contenido intestinal.

Deben definirse:

- identidad;
- condiciones;

- finalidad;
- conservación;
- acceso;
- destrucción;
- asociación con datos.

Sin una trazabilidad adecuada, la muestra pierde valor científico.

7.54. Riesgo de reidentificación empresarial

Aunque los datos no sean personales, los perfiles productivos y microbiológicos pueden identificar:

- granja;
- proveedor;
- dieta;
- incidencia sanitaria;
- tecnología.

El intercambio de datos entre empresas debe proteger información comercial sensible.

7.55. Función correcta de la IA generativa

Los modelos generativos pueden ayudar a:

- revisar literatura;
- resumir resultados;
- generar hipótesis;
- estructurar protocolos;
- redactar documentación.

No deberían utilizarse para:

- inventar mecanismos;
- extrapolar dosis;
- afirmar eficacia;
- sustituir revisión bibliográfica;
- recomendar tratamientos sin validación.

La plausibilidad textual puede ocultar falta de evidencia.

7.56. Criterios para seleccionar un modelo microbiológico

La empresa debería preguntar:

1. ¿Qué desenlace predice?
2. ¿Qué tipo de muestra necesita?
3. ¿En qué población se entrenó?
4. ¿Qué tamaño tuvo el conjunto?
5. ¿Cómo se controló la dieta?
6. ¿Existe validación externa?
7. ¿Cuál es el error?

8. ¿Qué ocurre con datos nuevos?
9. ¿Cambia una decisión?
10. ¿Se ha demostrado beneficio?

7.57. Cuadro de riesgos

Tabla 10. Síntesis de riesgo, ejemplo, consecuencia y control.

Riesgo	Ejemplo	Consecuencia	Control
Sobreajuste	Miles de taxones, pocos animales	Precisión irreal	Validación externa
Confusión	Dieta y granja cambian juntas	Causalidad falsa	Diseño equilibrado
Composicionalidad	Aumento relativo	Interpretación errónea	Métodos específicos
Variabilidad técnica	Cambio de kit	Deriva artificial	Estandarización
Claim excesivo	Cambio microbiano	Beneficio no demostrado	Revisión científica
Extrapolación	Cepa diferente	Eficacia falsa	Evidencia por cepa
Inestabilidad	Pérdida en granulación	Dosis insuficiente	Control de actividad
Interacción	Adsorbente y aditivo	Pérdida de efecto	Ensayo combinado
Causalidad espuria	Taxón asociado	Intervención ineficaz	Validación mecánica
Datos insuficientes	Muestra aislada	Clasificación insegura	Seguimiento longitudinal

7.58. Arquitectura de decisión para salud intestinal

Una plataforma madura podría integrar:

Capa de observación

- consumo;
- agua;
- heces;
- producción;
- ambiente;
- clínica.

Capa analítica

- microbiología;
- metabolitos;
- inmunidad;
- lesiones;
- digestibilidad.

Capa predictiva

- riesgo;
- respuesta;
- clasificación;
- confianza.

Capa de intervención

- dieta;
- aditivo;
- manejo;
- revisión sanitaria.

Capa de verificación

- respuesta;
 - persistencia;
 - efectos adversos;
 - coste.

7.59. Principio de intervención mínima suficiente

Cuando existe incertidumbre, debe elegirse la intervención:

- más reversible;
- más segura;
- más monitorizable;
- más compatible con el conocimiento existente.

No debería utilizarse una intervención compleja cuando una corrección básica de agua, higiene, proteína o manejo puede resolver el problema.

La IA debe priorizar causas simples antes de proponer soluciones sofisticadas.

7.60. Conclusión: del mapa microbiano a la decisión responsable

El microbioma ofrece una de las fuentes de información más prometedoras para la nutrición animal. Puede ayudar a explicar diferencias de digestibilidad, eficiencia, inmunidad, emisiones y respuesta a aditivos. La inteligencia artificial amplía esta capacidad al integrar miles de variables y detectar estructuras que serían difíciles de reconocer mediante análisis convencional.

Pero el ecosistema intestinal no se convierte en predecible por el mero hecho de secuenciarlo. Los datos son composicionales, dependientes del método, longitudinales y profundamente condicionados por dieta, ambiente y hospedador.

La IA puede responder:

Este patrón se asocia con este resultado.

Para convertir esa respuesta en una intervención debe demostrarse:

Modificar este componente mediante esta estrategia produce de manera reproducible este beneficio y no introduce un riesgo superior.

La distancia entre ambas afirmaciones es el espacio que separa el análisis exploratorio de la nutrición aplicada.

La utilización responsable del microbioma exige abandonar dos simplificaciones: que exista una comunidad universalmente ideal y que cualquier modificación sea beneficiosa.

La verdadera nutrición intestinal de precisión no busca imponer una composición microbiana estándar. Busca comprender qué funciones necesita cada animal, qué ecosistemas pueden sostenerlas y qué intervención ofrece la mejor combinación de eficacia, estabilidad, seguridad y coste.

La inteligencia artificial será valiosa cuando permita reducir el espacio de incertidumbre y seleccionar mejor los experimentos, los biomarcadores y las intervenciones. Será peligrosa cuando convierta asociaciones complejas en recomendaciones automáticas o en claims comerciales que la evidencia todavía no puede sostener.

8. Inteligencia artificial, salud animal y bienestar: detección precoz, nutrición clínica y límites del diagnóstico algorítmico

La nutrición animal, la sanidad y el bienestar no constituyen compartimentos independientes. Una reducción del consumo puede preceder a la aparición de signos clínicos; una dieta mal equilibrada puede aumentar la susceptibilidad a determinadas patologías; el dolor, el estrés térmico o la competencia social pueden modificar la ingestión y la eficiencia; y una alteración metabólica puede expresarse inicialmente como un cambio casi imperceptible en el comportamiento.

Esta continuidad biológica explica el creciente interés por aplicar inteligencia artificial a la detección temprana de enfermedad y a la monitorización del bienestar. Cámaras, micrófonos, acelerómetros, collares, sensores de rumia, básculas, medidores de agua, robots de ordeño y sistemas ambientales producen flujos de datos capaces de revelar desviaciones antes de que resulten evidentes para el observador humano.

La promesa es relevante: intervenir antes, reducir gravedad, limitar pérdidas, mejorar el uso de medicamentos y proteger el bienestar. Sin embargo, la misma capacidad de vigilancia puede producir alarmas excesivas, clasificaciones opacas, falsas asociaciones y una confianza injustificada en sistemas que no realizan un diagnóstico clínico completo.

La inteligencia artificial puede identificar patrones compatibles con enfermedad. No examina por sí sola al animal, no interpreta todo su contexto y no sustituye la competencia profesional veterinaria.

Su función correcta es apoyar una secuencia de detección, priorización, confirmación e intervención.

8.1. De la enfermedad visible a la desviación detectable

El enfoque clínico tradicional actúa cuando aparecen signos reconocibles:

- fiebre;
- diarrea;
- cojera;
- tos;
- pérdida marcada de peso;
- reducción de producción;
- alteración evidente del comportamiento.

Pero muchos procesos comienzan antes con cambios sutiles:

- menor frecuencia de visitas al comedero;
- reducción de rumia;
- aumento del tiempo tumbado;
- variación del patrón de bebida;
- menor velocidad de desplazamiento;
- aislamiento;
- alteraciones vocales;
- descenso de temperatura superficial en unas zonas y aumento en otras;
- cambio en la composición de la leche.

Estos cambios constituyen **señales prodrómicas**: indicadores tempranos que pueden preceder a la manifestación clínica.

El objetivo algorítmico es estimar:

$$P(H_{i,t+\Delta} = 1 \mid X_{i,t-k:t})$$

donde:

- $(H_{i,t+\Delta})$ representa la aparición futura de un problema sanitario;
- $(X_{i,t-k:t})$ contiene las observaciones recientes;
- (Δ) es el horizonte de predicción.

La utilidad no depende únicamente de detectar la enfermedad, sino de hacerlo con antelación suficiente para modificar el resultado.

8.2. Detección, predicción y diagnóstico

Estos conceptos deben diferenciarse.

Detección

Identificación de una anomalía presente en los datos.

Predicción

Estimación de la probabilidad de que ocurra un evento futuro.

Diagnóstico

Determinación profesional de una enfermedad o condición mediante la integración de signos, exploración, pruebas y conocimiento clínico.

Un sistema puede detectar reducción de rumia y predecir riesgo de enfermedad metabólica. No puede concluir automáticamente que el animal padece cetosis, desplazamiento de abomaso o metritis sin evidencia adicional.

La salida responsable será:

Patrón anómalo compatible con incremento de riesgo. Requiere evaluación.

No:

Diagnóstico confirmado.

8.3. La línea basal individual

Los animales presentan diferencias persistentes de comportamiento y producción. Un umbral común puede clasificar erróneamente a individuos que se encuentran sanos pero fuera de la media.

La alternativa es construir una línea basal individual:

$$B_i = f(X_{i,1}, X_{i,2}, \dots, X_{i,n})$$

La desviación se calcula respecto de su propio patrón:

$$D_{i,t} = X_{i,t} - B_i$$

Esta aproximación permite detectar cambios pequeños en animales normalmente estables.

Sin embargo, la línea basal puede estar contaminada si el periodo de referencia incluye enfermedad subclínica, adaptación, estrés o errores de medición. Debe actualizarse con prudencia para no normalizar progresivamente un deterioro.

8.4. Anomalía estadística y relevancia clínica

No toda desviación estadística tiene significado clínico.

Un animal puede reducir el consumo porque:

- cambió el horario;
- se modificó el pienso;
- aumentó la temperatura;
- sufrió competencia;
- el sensor falló;
- el comedero estuvo bloqueado.

La anomalía debe interpretarse mediante contexto.

Puede establecerse una jerarquía:

1. cambio aislado en una variable;
2. cambio persistente;
3. cambios concordantes;
4. asociación con factores de riesgo;
5. signos clínicos;
6. confirmación diagnóstica.

La confianza aumenta cuando varias señales independientes convergen.

8.5. Fusión multimodal de datos

La detección precoz mejora cuando combina distintas fuentes:

$$R_{i,t} f(C_{i,t}, A_{i,t}, W_{i,t}, P_{i,t}, E_t, L_{i,t})$$

donde:

- (C): consumo;
- (A): actividad;
- (W): agua;
- (P): producción;
- (E): ambiente;

- (L): resultados laboratoriales o clínicos.

Un descenso simultáneo de consumo, rumia y producción presenta mayor relevancia que una variación aislada.

La fusión multimodal también reduce dependencia de un solo sensor, pero aumenta la complejidad de integración, sincronización y mantenimiento.

8.6. Sensores de actividad

Los acelerómetros pueden clasificar:

- caminar;
- permanecer de pie;
- tumbarse;
- comer;
- rumiar;
- rascarse;
- movimientos anómalos.

La clasificación depende de:

- localización del sensor;
- frecuencia de muestreo;
- especie;
- edad;
- instalación;
- algoritmo.

Un modelo desarrollado con un collar no puede trasladarse automáticamente a un sensor auricular o de extremidad. Tampoco es seguro extrapolarlo entre razas, pesos o sistemas de alojamiento.

8.7. Rumia como indicador

En rumiantes, la reducción de rumia puede asociarse con:

- enfermedad;
- estrés;
- cambios de dieta;
- acidosis;
- dolor;
- alteraciones periparto.

Su valor reside en que puede cambiar antes que otros indicadores. Pero es inespecífica.

El sistema debe combinarla con:

- ingestión;
- leche;
- temperatura;
- actividad;

- días en lactación;
- cambios de ración.

La interpretación de una reducción de rumia después de una modificación dietética no debe ser igual que la de una reducción espontánea acompañada de fiebre.

8.8. Consumo de agua como señal sanitaria

El agua responde rápidamente a cambios fisiológicos y ambientales.

Una alteración puede indicar:

- fiebre;
- diarrea;
- enfermedad respiratoria;
- estrés térmico;
- obstrucción;
- fuga;
- cambio de presión;
- contaminación.

La señal debe evaluarse a escala individual y colectiva.

Una caída simultánea en toda la nave sugiere un problema de suministro. Una caída individual puede indicar enfermedad o fallo del identificador.

8.9. Visión artificial

Las cámaras permiten estimar:

- peso;
- condición corporal;
- postura;
- desplazamiento;
- interacción;
- lesiones visibles;
- distribución espacial;
- acceso a comederos.

La visión puede reducir la necesidad de manipulación, pero presenta limitaciones:

- oclusiones;
- suciedad;
- iluminación;
- fondos variables;
- animales superpuestos;
- dificultad para mantener identidad.

La precisión obtenida en imágenes seleccionadas suele ser superior a la alcanzada durante operación continua. La validación debe realizarse en las condiciones reales de la explotación.

8.10. Termografía

La termografía infrarroja puede detectar cambios superficiales asociados con:

- inflamación;
- fiebre;
- lesiones;
- mastitis;
- estrés térmico.

La temperatura superficial depende también de:

- ambiente;
- humedad;
- suciedad;
- distancia;
- ángulo;
- vascularización;
- pelo o plumas.

Un valor elevado no equivale automáticamente a temperatura corporal elevada. La termografía funciona mejor como cribado comparativo y longitudinal.

8.11. Análisis acústico

Tos, vocalizaciones y sonidos respiratorios pueden analizarse mediante micrófonos.

La IA puede identificar:

- frecuencia de tos;
- cambios vocales;
- estrés;
- eventos respiratorios.

Las dificultades incluyen:

- ruido de maquinaria;
- reverberación;
- múltiples animales;
- imposibilidad de atribuir el sonido a un individuo;
- cambios entre instalaciones.

La detección grupal puede ser útil para activar inspección, aunque no identifique al animal afectado.

8.12. Producción como biomarcador tardío y temprano

La producción es un indicador económico, pero también sanitario.

Pueden observarse:

- reducción de leche;

- descenso de puesta;
- menor crecimiento;
- peor conversión;
- cambios de composición.

En sistemas automatizados, pequeños descensos pueden detectarse rápidamente. Sin embargo, la producción está influida por:

- dieta;
- ambiente;
- fase;
- genética;
- manejo;
- ordeño;
- densidad.

El modelo debe evitar etiquetar como enfermedad cualquier desviación respecto del objetivo productivo.

8.13. Composición de leche y salud metabólica

Los robots y analizadores pueden registrar variables como:

- grasa;
- proteína;
- lactosa;
- conductividad;
- color;
- células somáticas;
- cuerpos cetónicos, cuando se dispone de medición.

Estas señales pueden contribuir a detectar:

- mastitis;
- balance energético negativo;
- cetosis;
- alteraciones digestivas.

Pero los sensores indirectos necesitan calibración y confirmación clínica. Un incremento de conductividad no es específico de mastitis.

8.14. Enfermedades metabólicas

Las enfermedades metabólicas se encuentran estrechamente relacionadas con la nutrición.

En vacuno de leche, el periodo de transición puede asociarse con:

- hipocalcemia;
- cetosis;
- desplazamiento de abomaso;
- hígado graso.

Los modelos pueden integrar:

- condición corporal;
- consumo;
- producción;
- parto;
- rumia;
- metabolitos;
- historial.

Su principal valor reside en seleccionar animales para pruebas o intervención temprana.

La recomendación nutricional debe integrarse con evaluación clínica. No toda vaca con elevado riesgo requiere idéntica medida.

8.15. Cojeras

La detección automática de cojera puede utilizar:

- cámaras;
- plataformas de presión;
- acelerómetros;
- distribución del peso;
- tiempo tumbado;
- velocidad.

La cojera altera acceso al alimento y agua, por lo que puede confundirse con un problema nutricional.

La relación es bidireccional:

cojera → menor consumo → peor condición

y determinadas estrategias nutricionales pueden influir en salud podal.

El algoritmo debe evitar interpretar la reducción de consumo como deficiencia de densidad cuando la causa principal es dolor.

8.16. Enfermedad respiratoria

En porcino, vacuno y avicultura pueden utilizarse:

- tos;
- temperatura;
- actividad;
- consumo;
- ventilación;
- gases;
- densidad.

Los modelos grupales pueden detectar cambios antes de que la morbilidad sea evidente.

Pero existe confusión con factores ambientales. Una concentración elevada de amoníaco puede producir cambios respiratorios y conductuales sin infección primaria.

La respuesta correcta puede ser corregir ventilación, no administrar tratamiento.

8.17. Trastornos digestivos

La detección puede incorporar:

- consumo;
- agua;
- consistencia fecal;
- imágenes;
- peso;
- temperatura;
- microbiología.

En lechones o terneros, los cambios pueden evolucionar rápidamente. La utilidad depende del tiempo de anticipación y de la capacidad de localizar al animal.

Un sistema que detecta diarrea a escala grupal pero no identifica individuos sigue siendo útil para revisar el lote, aunque no permita intervención individual automática.

8.18. Mortalidad como indicador insuficiente

La mortalidad es objetiva, pero tardía.

Un programa que evalúe la salud únicamente mediante mortalidad puede ignorar:

- dolor;
- enfermedad subclínica;
- pérdida de crecimiento;
- tratamientos;
- decomisos;
- retrasos.

Los sistemas de IA deberían orientarse hacia indicadores anteriores y más sensibles.

8.19. Bienestar positivo y ausencia de enfermedad

El bienestar no equivale únicamente a ausencia de patología.

Incluye:

- capacidad de descanso;
- acceso a recursos;
- comportamiento social;
- exploración;
- confort térmico;
- ausencia de miedo y dolor;
- estados positivos.

Los sistemas tecnológicos miden con mayor facilidad resultados negativos que experiencias positivas. Esta limitación debe reconocerse.

Un animal productivo no es necesariamente un animal con bienestar adecuado.

8.20. Indicadores de bienestar

Pueden utilizarse:

- tiempo tumbado;
- sincronización;
- agresiones;
- estereotipias;
- plumaje;
- lesiones;
- vocalización;
- uso del espacio;
- acceso a recursos.

La interpretación depende de especie y sistema. Un aumento de tiempo tumbado puede indicar descanso adecuado o enfermedad.

La señal debe contextualizarse mediante postura, lugar, actividad previa y respuesta posterior.

8.21. Competencia por el alimento

La nutrición formulada no garantiza nutrición consumida.

La competencia puede provocar:

- acceso desigual;
- desplazamientos;
- comidas más rápidas;
- consumo irregular;
- mayor variabilidad.

La visión y los identificadores pueden cuantificar:

- visitas;
- duración;
- rechazos;
- desplazamientos;
- orden de acceso.

Estos datos permiten detectar animales que reciben una dieta adecuada en teoría pero no la consumen en cantidad suficiente.

8.22. Densidad y distribución espacial

La concentración de animales en determinadas zonas puede indicar:

- confort térmico;
- corrientes;
- problemas de cama;
- iluminación;
- miedo;
- acceso a recursos.

Los modelos espaciales pueden construir mapas de uso.

Pero la interpretación exige conocimiento del diseño de la nave. Una zona vacía puede deberse a un obstáculo invisible para la cámara o a una fuente de ruido.

8.23. Estrés térmico

La IA puede combinar:

- temperatura;
- humedad;
- velocidad del aire;
- radiación;
- consumo;
- respiración;
- posición;
- producción.

El índice temperatura-humedad constituye una aproximación poblacional. La respuesta individual puede variar.

Los modelos avanzados pueden estimar riesgo específico por animal, pero deben activar acciones sobre:

- ventilación;
- agua;
- horarios;
- densidad;
- dieta.

No debe limitarse la respuesta a modificar nutrientes cuando el problema principal es ambiental.

8.24. Bienestar y función objetivo

Si el modelo optimiza únicamente coste y producción, puede elegir decisiones perjudiciales para el bienestar.

El bienestar debe incorporarse mediante restricciones:

$$W_k(X) \geq W_{k,\min}$$

No como un término compensable por mayor rendimiento.

Determinados requisitos —acceso al agua, ausencia de hambre prolongada, límites térmicos— deben ser absolutos.

8.25. Etiquetas clínicas y calidad del entrenamiento

Los modelos supervisados necesitan etiquetas:

- sano;
- enfermo;
- cojera;
- mastitis;
- cetosis.

Estas etiquetas pueden contener errores por:

- diagnóstico incompleto;
- diferencias entre observadores;
- ausencia de pruebas;
- variación de criterios;
- momento del examen.

Un modelo entrenado con etiquetas deficientes aprenderá inconsistencias.

La creación del conjunto clínico debe definir:

- criterio diagnóstico;
- profesional;
- pruebas;
- momento;
- gravedad;
- tratamiento.

8.26. Enfermedad subclínica y controles falsamente sanos

Los animales clasificados como controles pueden presentar enfermedad subclínica.

Esto reduce la separación entre grupos y puede introducir patrones engañosos.

Cuando sea posible, la categoría “sano” debería basarse en:

- ausencia de signos;
- parámetros adecuados;
- seguimiento posterior;
- ausencia de tratamiento.

La salud es una condición que debe demostrarse razonablemente, no una simple ausencia de diagnóstico registrado.

8.27. Desbalance de clases

Las enfermedades graves pueden ser poco frecuentes:

$$n_{\text{enfermos}} \ll n_{\text{sanos}}$$

Un modelo que clasifique a todos como sanos puede presentar alta exactitud.

Por ello deben utilizarse métricas como:

- sensibilidad;
- especificidad;
- precisión positiva;
- valor predictivo negativo;
- área bajo curva;
- calibración;
- tiempo de anticipación.

En una prevalencia baja, incluso una buena sensibilidad puede producir numerosos falsos positivos.

8.28. Valor predictivo y prevalencia

El valor predictivo positivo depende de la prevalencia:

$$VPP = \frac{Se \cdot Prev}{Se \cdot Prev + (1 - Sp)(1 - Prev)}$$

donde:

- (Se): sensibilidad;
- (Sp): especificidad;
- (Prev): prevalencia.

Un modelo probado durante un brote puede perder utilidad en una explotación con baja prevalencia.

Los resultados deben comunicarse para el entorno real de uso.

8.29. Coste de la falsa alarma

Las falsas alarmas generan:

- tiempo;
- pruebas;
- manipulación;
- estrés;
- tratamientos innecesarios;
- fatiga del personal.

Si la tasa es elevada, las alertas pueden ignorarse.

El umbral debe equilibrar sensibilidad y carga operativa. Para enfermedades graves puede aceptarse mayor número de comprobaciones, pero debe medirse su impacto.

8.30. Coste del falso negativo

El falso negativo puede provocar:

- retraso terapéutico;
- transmisión;
- dolor;
- mortalidad;
- pérdida productiva;
- uso posterior de tratamientos más intensos.

La función de coste debe reflejar asimetría:

$$C = c_{FP}FP + c_{FN}FN$$

con frecuencia:

$$c_{FN} > c_{FP}$$

Pero el balance depende de la enfermedad y de la intervención asociada.

8.31. Calibración probabilística

Un modelo puede discriminar correctamente y producir probabilidades incorrectas.

Si asigna riesgo del 80 % a cien animales, aproximadamente ochenta deberían desarrollar el evento para estar bien calibrado.

La calibración permite definir umbrales clínicos y asignar recursos.

Debe evaluarse mediante:

- curvas de calibración;
- error de Brier;
- comparación entre riesgo predicho y observado.

8.32. Tiempo de anticipación

La sensibilidad por sí sola no basta.

Detectar una enfermedad una hora antes de la observación humana puede aportar poco. Detectarla varios días antes puede cambiar el resultado.

Debe medirse:

$$T_{\text{alerta}} - T_{\text{diagnóstico}}$$

La anticipación debe ser suficiente y mantener una tasa aceptable de falsos positivos.

8.33. Priorización de animales

En explotaciones grandes, la IA puede crear una lista ordenada:

1. riesgo crítico;
2. riesgo alto;

3. revisión programada;
4. seguimiento.

Esto optimiza el trabajo veterinario y del personal.

La lista debe incluir motivos comprensibles:

- consumo –25 %;
- rumia –18 %;
- temperatura elevada;
- producción descendente;
- patrón persistente 36 horas.

Una puntuación opaca dificulta la evaluación.

8.34. Diagnóstico diferencial asistido

El sistema puede sugerir hipótesis compatibles:

- fallo de agua;
- estrés térmico;
- trastorno digestivo;
- enfermedad respiratoria;
- dolor.

Pero debe mostrar qué datos faltan para diferenciarlas.

Ejemplo:

Se recomienda comprobar temperatura corporal, acceso al agua y exploración respiratoria.

Esta orientación es más segura que asignar una enfermedad única.

8.35. Nutrición clínica y de recuperación

La enfermedad modifica:

- ingestión;
- metabolismo;
- necesidades;
- tolerancia digestiva;
- balance hídrico.

La nutrición de animales enfermos puede requerir:

- mayor densidad;
- mayor digestibilidad;
- cambios de textura;
- fraccionamiento;
- electrolitos;
- apoyo específico.

Pero no existe una regla universal.

Un algoritmo no debe recomendar automáticamente aumentar nutrientes cuando la capacidad de ingestión o metabolismo está comprometida.

8.36. Interacción con tratamientos

Las dietas y aditivos pueden interactuar con:

- antimicrobianos;
- antiinflamatorios;
- antiparasitarios;
- vacunas;
- tratamientos metabólicos.

El sistema debe conocer tratamientos activos antes de modificar:

- minerales;
- adsorbentes;
- probióticos;
- acidificantes;
- palatantes.

Una recomendación nutricional no puede formularse ignorando el plan veterinario.

8.37. Reducción responsable de antimicrobianos

La detección temprana puede permitir:

- aislamiento;
- corrección ambiental;
- tratamiento dirigido;
- prevención de propagación.

Esto puede contribuir a un uso más prudente de antimicrobianos.

Pero la IA no debe utilizarse para negar tratamiento necesario con el objetivo de mejorar un indicador de consumo de medicamentos.

La prioridad debe ser:

1. bienestar;
2. diagnóstico;
3. tratamiento apropiado;
4. prevención.

8.38. Vigilancia de resistencia antimicrobiana

Los sistemas pueden integrar:

- consumo de antimicrobianos;

- diagnósticos;
- sensibilidad;
- genes de resistencia;
- movimientos;
- brotes.

La IA puede detectar patrones de uso o emergencia.

Pero la predicción de resistencia no sustituye el antibiograma cuando sea necesario para la decisión clínica.

8.39. Epidemiología de explotación

La unidad de análisis puede ser:

- individuo;
- corral;
- lote;
- nave;
- explotación;
- red de explotaciones.

Un aumento simultáneo de signos en varios animales puede indicar:

- brote;
- fallo de ventilación;
- contaminación del alimento;
- problema de agua.

La agregación espacial y temporal ayuda a distinguir eventos individuales de eventos sistémicos.

8.40. Detección de brotes

Un algoritmo puede comparar incidencia observada y esperada:

$$S_t = O_t - E_t$$

donde:

- (O_t): casos observados;
- (E_t): casos esperados.

El aumento sostenido activa investigación.

La definición del nivel esperado debe adaptarse a estación, edad y fase. Un promedio anual puede ocultar patrones normales.

8.41. Trazabilidad entre pienso y enfermedad

Cuando aparece una incidencia sanitaria, debe poder relacionarse con:

- lote de pienso;

- fórmula;
- ingredientes;
- fabricación;
- silo;
- periodo de consumo;
- granja;
- animales afectados.

La IA puede identificar asociaciones entre lotes y eventos, pero la atribución causal requiere controlar:

- tiempo;
- destino;
- exposición;
- otros factores.

Un lote asociado con varias incidencias merece investigación, no condena automática.

8.42. Farmacovigilancia y vigilancia de aditivos

Tras introducir un aditivo o estrategia nutricional, el sistema puede monitorizar:

- consumo;
- salud;
- producción;
- efectos inesperados;
- subgrupos.

Esta vigilancia posimplantación permite detectar problemas no observados en ensayos limitados.

Debe diferenciarse entre:

- ausencia de beneficio;
- efecto adverso;
- fallo de aplicación;
- interacción.

8.43. Aprendizaje federado

Las enfermedades poco frecuentes requieren datos de múltiples explotaciones. El aprendizaje federado permite entrenar modelos sin centralizar todos los datos brutos.

Cada organización entrena localmente y comparte actualizaciones del modelo.

Esto puede mejorar privacidad y colaboración, pero no elimina riesgos:

- heterogeneidad;
- ataques;
- filtración;
- diferencias de etiquetas;
- influencia desigual.

La gobernanza debe definir quién participa, qué se comparte y cómo se valida.

8.44. Sesgo por tipo de explotación

Los conjuntos de datos suelen proceder de explotaciones digitalizadas.

Estas pueden diferir en:

- tamaño;
- manejo;
- genética;
- sanidad;
- infraestructura.

El modelo puede perder precisión en sistemas menos tecnificados.

La validación debe incluir diversidad productiva y no asumir que el entorno con más datos representa todo el sector.

8.45. Sesgo de intervención

Cuando un sistema genera una alerta, el personal interviene y puede evitar la enfermedad.

El registro puede mostrar que el animal alertado nunca enfermó y etiquetar la alerta como falsa, cuando fue correcta y la intervención cambió el resultado.

Este fenómeno dificulta el reentrenamiento.

Debe registrarse:

- alerta;
- acción;
- tratamiento;
- desenlace.

Sin esta información, el modelo aprende de resultados alterados por su propia utilización.

8.46. Retroalimentación y profecías autocumplidas

Una puntuación de alto riesgo puede provocar más observación y más diagnósticos. Los animales con bajo riesgo reciben menos atención.

El conjunto futuro puede parecer confirmar que los animales alertados enferman más, en parte porque fueron examinados más intensamente.

La evaluación debe mantener controles y protocolos para evitar sesgo de verificación.

8.47. Autonomía limitada

Las acciones automáticas admisibles pueden incluir:

- generar alerta;
- cambiar frecuencia de observación;
- activar ventilación;
- bloquear una recomendación nutricional;
- convocar revisión.

Acciones de mayor impacto, como tratamiento, aislamiento prolongado o sacrificio, requieren decisión profesional y cumplimiento normativo.

Debe existir una matriz de autonomía:

Tabla 11. Síntesis de nivel, acción y supervisión.

Nivel	Acción	Supervisión
0	Registrar	No inmediata
1	Alertar	Revisión posterior
2	Ajuste reversible	Supervisión definida
3	Intervención clínica	Autorización profesional
4	Decisión irreversible	Nunca exclusivamente algorítmica

8.48. Errores de identificación

Una alerta correcta asignada al animal equivocado puede ser inútil o perjudicial.

Las causas incluyen:

- pérdida de dispositivo;
- duplicación;
- lectura cruzada;
- cambio de animal;
- error de cámara.

La identidad debe verificarse antes de cualquier intervención individual.

8.49. Ciberseguridad y salud

Un ataque o error puede:

- ocultar alertas;
- crear falsas alarmas;
- alterar tratamientos;
- modificar dietas;
- bloquear ventilación;
- borrar trazabilidad.

Los sistemas sanitarios conectados deben considerarse infraestructura crítica de la explotación.

Se requieren:

- control de acceso;
- segmentación;
- copias;
- registros;
- recuperación;
- procedimientos manuales.

8.50. Modo de contingencia

Cuando el sistema falla, la explotación debe conservar capacidad para:

- observar;
- alimentar;
- ventilar;
- tratar;
- registrar.

La digitalización no debe eliminar competencias básicas ni procedimientos manuales.

8.51. Validación clínica

La validación debe responder:

- ¿detecta animales realmente afectados?
- ¿con qué antelación?
- ¿en qué gravedad?
- ¿en qué población?
- ¿qué ocurre después de la alerta?
- ¿mejora el resultado?

Un buen desempeño estadístico no basta si la intervención posterior no cambia salud, bienestar o eficiencia.

8.52. Ensayo de impacto

La evaluación ideal compara:

- manejo habitual;
- sistema de alertas;
- sistema de alertas con protocolo de actuación.

Los desenlaces deben incluir:

- tiempo hasta diagnóstico;
- gravedad;
- tratamientos;
- mortalidad;
- producción;
- bienestar;
- carga de trabajo;
- coste.

Esto permite conocer el valor del sistema completo, no solo del algoritmo.

8.53. Indicadores de desempeño

Tabla 12. Síntesis de dimensión y indicador.

Dimensión	Indicador
Detección	Sensibilidad
Falsas alarmas	Alertas por animal y periodo
Anticipación	Horas o días
Calibración	Riesgo predicho frente a observado
Clínica	Reducción de gravedad
Bienestar	Duración de dolor o enfermedad
Producción	Pérdida evitada
Medicación	Uso dirigido
Operación	Tiempo de revisión
Tecnología	Disponibilidad del sistema

8.54. Explicabilidad clínica

La explicación debe responder:

- por qué se alertó;
- respecto de qué línea basal;
- durante cuánto tiempo;
- qué variables fueron relevantes;
- qué otras causas son posibles.

No basta con mostrar la importancia matemática. La explicación debe ser útil para decidir la siguiente acción.

8.55. Responsabilidad profesional

La existencia de una recomendación algorítmica no desplaza automáticamente la responsabilidad.

La organización debe definir:

- quién supervisa;
- quién valida;
- quién interviene;
- quién documenta;
- quién revisa fallos.

El sistema debe apoyar la decisión profesional, no crear una zona de irresponsabilidad entre proveedor, integrador y usuario.

8.56. Auditoría de alertas

Periódicamente deben revisarse:

- alertas correctas;
- falsas;
- omitidas;
- anuladas;
- ignoradas;
- acciones;
- resultados.

Cada fallo debe analizarse:

- sensor;
- identidad;
- datos;
- modelo;
- umbral;
- actuación.

El objetivo es mejorar el sistema completo.

8.57. Principio de proporcionalidad clínica

La intensidad de la intervención debe depender de:

$$I = f(P, G, U, R)$$

donde:

- (P): probabilidad;
- (G): gravedad;
- (U): urgencia;
- (R): reversibilidad.

Un riesgo moderado de enfermedad leve puede justificar observación. Un riesgo moderado de evento grave puede justificar confirmación inmediata.

8.58. Arquitectura de un sistema sanitario-nutricional

Capa de captura

- consumo;
- agua;
- actividad;
- producción;
- imágenes;
- ambiente.

Capa de calidad

- calibración;
- identidad;
- plausibilidad;
- sincronización.

Capa analítica

- anomalías;
- riesgo;
- evolución;
- comparación.

Capa clínica

- diagnóstico diferencial;
- pruebas;
- prioridad.

Capa nutricional

- ajuste;
- bloqueo;
- recuperación.

Capa de seguimiento

- tratamiento;
- respuesta;
- cierre del caso.

8.59. Principios de diseño responsable

1. El modelo no debe presentarse como diagnóstico si no lo es.
2. La alerta debe ser explicable y accionable.
3. El sistema debe incorporar líneas basales individuales.
4. Las variables ambientales y nutricionales deben incluirse en el diagnóstico diferencial.
5. Las intervenciones clínicas requieren supervisión profesional.
6. Las acciones irreversibles no deben automatizarse.
7. Debe registrarse la intervención posterior a la alerta.
8. La eficacia debe medirse en resultados sanitarios y de bienestar.
9. Debe existir un modo de contingencia.
10. El bienestar prevalece sobre la optimización productiva.

8.60. Conclusión: detectar antes para cuidar mejor, no para delegar la clínica

La inteligencia artificial puede transformar la vigilancia sanitaria de reactiva en anticipatoria. Puede reconocer cambios de consumo, actividad, rumia, vocalización, temperatura y producción antes de que la enfermedad resulte evidente. Esta capacidad permite dirigir la atención hacia los animales con mayor probabilidad de necesitarla y construir una relación más estrecha entre nutrición, sanidad y bienestar.

Pero la detección temprana no equivale a diagnóstico automático. Las señales son inespecíficas, los sensores fallan, los animales difieren y las intervenciones modifican los datos futuros. Un sistema que ignora estas limitaciones puede provocar tratamientos innecesarios, retrasar la atención correcta o convertir cualquier desviación productiva en una supuesta enfermedad.

La IA responsable no reemplaza al veterinario ni al cuidador. Amplía su capacidad de observación, organiza la incertidumbre y prioriza los casos.

El criterio de éxito no debe ser cuántos animales fueron clasificados, sino cuántos problemas relevantes se detectaron a tiempo, cuántas intervenciones fueron apropiadas y cuánto sufrimiento o pérdida pudo evitarse.

La integración entre nutrición y salud debe partir de una idea esencial: el animal no es un conjunto de indicadores que debe regresar a una curva productiva ideal. Es un organismo cuya desviación puede expresar enfermedad, dolor, adaptación, variabilidad o respuesta al ambiente.

La inteligencia artificial será verdaderamente útil cuando ayude a distinguir esas posibilidades y conduzca a una intervención más rápida, proporcionada, fundamentada y humana.

9. La fábrica inteligente de piensos: control de proceso, calidad en línea y autonomía industrial segura

La inteligencia artificial aplicada a la nutrición animal no alcanza su verdadera dimensión industrial mientras permanece limitada a la formulación, la predicción biológica o la monitorización de los animales. El valor nutricional diseñado debe convertirse en un producto físico reproducible, homogéneo, seguro y estable. Entre la fórmula teórica y el pienso consumido existe una sucesión de operaciones —recepción, almacenamiento, transporte interno, molienda, dosificación, mezcla, acondicionamiento, granulación, extrusión, enfriamiento, recubrimiento y expedición— capaces de modificar sustancialmente la calidad final.

Una fórmula puede ser nutricionalmente correcta y fracasar industrialmente por:

- error de dosificación;
- segregación;
- mezcla insuficiente;
- molienda inadecuada;
- destrucción térmica;
- mala gelatinización;
- escasa durabilidad del gránulo;
- exceso de finos;
- contaminación cruzada;
- proliferación microbiana;
- dosificación incorrecta de líquidos;
- deterioro durante almacenamiento.

La fábrica inteligente pretende observar estas operaciones de manera continua, integrar sus variables y adaptar el proceso antes de que la desviación se transforme en producto no conforme.

No se trata solamente de digitalizar partes de producción o sustituir documentos en papel. Una fábrica verdaderamente inteligente debe ser capaz de:

1. conocer qué material circula por cada equipo;
2. reconocer el estado de máquinas y producto;
3. comparar el comportamiento real con el esperado;
4. detectar desviaciones;
5. predecir su evolución;
6. recomendar o ejecutar correcciones;
7. conservar evidencia completa de lo sucedido.

La inteligencia artificial puede intervenir en todos estos niveles. Pero cuanto más directamente controla equipos, temperaturas, válvulas, dosificadores o secuencias de fabricación, mayor es la necesidad de validación, restricciones y modos seguros de operación.

9.1. De la automatización convencional a la fabricación cognitiva

Las fábricas de piensos llevan décadas utilizando automatización industrial. Los autómatas programables, sistemas SCADA, células de carga y secuencias de transporte permiten ejecutar recetas de forma repetitiva.

La automatización convencional sigue reglas previamente definidas:

Si $X > \tau$, entonces ejecutar A

La inteligencia artificial añade capacidad para aprender relaciones complejas:

$$\hat{y} = f(X_1, X_2, \dots, X_n)$$

Puede predecir la consecuencia de una combinación de variables y seleccionar una acción antes de superar un límite.

La diferencia puede observarse en una granuladora.

Un control convencional mantiene una temperatura objetivo. Un sistema predictivo puede anticipar que, dadas la humedad de la harina, la composición de la fórmula, la carga del motor y la presión, la durabilidad del pellet caerá o se producirá un atasco. La intervención se adelanta al defecto.

No obstante, el aprendizaje no sustituye la lógica determinista de seguridad. Las funciones críticas deben conservar:

- enclavamientos;
- límites máximos;
- secuencias verificadas;
- parada de emergencia;
- control independiente.

La IA debe operar dentro de un espacio seguro definido por ingeniería y calidad.

9.2. Marco higiénico y responsabilidad del fabricante

El Reglamento (CE) N.º 183/2005 establece requisitos de higiene de los piensos, condiciones para garantizar su trazabilidad y obligaciones de los operadores, incluyendo procedimientos basados en los principios del APPCC para numerosas actividades del sector. La automatización no reduce estas obligaciones ni traslada la responsabilidad al proveedor del software.

La industria debe asegurar que:

- las instalaciones son adecuadas;
- los equipos se mantienen y limpian;
- la producción se controla;
- los peligros se previenen;
- los productos son trazables;
- las desviaciones se gestionan.

Las buenas prácticas para la industria de piensos de FAO e IFIF sitúan la producción dentro de sistemas integrados de aseguramiento de la calidad y la seguridad. La inteligencia artificial puede reforzar ese sistema, pero no sustituir sus fundamentos.

Una fábrica digitalmente avanzada que carezca de limpieza, mantenimiento, control de plagas o disciplina documental seguirá siendo una fábrica insegura, aunque disponga de cuadros de mando sofisticados.

9.3. Arquitectura de datos de la fábrica

La fábrica inteligente necesita integrar, al menos, cinco niveles tecnológicos:

Nivel de campo

- células de carga;
- caudalímetros;
- sondas;
- motores;
- vibración;
- cámaras;
- analizadores;
- válvulas;
- actuadores.

Nivel de control

- PLC;
- variadores;
- controladores locales;
- enclavamientos;
- alarmas.

Nivel de supervisión

- SCADA;
- interfaces;
- históricos;
- estados de línea.

Nivel de ejecución

- MES;
- órdenes;
- recetas;
 - secuencias;
 - genealogía de lotes;
 - rendimientos.

Nivel empresarial

- ERP;
- compras;
- inventarios;
- ventas;
- calidad;
- mantenimiento;
- laboratorio.

La IA necesita conectar estos niveles sin eliminar su separación funcional.

Una recomendación sobre producción debe conocer simultáneamente:

- formulación aprobada;
- disponibilidad real;
- calidad del ingrediente;
- estado de equipo;
- orden de fabricación;
- destino;
- restricciones legales.

La ausencia de interoperabilidad produce decisiones parciales.

9.4. Identidad digital de materias, lotes y equipos

Cada movimiento físico debe corresponder a una identidad digital inequívoca.

La genealogía puede representarse como un grafo:

$$G = (V, E)$$

donde los nodos incluyen:

- materias primas;
- silos;
- lotes;
- líneas;
- procesos;
- productos terminados.

Las aristas representan:

- transferencia;
- mezcla;
- transformación;
- división;
- incorporación.

Una trazabilidad débil puede registrar que se utilizó “trigo”, pero no qué lote entró en qué proporción ni cuánto residuo procedía de la fabricación anterior.

La trazabilidad inteligente debe responder:

- qué entró;
- cuánto;
- cuándo;
- desde dónde;
- a través de qué equipos;
- con qué parámetros;
- en qué productos terminó.

9.5. Recepción inteligente

La recepción es la primera barrera industrial.

Pueden integrarse:

- documentación;
- proveedor;
- origen;
- peso;
- temperatura;
- humedad;
- NIRS;
- imagen;
- olor;
- resultados rápidos;
- historial.

El sistema puede estimar:

$$P(\text{lote conforme} \mid X)$$

y asignar:

- descarga directa;
- muestreo reforzado;
- cuarentena;
- silo específico;
- rechazo.

Pero la recomendación no debe sustituir el plan de control. Un lote clasificado como bajo riesgo puede contener un peligro no representado en los datos.

El uso más sólido de la IA es adaptar la intensidad del control y detectar inconsistencias:

- humedad incompatible con el documento;
- peso volumétrico anómalo;
- espectro fuera de dominio;
- origen no habitual;
- proveedor con desviaciones recientes.

9.6. Asignación inteligente de silos

La elección de silo influye en:

- capacidad;
- segregación;
- compatibilidad;
- trazabilidad;
- limpieza;
- rotación;

- contaminación cruzada.

Puede formularse como un problema de optimización:

$$\min C_{\text{movimiento}} + C_{\text{riesgo}} + C_{\text{cambio}}$$

sujeto a:

- capacidad disponible;
- incompatibilidades;
- secuencia FIFO o FEFO;
- estado del silo;
- limpieza;
- necesidad de segregación.

La función no debe permitir mezclar materiales incompatibles solo porque optimiza espacio.

Las restricciones de identidad preservada, producción ecológica, medicación o alérgenos deben actuar como restricciones duras.

9.7. Inventario real frente a inventario contable

El inventario del ERP puede diferir del físico por:

- humedad;
- polvo;
- pérdidas;
- adherencias;
- error de básculas;
- transferencias no registradas;
- densidad;
- producto retenido.

La reconciliación puede utilizar:

$$I_{\text{teórico}} I_0 + \text{entradas} - \text{salidas}$$

y compararlo con:

$$I_{\text{estimado por sensor}}$$

La diferencia:

$$e_I = I_{\text{estimado}} - I_{\text{teórico}}$$

debe analizarse temporalmente.

Una desviación creciente puede indicar:

- fuga;
- sensor desplazado;

- error de dosificación;
- acumulación;
- extracción no registrada.

9.8. Gestión de materiales a granel

El comportamiento de flujo depende de:

- granulometría;
- humedad;
- grasa;
- densidad;
- forma;
- electrostática;
- compactación.

Un material puede formar:

- bóvedas;
- chimeneas;
- adherencias;
- descargas intermitentes.

Los sensores y modelos pueden detectar:

- cambios de caudal;
- variaciones de carga;
- vibraciones;
- tiempos anómalos.

La predicción permite activar:

- vibradores;
- aireación;
- inspección;
- cambio de secuencia.

Pero una intervención automática excesiva puede empeorar la segregación o dañar equipos. Las acciones deben adaptarse al material.

9.9. Molienda inteligente

La molienda afecta a:

- digestibilidad;
- mezclado;
- granulación;
- consumo energético;
- salud gastrointestinal;
- polvo.

La granulometría resultante depende de:

- tipo de molino;
- criba;
- velocidad;
- desgaste;
- humedad;
- dureza;
- caudal;
- aspiración.

El modelo puede predecir:

$$PSD = f(M, C, V, W, Q)$$

donde:

- (PSD): distribución granulométrica;
- (M): materia prima;
- (C): criba;
- (V): velocidad;
- (W): desgaste;
- (Q): caudal.

El objetivo no debería reducirse al diámetro medio. Debe incluir distribución, partículas excesivamente finas y fracción gruesa.

9.10. Granulometría y eficiencia energética

Una molienda más fina puede mejorar determinadas características nutricionales o tecnológicas, pero aumenta:

- consumo energético;
- temperatura;
- polvo;
- riesgo de problemas digestivos en ciertas especies;
- velocidad de desgaste.

La optimización puede expresarse:

$$\min(C_{\text{energía}} + C_{\text{desviación granulométrica}} + C_{\text{desgaste}})$$

sujeta a una distribución aceptable.

El modelo debe buscar una zona operativa, no el tamaño mínimo posible.

9.11. Desgaste de martillos y cribas

El desgaste modifica progresivamente:

- capacidad;

- granulometría;
- consumo;
- vibración.

La detección puede utilizar:

- horas;
- toneladas;
- intensidad;
- temperatura;
- vibración;
- distribución granulométrica.

El mantenimiento basado solo en calendario sustituye componentes aunque puedan seguir funcionando o los conserva más allá de su vida útil.

El mantenimiento predictivo estima:

$$RUL = f(X_t)$$

donde (RUL) es la vida útil restante.

Las revisiones recientes sobre mantenimiento predictivo en Industria 4.0 destacan su capacidad potencial para reducir paradas y costes, aunque señalan dificultades de calidad de datos, integración y transferencia entre equipos.

9.12. Dosificación de macroingredientes

La dosificación debe cumplir:

$$m_j^{\text{real}} \approx m_j^{\text{objetivo}}$$

El error puede expresarse:

$$e_j = m_j^{\text{real}} - m_j^{\text{objetivo}}$$

El sistema debe distinguir:

- error aleatorio;
- sesgo persistente;
- error de identificación;
- flujo residual;
- fallo mecánico.

La IA puede detectar que una báscula presenta un sesgo creciente antes de superar una tolerancia.

Sin embargo, la corrección automática de la calibración requiere precaución. Un algoritmo no debe ocultar una avería ajustando matemáticamente los resultados sin comprobar físicamente el equipo.

9.13. Microdosificación

Los microingredientes presentan especial criticidad porque pequeñas desviaciones pueden tener gran relevancia.

La incertidumbre relativa aumenta cuando la masa es pequeña:

$$\text{Error relativo} = \frac{|e|}{m_{\text{objetivo}}}$$

Un error de 100 gramos puede ser irrelevante en una tonelada de cereal y crítico en un aditivo de baja inclusión.

La microdosificación requiere:

- resolución adecuada;
- prevención de adherencias;
- control de identidad;
- secuencia;
- verificación;
- limpieza.

La visión artificial y la lectura automática pueden comprobar:

- saco;
- etiqueta;
- código;
- lote;
- color;
- posición.

Pero la verificación debe diseñarse para impedir que el sistema acepte un envase correcto con un contenido incorrecto por error previo.

9.14. Dosificación manual asistida

Las adiciones manuales son una fuente relevante de riesgo.

El sistema puede guiar al operario:

1. identificar orden;
2. localizar ingrediente;
3. verificar lote;
4. pesar;
5. comprobar tolerancia;
6. confirmar adición.

Las ayudas pueden incluir:

- escáner;
- balanza conectada;

- iluminación de ubicación;
- bloqueo si el ingrediente es incorrecto;
- registro fotográfico.

La IA puede detectar patrones anómalos, pero la secuencia básica debe mantenerse mediante controles deterministas.

9.15. Mezclado

La mezcla pretende distribuir uniformemente ingredientes presentes en proporciones muy distintas.

La calidad depende de:

- diseño;
- nivel de llenado;
- tiempo;
- secuencia;
- densidad;
- granulometría;
- líquidos;
- desgaste;
- residuo.

Un tiempo insuficiente produce heterogeneidad. Uno excesivo puede favorecer segregación en determinadas mezclas.

La homogeneidad suele evaluarse mediante un marcador y el coeficiente de variación:

$$CV = \frac{s}{\bar{x}} \times 100$$

El valor debe interpretarse según método, marcador, concentración y plan de muestreo.

9.16. Predicción de homogeneidad

Un modelo puede relacionar:

$$CV = f(t, L, S, D, F, W)$$

donde:

- (t): tiempo;
- (L): carga;
- (S): secuencia;
- (D): densidad;
- (F): líquidos;
- (W): desgaste.

El objetivo es predecir riesgo de mezcla deficiente sin analizar cada lote.

Pero esta predicción requiere verificación periódica. FAO destaca que el control del producto terminado debe comprobar que los ingredientes fueron incorporados en las proporciones previstas y que la falta de homogeneidad puede revelar deficiencias de mezcla o segregación.

La IA no elimina la necesidad de pruebas de homogeneidad; permite diseñarlas de manera más informada.

9.17. Secuencia de incorporación

La secuencia puede afectar a:

- distribución de microingredientes;
- formación de grumos;
- absorción de líquidos;
- recubrimiento;
- reacción entre componentes.

Una estrategia habitual incorpora primero una fracción de macroingredientes, después premezclas y finalmente el resto.

El modelo puede seleccionar la secuencia según:

- densidad;
- tamaño;
- higroscopicidad;
- carga;
- líquidos.

Pero no debe proponer una secuencia que aumente incompatibilidades químicas o riesgo de contaminación.

9.18. Segregación posterior

Un producto correctamente mezclado puede segregarse durante:

- transporte;
- caída;
- vibración;
- llenado;
- descarga;
- almacenamiento.

La segregación depende de diferencias de:

- tamaño;
- densidad;
- forma;
- carga electrostática.

La fábrica debe evaluar no solo la mezcla a la salida del mezclador, sino su estabilidad hasta la entrega.

La IA puede analizar dónde aparece variabilidad comparando muestras en diferentes puntos.

9.19. Adición de líquidos

La adición de:

- aceites;
- enzimas;
- ácidos;
- melaza;
- palatantes;
- agua;

requiere control de:

- viscosidad;
- temperatura;
- presión;
- caudal;
- boquillas;
- tiempo;
- distribución.

Una obstrucción parcial puede mantener un caudal total aparentemente correcto y producir mala distribución.

Los sensores de presión, visión o patrones de consumo de bomba pueden detectar este fallo.

9.20. Acondicionamiento térmico

El acondicionamiento modifica:

- humedad;
- temperatura;
- gelatinización;
- plasticidad;
- higiene;
- estabilidad de componentes.

Las variables incluyen:

- vapor;
- presión;
- calidad del vapor;
- temperatura;
- tiempo de retención;
- humedad;
- carga.

El sistema puede estimar el estado del material y ajustar vapor o velocidad.

El objetivo no es alcanzar la temperatura máxima, sino conseguir la transformación necesaria sin destruir nutrientes o aditivos sensibles.

9.21. Granulación

La calidad del pellet depende de:

- formulación;
- molienda;
- humedad;
- vapor;
- grasa;
- matriz;
- compresión;
- velocidad;
- refrigeración.

La durabilidad puede modelarse mediante:

$$PDI = f(X_{\text{fórmula}}, X_{\text{proceso}}, X_{\text{ambiente}})$$

Un estudio específico aplicó modelos de regresión de aprendizaje automático para predecir el índice de durabilidad del pellet a partir de formulación, parámetros industriales y condiciones ambientales, mostrando que estas relaciones pueden modelarse con utilidad predictiva.

Este enfoque permite anticipar problemas antes de que el producto llegue al ensayo final.

9.22. Durabilidad y finos

La durabilidad insuficiente produce:

- pérdidas;
- segregación;
- menor consumo;
- variabilidad de nutrientes;
- polvo.

Pero aumentar la durabilidad mediante mayor compresión o temperatura puede:

- elevar consumo energético;
- reducir capacidad;
- degradar componentes;
- endurecer excesivamente.

La función objetivo debe ser multiobjetivo:

$$J = w_1 PDI w_2 E w_3 D w_4 F$$

donde:

- (E): energía;
- (D): degradación;
- (F): finos.

9.23. Calidad física en línea

La medición tradicional de durabilidad, dureza y finos suele ser discontinua.

Los sistemas en línea pueden estimar:

- tamaño;
- longitud;
- roturas;
- color;
- finos;
- densidad.

La visión artificial permite analizar grandes cantidades de pellet, aunque debe validarse frente a métodos de referencia.

Una cámara puede detectar apariencia y geometría, pero no necesariamente durabilidad durante transporte.

9.24. Enfriamiento

El enfriador debe reducir temperatura y humedad de forma controlada.

Un producto insuficientemente enfriado puede favorecer:

- condensación;
- apelmazamiento;
- moho;
- pérdida de estabilidad.

Un enfriamiento excesivo puede reducir humedad por debajo del objetivo y generar pérdida económica.

El control puede modelar:

$$T_{\text{salida}} f(T_{\text{entrada}}, Q_{\text{aire}}, H_{\text{aire}}, M, \tau)$$

La humedad ambiental debe considerarse. Utilizar siempre el mismo caudal independientemente del clima reduce eficiencia.

9.25. Secado y actividad de agua

La humedad total no describe por completo la estabilidad microbiológica.

La actividad de agua:

$$a_w = \frac{p}{p_0}$$

representa la disponibilidad del agua para reacciones y crecimiento microbiano.

Los modelos pueden estimar (a_w) a partir de composición, humedad y temperatura, pero esta estimación debe validarse por matriz.

La IA puede predecir riesgo de deterioro, no sustituir automáticamente la medición cuando resulte crítica.

9.26. Extrusión

La extrusión combina:

- temperatura;
- presión;
- cizalla;
- humedad;
- tiempo;
- expansión.

Se utiliza en acuicultura, pet food y otras aplicaciones.

Las variables finales pueden incluir:

- densidad;
- expansión;
- flotabilidad;
- textura;
- digestibilidad;
- estabilidad en agua.

El proceso es altamente no lineal. Estudios recientes han mostrado la utilidad del aprendizaje automático para predecir propiedades de productos extrusionados a partir de variables de formulación y proceso.

No obstante, los modelos deben revalidarse al cambiar:

- equipo;
- tornillo;
- escala;
- materia prima;
- humedad;
- configuración.

9.27. Recubrimiento posproceso

El recubrimiento permite incorporar componentes sensibles después del tratamiento térmico.

Puede incluir:

- grasas;
- enzimas;
- aromas;
- vitaminas;
- probióticos;
- medicamentos autorizados.

La uniformidad depende de:

- vacío;
- presión;
- tamaño;
- porosidad;
- viscosidad;
- temperatura;
- tiempo.

La IA puede ajustar la cantidad según absorción prevista. Sin embargo, la cantidad aplicada debe verificarse mediante balances y análisis.

9.28. Conservación de nutrientes sensibles

El calor, oxígeno, humedad y presión pueden reducir:

- actividad enzimática;
- viabilidad microbiana;
- vitaminas;
- compuestos aromáticos.

La retención puede expresarse:

$$R = \frac{C_{\text{final}}}{C_{\text{inicial}}} \times 100$$

Los modelos pueden predecir retención según condiciones.

La formulación debe utilizar la concentración efectiva después del proceso, no únicamente la dosis añadida.

9.29. Control microbiológico del proceso

La fábrica debe controlar:

- materias primas;
- polvo;
- líneas;
- zonas húmedas;
- producto;
- transporte.

Los modelos pueden integrar:

- temperatura;
- humedad;
- limpieza;
- resultados ambientales;
- historial;
- tráfico.

Pueden crear mapas dinámicos de riesgo y orientar muestreo.

Pero la ausencia de alertas no sustituye programas de higiene, control de plagas y análisis.

9.30. Salmonella y otros peligros biológicos

Los peligros microbiológicos pueden presentar distribución irregular y persistir en nichos.

La IA puede identificar asociaciones entre positivos y:

- zona;
- humedad;
- línea;
- proveedor;
- estación;
- mantenimiento.

Pero un modelo no debe utilizarse para declarar una línea libre de patógenos sin evidencia microbiológica.

La función más segura es priorizar:

- inspección;
- limpieza;
- muestras;
- investigación de causa.

9.31. Contaminación cruzada y arrastre

El arrastre ocurre cuando parte de un producto permanece en el equipo y aparece en la fabricación posterior.

Puede afectar especialmente a:

- medicamentos;
- coccidiostatos;
- minerales;
- aditivos de baja dosis;
- alérgenos;
- productos para especies sensibles.

El Codex y FAO han destacado que una gestión inadecuada del carryover puede dañar a especies sensibles y producir residuos en alimentos de origen animal.

La IA puede estimar:

$$C_{n+1}f(C_n, E, S, L, F)$$

donde:

- (C_n): concentración anterior;
- (E): equipo;

- (S): secuencia;
- (L): limpieza;
- (F): flush.

Pero el modelo debe apoyarse en ensayos físicos de arrastre.

9.32. Secuenciación inteligente de órdenes

El orden de fabricación puede reducir:

- limpiezas;
- purgas;
- contaminación cruzada;
- cambios;
- pérdidas.

La optimización puede considerar:

$$\min(C_{\text{cambio}} + C_{\text{limpieza}} + C_{\text{riesgo}} + C_{\text{retraso}})$$

La secuencia debe respetar incompatibilidades.

Una lógica orientativa puede avanzar desde productos de menor a mayor concentración de ciertos componentes y aplicar purgas antes de especies sensibles. Sin embargo, las reglas dependen del peligro, equipo y validación interna.

9.33. Material de purga y reproceso

El material utilizado para limpiar una línea debe tener:

- identificación;
- cantidad;
- composición;
- destino permitido;
- trazabilidad.

La IA puede recomendar su reutilización, pero debe impedir destinos incompatibles.

La optimización económica no puede justificar incorporar un reproceso si:

- compromete seguridad;
- altera composición;
- incumple especificación;
- pierde identidad.

9.34. Formulación y fabricación como sistema integrado

La formulación convencional puede seleccionar ingredientes sin considerar completamente su comportamiento tecnológico.

Una formulación industrialmente inteligente incorpora:

- dureza;
- grasa;
- almidón;
- fibra;
- capacidad de absorción;
- granulabilidad;
- energía de molienda;
- estabilidad térmica.

Puede incluir un coste de proceso:

$$C_{\text{total}} C_{\text{ingredientes}} + C_{\text{fabricación}} + C_{\text{calidad}}$$

Una fórmula ligeramente más cara en ingredientes puede ser más económica si mejora capacidad, reduce energía y disminuye reproceso.

9.35. Soft sensors

Un sensor virtual estima una variable difícil de medir directamente.

Ejemplos:

- humedad del producto;
- durabilidad;
- gelatinización;
- homogeneidad;
- desgaste;
- actividad residual.

Se construye mediante:

$$\hat{y} = f(X_{\text{sensores}})$$

Su utilidad depende de:

- calibración;
- estabilidad;
- frecuencia de verificación;
- detección de deriva.

Un soft sensor no debe presentarse como medición directa.

9.36. Control de proceso basado en modelo

El control predictivo utiliza un modelo para simular la evolución y seleccionar acciones.

$$\min_{u_{t:t+H}} \sum_{k=1}^H |y_{t+k} - r_{t+k}|^2$$

sujeto a restricciones.

En granulación o extrusión puede ajustar:

- vapor;
- caudal;
- velocidad;
- humedad;
- temperatura.

La ventaja es anticipar interacciones. El riesgo es que un modelo incorrecto produzca acciones inapropiadas.

Debe existir un controlador seguro de respaldo.

9.37. Gemelo digital de la fábrica

El gemelo digital representa:

- materiales;
- equipos;
- parámetros;
- flujos;
- tiempos;
- calidad;
- energía.

Permite simular:

- nueva fórmula;
- avería;
- cambio de capacidad;
- secuencia;
- ampliación;
- restricción energética.

El gemelo puede utilizarse para entrenamiento y planificación sin intervenir directamente en la planta.

Su calidad depende de la actualización con datos reales. Un modelo que no refleja desgaste, acumulaciones o variaciones de materias primas se aleja progresivamente de la fábrica.

9.38. Detección de anomalías

Los modelos no supervisados pueden aprender el comportamiento normal:

$$X_t \sim P_{\text{normal}}$$

y generar alerta cuando:

$$d(X_t, P_{\text{normal}}) > \tau$$

Esto resulta útil para fallos no etiquetados.

Pero la anomalía puede representar:

- avería;
- producto nuevo;
- cambio legítimo;
- sensor defectuoso.

La alerta debe conducir a investigación, no a diagnóstico automático.

9.39. Mantenimiento predictivo

El mantenimiento predictivo puede aplicarse a:

- rodamientos;
- motores;
- reductores;
- ventiladores;
- bombas;
- prensas;
- molinos;
- transportadores.

Las variables incluyen:

- vibración;
- temperatura;
- corriente;
- sonido;
- lubricante;
- horas;
- carga.

La IA puede estimar:

- probabilidad de fallo;
- tipo;
- vida restante;
- momento de intervención.

El beneficio no es solo reducir paradas. Un equipo degradado puede producir calidad deficiente antes de fallar.

9.40. Mantenimiento basado en riesgo

No todos los equipos tienen la misma criticidad.

El riesgo puede calcularse:

$$R = P(F) \times C(F)$$

donde:

- (P(F)): probabilidad de fallo;
- (C(F)): consecuencia.

Un fallo de equipo auxiliar puede producir demora. Un fallo en microdosificación o control térmico puede comprometer seguridad.

La prioridad debe combinar fiabilidad, calidad y seguridad.

9.41. Optimización energética

La fábrica consume energía en:

- molienda;
- aire;
- vapor;
- granulación;
- extrusión;
- secado;
- transporte.

La IA puede:

- identificar consumos anómalos;
- adaptar cargas;
- optimizar secuencia;
- reducir picos;
- comparar eficiencia.

El indicador debe relacionarse con producción:

$$E_s = \frac{\text{kWh}}{\text{tonelada}}$$

Pero reducir energía no debe sacrificar tratamiento, mezcla o calidad.

9.42. Huella ambiental industrial

El sistema puede registrar:

- energía;
- agua;
- vapor;
- mermas;
- polvo;
- reproceso;
- residuos.

Una optimización ambiental completa debe evitar trasladar impactos.

Reducir temperatura puede ahorrar energía y aumentar rechazos. Mejorar durabilidad puede reducir pérdidas logísticas aunque consuma más energía en prensa.

El análisis debe considerar el ciclo completo.

9.43. Planificación avanzada

La planificación debe coordinar:

- pedidos;
- materias primas;
- líneas;
- silos;
- cambios;
- mantenimiento;
- expedición.

Puede plantearse como:

$$\min C_{\text{retraso}} + C_{\text{inventario}} + C_{\text{cambio}} + C_{\text{energía}}$$

con restricciones de seguridad.

La IA puede responder a incidencias en tiempo real, pero debe evitar replanificaciones continuas que desorganicen la planta.

9.44. Logística de expedición

El producto correcto debe cargarse en:

- vehículo correcto;
- compartimento correcto;
- destino correcto.

El sistema puede verificar:

- matrícula;
- orden;
- silo;
- peso;
- limpieza;
- precinto;
- ruta.

La visión artificial puede comprobar posición y limpieza aparente, pero no sustituye protocolos de inspección cuando exista riesgo no visible.

9.45. Prevención de carga errónea

La carga equivocada puede producir consecuencias graves.

La prevención requiere:

- identificación múltiple;

- bloqueo de válvulas;
- correspondencia orden-silo;
- confirmación;
- registro.

La IA puede detectar incongruencias, pero el control debe descansar en enclavamientos deterministas.

No debería existir una única decisión algorítmica capaz de abrir una ruta incompatible.

9.46. Laboratorio y liberación

La liberación debe integrar:

- proceso;
- análisis;
- desviaciones;
- fórmula;
- trazabilidad;
- destino.

La IA puede calcular riesgo residual y priorizar ensayos.

Pero los criterios obligatorios deben conservarse. No puede omitirse una determinación requerida porque el modelo considere bajo riesgo.

9.47. Liberación paramétrica

La liberación paramétrica utiliza evidencia del proceso para inferir que el producto cumple, reduciendo dependencia del ensayo final.

Requiere:

- proceso validado;
- sensores fiables;
- límites definidos;
- control estadístico;
- ausencia de desviaciones.

No debe aplicarse a características que el proceso no controla o mide adecuadamente.

La IA puede reforzar la liberación paramétrica, pero también aumentar la opacidad. Toda decisión debe reconstruirse.

9.48. Control estadístico de proceso

Los gráficos de control permiten distinguir variación común y especial.

Para una variable (X):

$$UCL = \mu + k\sigma$$

La IA puede detectar patrones multivariantes y no lineales.

Pero los límites de control no son especificaciones. Un proceso puede estar estable y producir fuera de especificación, o ser inestable y todavía producir dentro.

9.49. Deriva de proceso

La deriva puede ser gradual:

- desgaste;
- acumulación;
- cambio de operador;
- humedad estacional;
- proveedor;
- calibración.

Los modelos deben monitorizar:

- error;
- distribución;
- frecuencia de alertas;
- residuales.

La adaptación automática debe limitarse. Si el modelo aprende una deriva causada por deterioro, puede normalizarla en lugar de alertar.

9.50. Calidad por diseño

La inteligencia industrial debe comenzar antes de fabricar.

La calidad por diseño identifica:

- atributos críticos del producto;
- parámetros críticos del proceso;
- relaciones;
- zonas operativas.

Puede definirse un espacio:

$$\Omega = X: Q_j(X) \in S_j \forall j$$

La IA ayuda a caracterizar (Ω), pero las fronteras deben validarse.

Operar dentro del espacio reduce riesgo; no garantiza conformidad si aparecen peligros no modelizados.

9.51. Gestión de cambios

Todo cambio en:

- ingrediente;
- proveedor;

- fórmula;
- equipo;
- software;
- sensor;
- modelo;
- umbral;

puede afectar al proceso.

La gestión debe evaluar:

1. impacto;
2. validación;
3. documentación;
4. formación;
5. seguimiento.

Actualizar un modelo es un cambio de proceso, aunque no se modifique físicamente la línea.

9.52. Versionado del modelo

Debe conservarse:

- versión;
- datos de entrenamiento;
- variables;
- parámetros;
- fecha;
- aprobación;
- rendimiento;
- ámbito;
- cambios.

La fábrica debe poder reproducir qué modelo tomó una decisión sobre un lote concreto.

9.53. Intervención humana

La persona debe poder:

- aceptar;
- modificar;
- rechazar;
- detener;
- documentar.

Pero la supervisión no debe convertirse en confirmación automática.

La interfaz debe mostrar:

- recomendación;
- causa;

- riesgo;
- límites;
- efecto previsto;
- incertidumbre.

9.54. Competencia del personal

La digitalización modifica los perfiles profesionales.

Se necesitan competencias en:

- proceso;
- nutrición;
- calidad;
- automatización;
- datos;
- ciberseguridad.

No basta con contratar especialistas en IA que desconozcan la fabricación. Tampoco es suficiente delegar la tecnología en mantenimiento sin integrar calidad y nutrición.

La gobernanza debe ser multidisciplinar.

9.55. Fatiga de alarmas

Un sistema con demasiadas alertas pierde eficacia.

Las alarmas deben priorizarse por:

$$R = P \times S \times U$$

donde:

- (P): probabilidad;
- (S): severidad;
- (U): urgencia.

Deben eliminarse alarmas redundantes y revisarse las ignoradas.

Una alerta sin acción definida es ruido.

9.56. Ciberseguridad industrial

La fábrica conectada está expuesta a:

- accesos no autorizados;
- ransomware;
- manipulación;
- indisponibilidad;
- alteración de recetas;
- falsificación de datos.

La arquitectura debe incluir:

- segmentación entre IT y OT;
- control de acceso;
- autenticación;
- copias;
- registros;
- recuperación;
- gestión de proveedores.

La seguridad física y la digital convergen. Una alteración de válvulas, fórmulas o temperaturas puede producir producto peligroso.

9.57. Ataques sobre modelos

Los sistemas de IA pueden sufrir:

- manipulación de datos;
- entradas adversarias;
- sustitución de modelo;
- extracción;
- corrupción del entrenamiento.

Un atacante podría intentar:

- ocultar una avería;
- clasificar como conforme un lote;
- alterar mantenimiento;
- modificar secuencia.

Los modelos críticos deben protegerse como componentes de control industrial.

9.58. Modo manual y recuperación

La fábrica debe poder operar de forma segura ante:

- pérdida de red;
- fallo del modelo;
- servidor caído;
- datos incoherentes;
- ciberincidente.

El modo manual debe estar:

- documentado;
- probado;
- entrenado.

No basta con afirmar que existe. Si el personal nunca lo practica, puede resultar inoperante durante una emergencia.

9.59. Grados de autonomía

Puede establecerse:

Tabla 13. Síntesis de nivel y capacidad.

Nivel	Capacidad
0	Registro
1	Visualización
2	Recomendación
3	Ajuste automático reversible
4	Control autónomo dentro de límites
5	Optimización integral

La mayoría de las aplicaciones debería avanzar progresivamente.

No es necesario alcanzar autonomía máxima para obtener valor.

9.60. Matriz de criticidad

Tabla 14. Síntesis de aplicación, impacto potencial y autonomía recomendable.

Aplicación	Impacto potencial	Autonomía recomendable
Predicción de energía	Moderado	Automática supervisada
Planificación	Moderado	Recomendación
Mantenimiento	Moderado-alto	Recomendación
Ajuste de vapor	Alto	Automático limitado
Microdosificación	Muy alto	Control determinista y verificación
Secuencia de medicados	Muy alto	Bloqueo obligatorio
Liberación	Muy alto	Aprobación de calidad
Carga de camión	Muy alto	Verificación múltiple

9.61. Validación de sistemas

La validación debe demostrar:

- instalación correcta;
- operación correcta;
- desempeño;
- límites;
- recuperación;
- trazabilidad.

Puede estructurarse en:

IQ

Cualificación de instalación.

OQ

Cualificación operacional.

PQ

Cualificación de desempeño.

El componente de IA añade:

- validación del conjunto de datos;
- rendimiento por subgrupo;
- deriva;
- abstención;
- reproducibilidad.

9.62. Pruebas de escenarios extremos

Deben simularse:

- sensor congelado;
- señal imposible;
- pérdida de identidad;
- silo vacío;
- válvula bloqueada;
- orden incompatible;
- fallo de comunicación;
- modelo no disponible.

El sistema debe fallar de forma segura.

9.63. Validación continua

La validación no termina en la puesta en marcha.

Deben controlarse:

- precisión;
- errores;
- falsos negativos;
- intervenciones;
- cambios;
- rendimiento.

Una regla posible es activar revisión cuando:

$$|e_t| > \tau$$

durante un número definido de lotes o cuando cambie significativamente la distribución de entradas.

9.64. Indicadores clave

Tabla 15. Síntesis de dimensión y indicador.

Dimensión	Indicador
Dosificación	Error absoluto y relativo
Mezcla	Coefficiente de variación
Molienda	Distribución granulométrica
Granulación	PDI y finos
Energía	kWh/t
Capacidad	t/h
Mantenimiento	Paradas y RUL
Calidad	No conformidades
Seguridad	Incidentes y carryover
Trazabilidad	Lotes reconstruibles
Automatización	Intervenciones manuales
IA	Error y abstenciones

9.65. Modelo de madurez

Nivel 1. Digitalización básica

Datos aislados y registros electrónicos.

Nivel 2. Integración

Conexión entre producción, calidad y ERP.

Nivel 3. Analítica

Indicadores y detección de tendencias.

Nivel 4. Predicción

Calidad y fallos anticipados.

Nivel 5. Control adaptativo

Ajuste automático dentro de límites.

Nivel 6. Optimización integral

Producción, calidad, energía y logística coordinadas.

La madurez no debe medirse por número de sensores, sino por calidad de decisiones y reducción demostrada del riesgo.

9.66. Caso conceptual: control inteligente de granulación

La secuencia puede ser:

1. el sistema recibe la fórmula;
2. consulta humedad y composición;
3. estima condiciones iniciales;
4. arranca dentro de parámetros validados;
5. observa carga, temperatura, presión y caudal;
6. predice PDI y consumo energético;
7. ajusta vapor y velocidad dentro de límites;
8. detecta desviación;
9. solicita muestra o intervención;
10. registra todo.

La IA no controla:

- límites máximos de seguridad;
- parada de emergencia;
- incompatibilidades;
- liberación definitiva.

Estas funciones permanecen protegidas.

9.67. Caso conceptual: reducción del arrastre

El sistema analiza:

- fórmula anterior;
- concentración;
- ruta;
- equipo;
- producto siguiente;
- sensibilidad de especie.

Calcula riesgo y propone:

- secuencia directa;
- lote de transición;
- purga;
- limpieza.

Si la combinación está prohibida, el sistema bloquea.

Después compara análisis reales con la predicción y actualiza el modelo.

9.68. Riesgos de la fábrica excesivamente autónoma

Una autonomía mal diseñada puede producir:

- propagación rápida del error;

- pérdida de conocimiento práctico;
- dependencia del proveedor;
- dificultad de auditoría;
- normalización de anomalías;
- reducción de controles.

La velocidad es una ventaja cuando la decisión es correcta y una amenaza cuando es incorrecta.

Por ello, la autonomía debe aumentar solo cuando:

- el proceso es conocido;
- los datos son fiables;
- las restricciones están definidas;
- la acción es reversible;
- existe supervisión;
- el desempeño está validado.

9.69. Principios de implantación

1. Digitalizar primero el proceso real, no el proceso imaginado.
2. Corregir problemas básicos antes de aplicar IA.
3. Integrar nutrición, calidad, mantenimiento y producción.
4. Mantener controles deterministas para funciones críticas.
5. Validar los sensores antes que los modelos.
6. Diseñar la trazabilidad desde el origen.
7. Incluir abstención y modo degradado.
8. Medir calidad física, nutricional y sanitaria.
9. Proteger la infraestructura industrial.
10. Implantar autonomía progresiva.

9.70. Conclusión: convertir la fórmula en un producto verificable

La fábrica inteligente no es aquella que dispone de más pantallas, sensores o modelos. Es aquella que puede relacionar de forma fiable cada decisión de proceso con la calidad y seguridad del producto obtenido.

La inteligencia artificial permite anticipar desgaste, predecir durabilidad, ajustar parámetros, optimizar secuencias y detectar anomalías. Puede reducir energía, mermas, finos y paradas. También puede fortalecer el control del arrastre y la trazabilidad.

Pero la fábrica de piensos no es un entorno puramente digital. Manipula materias variables, equipos sometidos a desgaste y productos destinados a organismos vivos. La predicción no elimina la necesidad de limpiar, muestrear, calibrar, inspeccionar y verificar.

Una planta convencional afirma:

La receta se ejecutó.

Una planta digitalizada afirma:

Los equipos registraron que la receta se ejecutó.

Una fábrica verdaderamente inteligente debe poder demostrar:

La receta aprobada se ejecutó con estas materias, mediante estos equipos, dentro de estos parámetros, con este nivel de incertidumbre, produjo estos atributos y fue liberada mediante estos controles.

Esa capacidad de reconstrucción es tan importante como la optimización.

La autonomía industrial responsable no consiste en retirar a las personas del proceso. Consiste en reservar su intervención para las decisiones que exigen criterio, mientras las máquinas ejecutan, vigilan y documentan aquello que puede automatizarse de forma segura.

La inteligencia artificial aportará valor cuando reduzca la distancia entre lo formulado, lo fabricado y lo realmente suministrado al animal. Será peligrosa si convierte la complejidad industrial en una puntuación opaca o si desplaza controles esenciales bajo la apariencia de una eficiencia superior.

La fábrica inteligente debe ser, antes que nada, una fábrica explicable, verificable y capaz de detenerse cuando deja de comprender lo que está ocurriendo.

10. Cadena de suministro inteligente, trazabilidad y resiliencia: del proveedor de materias primas al destino final del pienso

La eficiencia de una fábrica de piensos no depende únicamente de lo que sucede dentro de sus instalaciones. La producción está condicionada por una red extensa de proveedores agrícolas, operadores logísticos, laboratorios, almacenistas, fabricantes de aditivos, distribuidores, integradores, explotaciones ganaderas y clientes industriales. Una alteración en cualquiera de estos puntos puede afectar a la disponibilidad de materias primas, la composición nutricional, la seguridad, el coste o la continuidad del suministro.

La inteligencia artificial permite convertir esta red, tradicionalmente gestionada mediante previsiones periódicas y reacción ante incidencias, en un sistema más anticipatorio. Puede predecir demanda, detectar riesgos de abastecimiento, comparar proveedores, optimizar inventarios, seleccionar rutas logísticas y acelerar la identificación de productos afectados ante una alerta.

No obstante, una cadena de suministro no es un entorno completamente controlado. Está sometida a:

- variabilidad agrícola;
- fenómenos meteorológicos;
- conflictos comerciales;
- restricciones regulatorias;
- volatilidad energética;
- fallos portuarios;
- huelgas;
- enfermedades animales;
- crisis sanitarias;
- fraude;
- insolvencia de proveedores;
- interrupciones digitales.

La IA no elimina estas perturbaciones. Puede mejorar la capacidad para reconocerlas, evaluar sus consecuencias y seleccionar respuestas proporcionadas.

El objetivo no debe ser construir una cadena aparentemente perfecta, sino una cadena capaz de mantener funciones esenciales, explicar sus decisiones y recuperarse de los fallos sin comprometer la seguridad.

10.1. De la cadena lineal a la red de suministro

La representación tradicional describe una secuencia:

proveedor → fábrica → distribuidor → cliente

En la práctica, la estructura es una red.

Una materia prima puede proceder de múltiples orígenes. Un mismo ingrediente puede entrar por distintos puertos, almacenarse en varios centros y formar parte de numerosos productos. A su vez, un pienso puede suministrarse a diferentes especies, fases o explotaciones.

La red puede representarse como:

$$G = (V, E)$$

donde:

- (V) representa proveedores, almacenes, fábricas, silos, transportistas y clientes;
- (E) representa flujos de producto, información, dinero o responsabilidad.

El análisis de redes permite identificar:

- nodos críticos;
- proveedores concentrados;
- rutas únicas;
- dependencias ocultas;
- puntos de propagación;
- alternativas disponibles.

Una cadena que parece diversificada puede depender indirectamente de un único fabricante de premix, una sola terminal portuaria o una región productora concreta.

10.2. Visibilidad de extremo a extremo

La visibilidad no consiste únicamente en conocer dónde está un camión. Implica disponer de información suficiente sobre:

- identidad;
- origen;
- cantidad;
- calidad;
- estado;
- tiempo;
- destino;
- restricciones.

Puede definirse:

$$V = f(I, Q, T, L, S)$$

donde:

- (I): identidad;
- (Q): calidad;
- (T): tiempo;
- (L): localización;
- (S): estado.

La localización sin calidad es insuficiente. Saber que un lote llegará mañana no resuelve el problema si su humedad, perfil nutricional o situación documental son desconocidos.

La visibilidad debe incorporar tanto el flujo físico como la evidencia asociada.

10.3. Trazabilidad hacia atrás y hacia delante

Ante una incidencia, la empresa debe responder dos preguntas.

Trazabilidad hacia atrás

¿De dónde proceden los materiales incorporados?

Trazabilidad hacia delante

¿A qué productos y clientes llegaron?

La reconstrucción puede representarse mediante:

$$T^{-}(L)$$

para los antecedentes de un lote (L), y:

$$T^{+}(L)$$

para sus destinos posteriores.

La IA puede acelerar esta búsqueda mediante grafos, motores de reglas y detección de relaciones. Pero la rapidez depende de que los datos de origen sean correctos.

Una trazabilidad instantánea construida sobre identificaciones erróneas produce una respuesta rápida y falsa.

10.4. Trazabilidad de masa

La trazabilidad documental debe ser compatible con los balances físicos.

Para un ingrediente:

$$M_{\text{entrada}} = M_{\text{producto}} + M_{\text{residuo}} + M_{\text{merma}} + M_{\text{inventario}}$$

Las diferencias sostenidas pueden indicar:

- errores de registro;
- pérdidas;
- mezclas no documentadas;
- humedad;
- fraude;
- calibración incorrecta.

La IA puede detectar patrones anormales de balance antes de que la desviación sea evidente.

Pero debe considerar la incertidumbre física. No toda diferencia constituye fraude; puede deberse a variaciones de humedad, polvo o tolerancia de medición.

10.5. Genealogía de lote

La genealogía debe registrar cómo un lote se transforma.

Puede incluir:

- división;
- combinación;
- reproceso;
- purga;
- transferencia;
- reetiquetado;
- cambio de destino.

Una representación útil es el grafo dirigido:

$$L_a, L_b \rightarrow P_1 \rightarrow P_2, P_3$$

El sistema debe conservar proporciones, no solo relaciones binarias.

No es igual que un ingrediente represente el 0,01 % o el 50 % del producto. Esta información resulta esencial para estimar exposición y alcance de una retirada.

10.6. Granularidad de la trazabilidad

Una trazabilidad excesivamente agregada amplía innecesariamente una retirada. Una trazabilidad demasiado fragmentada puede resultar inviable.

La granularidad depende de:

- peligro;
- proceso;
- tamaño de lote;
- capacidad de segregación;
- sistema de producción.

Puede definirse un coste total:

$$C(g)C_{\text{registro}}(g) + C_{\text{retirada}}(g)$$

donde (g) representa la granularidad.

Una mayor granularidad aumenta el coste de captura y reduce potencialmente el alcance de las retiradas.

La decisión debe basarse en criticidad y no solo en comodidad administrativa.

10.7. Identificadores y estándares

Los sistemas pueden utilizar:

- códigos internos;

- códigos de barras;
- QR;
- RFID;
- identificadores electrónicos;
- sellos digitales.

El identificador debe permanecer asociado al material durante:

- recepción;
- almacenamiento;
- fabricación;
- expedición;
- devolución.

Un problema frecuente es la coexistencia de múltiples códigos para el mismo lote. La empresa debe mantener una correspondencia inequívoca entre:

- proveedor;
- transportista;
- sistema interno;
- cliente.

La IA puede resolver coincidencias, pero no debería sustituir una política robusta de identificación.

10.8. Interoperabilidad

La trazabilidad completa requiere intercambio entre sistemas diferentes:

- ERP;
- MES;
- LIMS;
- plataformas logísticas;
- proveedores;
- clientes;
- autoridades.

Los obstáculos incluyen:

- formatos incompatibles;
- nomenclaturas distintas;
- unidades;
- fechas;
- duplicados;
- semántica.

Dos sistemas pueden utilizar la palabra “lote” para unidades diferentes.

La interoperabilidad exige definir:

- significado;
- estructura;

- unidad;
- obligatoriedad;
- responsable.

La inteligencia artificial puede ayudar a mapear datos heterogéneos, pero las decisiones críticas necesitan reglas semánticas explícitas.

10.9. Calidad del dato externo

Los datos de terceros pueden contener:

- errores;
- retrasos;
- campos incompletos;
- cambios de formato;
- información comercialmente sesgada.

Un modelo no debe asignar la misma confianza a:

- certificado analítico;
- dato de sensor;
- declaración comercial;
- estimación;
- inferencia.

Puede utilizarse un nivel de confianza:

$$q_j \in [0,1]$$

para cada fuente.

La decisión debe considerar tanto el valor como la calidad de la evidencia.

10.10. Predicción de demanda

La demanda de pienso depende de:

- censo;
- ciclo productivo;
- estacionalidad;
- precio;
- contratos;
- sanidad;
- clima;
- mercado de productos animales.

El modelo puede estimar:

$$\hat{D}_{t+h} f(D_{t-k:t}, X_t)$$

donde (X_t) incluye variables externas.

La previsión debe producir un intervalo:

$$D_{t+h} \in [\hat{D}^-, \hat{D}^+]$$

Un único valor oculta incertidumbre y puede conducir a sobreproducción o rotura de stock.

10.11. Demanda dependiente y demanda independiente

La demanda puede ser:

Independiente

Pedido externo del cliente.

Dependiente

Necesidad de materias primas derivada del plan de producción.

La IA debe conectar ambas.

Una previsión de producto terminado debe traducirse en:

- toneladas de cereal;
- proteína;
- grasa;
- minerales;
- aditivos;
- capacidad;
- transporte.

El error se propaga. Una previsión moderadamente incorrecta de varios productos puede producir una desviación importante en un ingrediente común.

10.12. Segmentación de demanda

No todos los productos presentan el mismo patrón.

Pueden existir:

- productos regulares;
- estacionales;
- intermitentes;
- de campaña;
- bajo pedido;
- estratégicos.

Aplicar un mismo modelo a todos reduce precisión.

La clasificación puede realizarse según:

- frecuencia;

- variabilidad;
- volumen;
- criticidad;
- margen.

La elección del modelo debe adaptarse al comportamiento de cada referencia.

10.13. Demanda intermitente

Los productos especializados pueden presentar numerosos periodos sin consumo y pedidos elevados ocasionales.

La media móvil puede ser inadecuada.

El modelo debe estimar por separado:

- probabilidad de pedido;
- tamaño esperado.

$$E(D) = P(D > 0) \cdot E(D \mid D > 0)$$

La incertidumbre debe incorporarse al inventario.

10.14. Efecto látigo

Pequeñas variaciones en el consumo final pueden amplificarse aguas arriba.

El efecto látigo puede producir:

- compras excesivas;
- inventarios;
- falta de capacidad;
- oscilación de precios.

Las causas incluyen:

- previsiones aisladas;
- pedidos por lotes;
- promociones;
- miedo a escasez;
- falta de visibilidad.

Compartir información real puede reducir este efecto. Pero también requiere confianza entre empresas.

10.15. Planificación probabilística

La planificación clásica utiliza una demanda prevista. La planificación robusta considera escenarios:

$$\omega_1, \omega_2, \dots, \omega_n$$

Cada escenario puede representar:

- demanda alta;
- demanda baja;
- retraso;
- falta de ingrediente;
- subida de precio.

La decisión busca funcionar razonablemente en varios escenarios.

No debe optimizar únicamente el más probable si el escenario menos probable tiene consecuencias críticas.

10.16. Stock de seguridad

El stock de seguridad protege frente a variación de demanda y suministro.

Puede expresarse de forma simplificada:

$$SS = z\sigma_L$$

donde:

- (z) depende del nivel de servicio;
- (σ_L) es la variabilidad durante el plazo.

La IA puede actualizar esta estimación según:

- fiabilidad del proveedor;
- congestión;
- clima;
- volatilidad;
- calidad.

El stock no debe reducirse automáticamente porque el modelo prometa mayor precisión. La incertidumbre estructural sigue existiendo.

10.17. Inventario multivariable

En ingredientes no basta con conocer cantidad. Debe considerarse:

- composición;
- humedad;
- calidad;
- caducidad;
- origen;
- segregación.

Dos lotes de soja no son necesariamente equivalentes.

El inventario útil puede expresarse:

$$I_{\text{utilizable}} = \sum_j I_j \cdot A_j$$

donde (A_j) indica si el lote es apto para una fórmula o destino.

Un almacén puede disponer de gran volumen y, sin embargo, carecer del material adecuado para un producto específico.

10.18. FEFO y vida útil

Cuando existe fecha de caducidad o pérdida progresiva de actividad, la rotación debe seguir:

First Expired, First Out

La IA puede predecir vida útil remanente según:

- temperatura;
- humedad;
- tiempo;
- envase;
- estabilidad.

La vida útil dinámica puede ser más precisa que una fecha fija, pero su uso requiere validación y no debe extender arbitrariamente el periodo autorizado.

10.19. Obsolescencia

Los inventarios pueden perder valor por:

- cambio de fórmula;
- nueva regulación;
- deterioro;
- baja demanda;
- pérdida de actividad;
- cambio comercial.

El modelo puede calcular riesgo:

$$P(\text{obsolescencia} | X)$$

y proponer:

- consumo prioritario;
- reformulación;
- transferencia;
- devolución.

La recomendación debe respetar especificaciones y destinos permitidos.

10.20. Selección de proveedores

La evaluación puede incorporar:

- calidad;

- cumplimiento;
- precio;
- plazo;
- flexibilidad;
- documentación;
- incidencias;
- sostenibilidad;
- solvencia.

Una puntuación simple:

$$S_j = \sum_k w_k x_{jk}$$

puede ser útil, pero oculta compensaciones. Un precio bajo no debería compensar una deficiencia crítica de seguridad.

Los criterios esenciales deben actuar como umbrales de exclusión.

10.21. Rendimiento ajustado por riesgo

El coste de un proveedor no es solo su precio.

$$C_{\text{real}} = C_{\text{compra}} + C_{\text{control}} + C_{\text{retraso}} + C_{\text{desviación}} + C_{\text{incidencia}}$$

Un proveedor más caro puede tener menor coste total si ofrece:

- calidad estable;
- plazos fiables;
- documentación completa;
- menor variabilidad.

La IA puede estimar estos costes ocultos mediante datos históricos.

10.22. Sesgo en la evaluación de proveedores

Un proveedor con mayor volumen tendrá más incidencias absolutas. La comparación debe ajustarse por exposición:

$$\text{tasa} = \frac{\text{incidencias}}{\text{toneladas o entregas}}$$

También debe considerar gravedad. Una desviación documental menor no equivale a una contaminación.

La puntuación debe ser explicable y permitir revisión.

10.23. Proveedor nuevo

Un proveedor nuevo carece de historial.

El sistema puede utilizar:

- certificaciones;
- país;
- producto;
- auditoría;
- referencias;
- similitud con otros proveedores.

Pero esta predicción contiene alta incertidumbre.

La respuesta apropiada es aumentar control hasta acumular evidencia.

10.24. Concentración del abastecimiento

La dependencia puede medirse mediante:

$$HHI = \sum_j s_j^2$$

donde (s_j) es la participación del proveedor.

Una concentración elevada aumenta vulnerabilidad.

Pero diversificar no siempre es mejor si introduce proveedores de menor calidad. La estrategia debe equilibrar:

- continuidad;
- seguridad;
- coste;
- capacidad de sustitución.

10.25. Sustituibilidad de ingredientes

Ante una escasez, el sistema puede buscar alternativas.

La sustitución debe considerar:

- nutrientes;
- digestibilidad;
- límites;
- tecnología;
- seguridad;
- disponibilidad;
- etiquetado;
- aceptación.

Puede definirse una distancia:

$$d(i, j)w_1d_{\text{nutricional}} + w_2d_{\text{tecnológico}} + w_3d_{\text{regulatorio}} + w_4d_{\text{riesgo}}$$

La alternativa más próxima nutricionalmente puede no ser viable industrialmente.

10.26. Reformulación ante crisis

Una crisis de suministro puede requerir:

- nueva materia prima;
- cambio de concentración;
- reducción de referencias;
- priorización de clientes.

La IA puede generar escenarios, pero la reformulación debe ser revisada por nutrición, calidad, compras y producción.

La urgencia no elimina la necesidad de validación.

10.27. Riesgo geopolítico y comercial

Las materias primas agrícolas están expuestas a:

- aranceles;
- sanciones;
- cierres;
- conflictos;
- restricciones de exportación;
- cambios monetarios.

El modelo puede integrar indicadores externos y estimar riesgo de interrupción.

Pero estos eventos tienen baja frecuencia y alta consecuencia. Los datos históricos pueden ser insuficientes.

La planificación debe incorporar escenarios expertos además de modelos estadísticos.

10.28. Riesgo climático

El clima puede afectar:

- rendimiento agrícola;
- calidad;
- micotoxinas;
- humedad;
- transporte;
- precio.

Una sequía puede reducir disponibilidad y aumentar concentración de determinados contaminantes. Una cosecha abundante puede saturar almacenamiento.

La IA debe conectar la previsión agronómica con:

- compras;
- control;
- formulación;

- inventario.

10.29. Predicción de precio

Los precios dependen de múltiples factores.

El modelo puede utilizar:

- futuros;
- cosechas;
- inventarios;
- energía;
- transporte;
- divisas;
- demanda.

Sin embargo, las predicciones de mercado son altamente inestables.

La empresa debe utilizar rangos y escenarios, no tratar la predicción como certeza.

10.30. Cobertura y compras

La IA puede apoyar decisiones sobre:

- compra física;
- contratos;
- coberturas;
- momento.

Pero estas decisiones implican riesgo financiero y deben estar sujetas a políticas autorizadas.

El modelo no debe ejecutar operaciones fuera de límites definidos.

10.31. Logística de entrada

La recepción debe coordinar:

- cita;
- capacidad;
- silo;
- descarga;
- análisis;
- limpieza;
- documentación.

La IA puede reducir esperas y congestión.

Una planificación óptima debe considerar que un camión puede quedar bloqueado por:

- resultado pendiente;
- silo ocupado;

- material incorrecto;
- avería.

La agenda debe incluir capacidad de absorción de incidencias.

10.32. Optimización de rutas

Para la distribución pueden optimizarse:

- distancia;
- capacidad;
- ventanas;
- restricciones;
- limpieza;
- compatibilidad.

El problema puede formularse:

$$\min C_{\text{distancia}} + C_{\text{tiempo}} + C_{\text{riesgo}}$$

sujeto a requisitos de entrega.

La ruta más corta no siempre es la más segura si implica cargar productos incompatibles en secuencia.

10.33. Compartimentos y secuencia de entrega

Los vehículos pueden transportar varios productos.

La planificación debe considerar:

- compartimentos;
- orden de descarga;
- contaminación cruzada;
- estabilidad;
- cliente.

Una mala secuencia puede hacer inaccesible el producto que debe entregarse primero o aumentar el arrastre.

La optimización debe incluir la geometría y operación real del vehículo.

10.34. Limpieza de transporte

La limpieza depende del producto anterior y del siguiente.

El sistema debe conocer:

- historial;
- compartimento;
- método;
- certificado;

- inspección.

La IA puede asignar nivel de limpieza, pero las incompatibilidades críticas deben estar codificadas mediante reglas obligatorias.

10.35. Transporte y condiciones ambientales

Durante el transporte pueden producirse:

- humedad;
- condensación;
- calentamiento;
- rotura;
- separación;
- contaminación.

Los sensores pueden registrar:

- temperatura;
- humedad;
- apertura;
- ubicación;
- vibración.

Las alarmas deben distinguir entre desviaciones leves y condiciones capaces de comprometer el producto.

10.36. Cadena de custodia

En situaciones críticas, debe demostrarse quién tuvo control del material en cada momento.

La cadena de custodia incluye:

- entrega;
- recepción;
- precinto;
- apertura;
- transferencia;
- muestra.

Es especialmente relevante para:

- investigación;
- fraude;
- muestras oficiales;
- reclamaciones.

La tecnología puede reforzarla, pero no sustituye la disciplina documental.

10.37. Blockchain y registros distribuidos

Los registros distribuidos se proponen para mejorar la inmutabilidad.

Pueden aportar:

- sello temporal;
- registro compartido;
- dificultad de modificación.

Pero no garantizan que el dato inicial sea correcto.

dato falso + registro inmutable = falsedad permanente

La principal dificultad sigue siendo verificar la relación entre evento físico y registro digital.

10.38. Contratos inteligentes

Un contrato inteligente puede ejecutar acciones cuando se cumplen condiciones:

- recepción;
- análisis;
- entrega;
- pago.

Su utilidad depende de que las condiciones sean objetivas y fiables.

No es adecuado para resolver automáticamente situaciones que requieren interpretación, como una desviación controvertida o una causa de fuerza mayor.

10.39. Detección de fraude documental

La IA puede comparar:

- certificados;
- facturas;
- lotes;
- pesos;
- fechas;
- firmas;
- formatos.

Puede detectar:

- duplicados;
- alteraciones;
- inconsistencias;
- documentos atípicos.

La detección debe iniciar verificación. No debe acusarse a un proveedor exclusivamente por una puntuación algorítmica.

10.40. Riesgo de documentación sintética

La IA generativa facilita crear documentos aparentemente válidos.

Los sistemas deben reforzar:

- autenticidad;
- firma;
- origen;
- consistencia;
- verificación directa.

La apariencia profesional deja de ser evidencia suficiente.

10.41. Monitorización de noticias y señales externas

Los sistemas pueden analizar:

- alertas;
- prensa;
- meteorología;
- mercados;
- cierres;
- cambios legales.

El objetivo es detectar señales tempranas.

Pero la información externa puede ser:

- errónea;
- repetida;
- descontextualizada;
- manipulada.

La empresa debe establecer una jerarquía de fuentes y verificación.

10.42. Control de versiones regulatorias

Los requisitos pueden cambiar según:

- país;
- especie;
- producto;
- fecha.

Una base regulatoria debe conservar:

- norma;
- versión;
- vigencia;
- territorio;
- interpretación aprobada.

La IA puede buscar y resumir, pero la decisión de cumplimiento requiere fuentes oficiales y revisión competente.

10.43. Gestión dinámica de restricciones

Las restricciones de distribución pueden incluir:

- especies;
- edades;
- mercados;
- formulaciones;
- sustancias;
- periodos.

El sistema debe impedir que un producto sea enviado a un destino no autorizado.

Estas reglas deben estar separadas del modelo predictivo. No deberían depender de probabilidades.

10.44. Priorización de clientes en escasez

Cuando no existe producto suficiente, la empresa debe definir criterios.

Pueden incluir:

- bienestar animal;
- continuidad de explotación;
- contrato;
- riesgo sanitario;
- existencia de alternativas.

La decisión no debe basarse únicamente en margen.

Los criterios deben aprobarse antes de la crisis.

10.45. Servicio y continuidad nutricional

Una entrega tardía puede obligar al cliente a:

- cambiar dieta;
- reducir fases;
- comprar emergencia;
- alterar transición.

Esto puede afectar producción y salud.

El indicador de servicio debe incluir:

- puntualidad;
- cantidad;
- producto correcto;
- continuidad.

No basta con medir pedidos entregados.

10.46. Predicción de incumplimiento de entrega

El modelo puede utilizar:

- estado de producción;
- disponibilidad;
- tráfico;
- clima;
- vehículo;
- historial.

La probabilidad:

$$P(\text{retraso} > \tau \mid X)$$

permite actuar antes:

- reasignar;
- informar;
- producir;
- buscar alternativa.

La comunicación temprana puede reducir el impacto incluso cuando el retraso no pueda evitarse.

10.47. Gestión de reclamaciones

Las reclamaciones proporcionan datos sobre:

- calidad;
- palatabilidad;
- finos;
- retrasos;
- resultados.

La IA puede agrupar textos y detectar patrones.

Pero debe distinguir entre:

- defecto real;
- expectativa;
- problema de manejo;
- incidencia sanitaria;
- formulación.

El análisis automático no sustituye investigación técnica.

10.48. Vinculación entre reclamación y lote

La trazabilidad debe identificar:

- lote;

- entrega;
- vehículo;
- silo cliente;
- fecha;
- consumo.

La ausencia de identificación puede obligar a ampliar la investigación.

El sistema debe registrar también si el producto fue mezclado, almacenado o transferido después de la entrega.

10.49. Retirada de producto

La retirada requiere:

1. identificar peligro;
2. bloquear inventario;
3. determinar lotes;
4. localizar clientes;
5. comunicar;
6. recuperar;
7. verificar;
8. investigar.

La IA puede acelerar el análisis de alcance.

Pero la decisión debe ser conservadora cuando existan datos incompletos.

10.50. Alcance mínimo seguro

El objetivo no es retirar la menor cantidad posible, sino la menor cantidad que permita asegurar control del riesgo.

Puede definirse:

$$R(S)P(\text{producto afectado fuera de } S)$$

donde (S) es el conjunto retirado.

Debe elegirse un (S) que mantenga el riesgo residual por debajo del nivel aceptable.

Reducir el alcance por motivos económicos sin evidencia suficiente puede dejar producto afectado en el mercado.

10.51. Simulación de retirada

La empresa debe realizar ejercicios periódicos.

Debe medir:

- tiempo de identificación;

- porcentaje localizado;
- contactos;
- precisión;
- conciliación de cantidades.

La simulación debe incluir escenarios complejos:

- reproceso;
- mezcla;
- distribución internacional;
- datos incompletos.

10.52. Trazabilidad temporal

No basta con conocer qué lotes están relacionados. Debe determinarse si coincidieron en el tiempo.

Una materia prima no puede afectar a un producto fabricado antes de su recepción.

La temporalidad permite excluir relaciones falsas.

La base debe registrar marcas de tiempo coherentes y zonas horarias cuando existan operaciones internacionales.

10.53. Riesgo de relojes desincronizados

Sistemas distintos pueden registrar horas diferentes.

Esto puede alterar:

- secuencia;
- custodia;
- interpretación.

La sincronización debe ser una medida de integridad.

El sistema debe detectar marcas imposibles, como una descarga registrada antes de la llegada.

10.54. Gestión de devoluciones

El producto devuelto debe evaluarse antes de:

- reexpedir;
- reprocesar;
- destruir.

La IA puede estimar riesgo según:

- causa;
- tiempo;
- almacenamiento;
- integridad;

- trazabilidad.

Pero un producto fuera del control de la empresa requiere especial precaución.

No debería reincorporarse automáticamente por razones de coste.

10.55. Circularidad y trazabilidad

Los coproductos y materias circulares pueden aumentar la complejidad por:

- variabilidad;
- múltiples orígenes;
- procesos previos;
- contaminantes;
- estabilidad.

La trazabilidad debe registrar la historia del material antes de convertirse en ingrediente.

La circularidad no debe reducir los requisitos de evidencia.

10.56. Resiliencia

La resiliencia es la capacidad para:

- anticipar;
- absorber;
- adaptarse;
- recuperarse.

Puede representarse mediante:

$$R = f(P, A, D, C)$$

donde:

- (P): preparación;
- (A): absorción;
- (D): adaptación;
- (C): recuperación.

Una cadena eficiente en condiciones normales puede ser frágil ante perturbaciones.

10.57. Redundancia frente a eficiencia

Reducir inventarios, proveedores y capacidad ociosa mejora eficiencia aparente.

Pero puede aumentar vulnerabilidad.

La empresa debe decidir qué redundancias conservar:

- proveedor alternativo;

- stock;
- línea;
- transporte;
- energía;
- datos.

La redundancia estratégica no es necesariamente desperdicio; puede ser una reserva de continuidad.

10.58. Tiempo de recuperación

Un indicador clave es:

TTR = tiempo hasta restablecer capacidad

También debe medirse:

TTS = tiempo hasta quedar sin suministro

Si:

$$TTR > TTS$$

la interrupción afectará necesariamente al servicio.

La estrategia debe reducir (TTR), aumentar (TTS) o ambas.

10.59. Mapas de dependencia

La empresa debe identificar:

- ingredientes únicos;
- proveedores únicos;
- equipos únicos;
- rutas únicas;
- conocimientos únicos;
- sistemas digitales únicos.

Un proveedor puede tener alternativas aparentes que dependen del mismo origen.

El análisis debe alcanzar varios niveles de la cadena.

10.60. Escenarios de estrés

Deben simularse:

- cierre de puerto;
- pérdida de proveedor;
- contaminación;
- fallo informático;
- subida energética;
- brote animal;

- restricción legal.

Para cada escenario:

- impacto;
- tiempo;
- alternativas;
- responsables;
- comunicación.

La IA puede generar y evaluar escenarios, pero las hipótesis deben revisarse por especialistas.

10.61. Control humano en crisis

Durante una crisis existe presión por automatizar decisiones.

Sin embargo, los datos pueden ser incompletos y el entorno cambia rápidamente.

La IA debe presentar:

- escenarios;
- probabilidades;
- consecuencias;
- restricciones.

La dirección debe conservar autoridad sobre decisiones estratégicas, regulatorias y reputacionales.

10.62. Comunicación de riesgo

Una comunicación incorrecta puede amplificar el daño.

Debe ser:

- precisa;
- oportuna;
- coherente;
- documentada.

La IA generativa puede ayudar a adaptar mensajes, pero debe evitar:

- minimizar;
- exagerar;
- inventar;
- atribuir causas no demostradas.

La aprobación humana resulta imprescindible.

10.63. Ciberresiliencia

Una cadena conectada depende de:

- plataformas;
- comunicaciones;
- proveedores cloud;
- interfaces.

Un incidente puede bloquear:

- pedidos;
- trazabilidad;
- producción;
- expedición.

Deben existir:

- copias;
- datos esenciales offline;
- procedimientos manuales;
- contactos alternativos;
- pruebas de recuperación.

10.64. Dependencia del proveedor tecnológico

Una plataforma puede convertirse en un punto único de fallo.

La empresa debe asegurar:

- exportación de datos;
- documentación;
- continuidad;
- acceso a históricos;
- propiedad;
- procedimiento de salida.

El conocimiento del proceso no puede quedar encerrado en una aplicación.

10.65. Gobernanza de datos compartidos

Cuando varias empresas comparten datos, debe definirse:

- finalidad;
- propiedad;
- acceso;
- uso secundario;
- conservación;
- responsabilidad.

Un proveedor puede aceptar compartir calidad para mejorar previsiones, pero no para que su información se utilice en negociación sin transparencia.

La confianza es una infraestructura de la cadena tanto como los sistemas tecnológicos.

10.66. Confidencialidad y competencia

Los datos de demanda, precio y capacidad son sensibles.

La agregación y el aprendizaje colaborativo deben diseñarse para evitar:

- revelación;
- inferencias;
- usos anticompetitivos.

La eficiencia no justifica compartir indiscriminadamente información comercial.

10.67. Indicadores de la cadena inteligente

Tabla 16. Síntesis de dimensión y indicador.

Dimensión	Indicador
Servicio	Entrega completa y puntual
Previsión	Error y sesgo
Inventario	Rotación y cobertura
Calidad	Incidencias por tonelada
Proveedores	Cumplimiento ajustado por riesgo
Trazabilidad	Tiempo de reconstrucción
Retirada	Porcentaje localizado
Resiliencia	TTR y TTS
Logística	Coste y kilómetros
Sostenibilidad	Emisiones por tonelada
Datos	Registros completos
IA	Calibración y deriva

10.68. Modelo de madurez

Nivel 1. Registro fragmentado

Información distribuida en documentos y sistemas aislados.

Nivel 2. Trazabilidad digital

Identidad y movimientos centralizados.

Nivel 3. Visibilidad

Estado e inventario actualizados.

Nivel 4. Predicción

Demanda, retrasos y riesgos estimados.

Nivel 5. Optimización

Inventario, compras y rutas coordinados.

Nivel 6. Resiliencia adaptativa

Escenarios, alternativas y respuesta dinámica.

La madurez no se mide por el número de conexiones, sino por la capacidad para mantener el control durante una perturbación.

10.69. Principios de diseño responsable

1. La trazabilidad física debe preceder a la sofisticación analítica.
2. Toda identidad debe ser inequívoca.
3. Los balances deben reconciliar datos y masa.
4. Las previsiones deben incluir incertidumbre.
5. Los criterios críticos no deben compensarse con precio.
6. La sustitución de ingredientes requiere validación integral.
7. Las retiradas deben priorizar seguridad.
8. La resiliencia exige redundancia selectiva.
9. Los datos externos deben ponderarse por calidad.
10. La IA debe apoyar, no monopolizar, la gestión de crisis.

10.70. Conclusión: una cadena inteligente debe recordar, anticipar y resistir

La inteligencia artificial puede transformar la cadena de suministro de piensos al conectar demanda, materias primas, fabricación, transporte y destino. Puede anticipar escasez, optimizar inventarios, evaluar proveedores, seleccionar rutas y reconstruir rápidamente la genealogía de un producto.

Pero la velocidad de análisis no compensa una identidad incorrecta ni una captura incompleta. La trazabilidad no se crea en el momento de la crisis; se construye en cada recepción, transferencia, mezcla, carga y entrega.

Una cadena verdaderamente inteligente debe ser capaz de recordar con precisión lo que ocurrió, anticipar razonablemente lo que puede ocurrir y resistir cuando las predicciones fracasan.

La eficiencia persigue eliminar excedentes. La resiliencia conserva capacidades que pueden parecer innecesarias hasta que se produce una interrupción. La dirección responsable debe equilibrar ambas.

El valor de la IA no reside en prometer una cadena sin fallos, sino en permitir reconocer antes sus fragilidades, comprender mejor sus dependencias y responder con menor improvisación.

Cuando aparezca una crisis, el sistema deberá poder contestar:

- qué ha ocurrido;
- qué productos están afectados;
- dónde se encuentran;
- qué alternativas existen;

- cuánto tiempo puede mantenerse el suministro;
- qué decisiones son seguras;
- qué incertidumbres permanecen.

Esa capacidad de respuesta constituye el verdadero criterio de inteligencia de una cadena de suministro destinada a alimentar animales y, de forma indirecta, a sostener una parte esencial del sistema alimentario.

11. Inteligencia artificial, sostenibilidad y huella ambiental de la nutrición animal: medir, atribuir y reducir sin desplazar impactos

La sostenibilidad se ha convertido en uno de los principales vectores de transformación de la industria de alimentación animal. La presión procede simultáneamente de la regulación, los mercados, las cadenas alimentarias, las entidades financieras, los consumidores y la propia necesidad de mantener la producción dentro de límites ambientales compatibles con la disponibilidad de recursos.

La nutrición animal ocupa una posición central en esta transición porque condiciona una parte importante de:

- las emisiones asociadas a la producción de materias primas;
- la utilización del suelo;
- el consumo de agua;
- la excreción de nitrógeno y fósforo;
- las emisiones entéricas;
- la gestión de estiércoles;
- la eficiencia productiva;
- la conversión de biomasa no consumible por el ser humano;
- la huella final de carne, leche, huevos, pescado y alimentos para animales de compañía.

La inteligencia artificial puede contribuir a integrar estos factores y a identificar combinaciones de ingredientes, procesos y estrategias alimentarias que reduzcan impactos sin comprometer la salud, el bienestar o la seguridad.

Sin embargo, la sostenibilidad algorítmica presenta un riesgo conceptual importante: optimizar aquello que resulta fácil de medir y desplazar el impacto hacia variables menos visibles.

Una dieta puede reducir la huella de carbono por kilogramo de pienso y aumentar la excreción de fósforo. Una materia prima circular puede disminuir la competencia con alimentación humana, pero presentar mayor variabilidad o necesidad de secado. Un aditivo puede reducir metano por unidad de producto y aumentar el coste, la dependencia tecnológica o la huella de fabricación.

La inteligencia artificial solo puede optimizar los objetivos y límites que se incorporan al modelo. Si una dimensión ambiental queda fuera, el sistema puede actuar como si no existiera.

La sostenibilidad no debe tratarse como una puntuación única, sino como un conjunto de impactos relacionados, parcialmente compensables y sometidos a restricciones biológicas, sociales, económicas y regulatorias.

11.1. La nutrición como palanca ambiental

El alimento suministrado determina:

- cantidad de recursos utilizados;
- eficiencia de conversión;
- nutrientes retenidos;
- nutrientes excretados;
- fermentaciones;

- emisiones;
- duración del ciclo productivo.

Puede expresarse un balance simplificado:

$$N_{\text{ingerido}} - N_{\text{retenido}} + N_{\text{excretado}} + N_{\text{pérdidas}}$$

La nutrición de precisión busca aumentar la fracción retenida y reducir el exceso.

Pero una mayor retención no garantiza automáticamente menor impacto total. Si el ingrediente utilizado para conseguirla presenta una huella de producción elevada, la mejora biológica puede verse parcialmente compensada.

Por ello, la sostenibilidad debe evaluarse desde la materia prima hasta el producto animal.

11.2. Eficiencia productiva y eficiencia ambiental

La eficiencia productiva puede medirse mediante:

$$FCR = \frac{\text{alimento consumido}}{\text{ganancia o producto}}$$

Una reducción del índice de conversión suele disminuir el impacto por unidad de producto porque se necesita menos alimento.

Sin embargo, el FCR no describe:

- origen del alimento;
- emisiones;
- uso de suelo;
- consumo de agua;
- excreción;
- biodiversidad.

Dos dietas con igual conversión pueden presentar perfiles ambientales muy diferentes.

La eficiencia ambiental requiere ampliar la función:

$$E_{\text{ambiental}} f(FCR, C, L, W, N, P, M)$$

donde:

- (C): carbono;
- (L): uso de suelo;
- (W): agua;
- (N): nitrógeno;
- (P): fósforo;
- (M): metano u otras emisiones.

11.3. Huella absoluta e intensidad ambiental

Debe distinguirse entre:

Impacto absoluto

Cantidad total emitida o utilizada.

Intensidad

Impacto por unidad de producto.

$$I_c = \frac{\text{kg CO}_2\text{e}}{\text{kg de producto}}$$

Una empresa puede reducir la intensidad y aumentar las emisiones absolutas si crece suficientemente el volumen.

Ambos indicadores son necesarios.

La comunicación exclusiva de intensidad puede ocultar un incremento total. La comunicación exclusiva de valores absolutos puede penalizar el crecimiento eficiente.

11.4. Análisis de ciclo de vida

El análisis de ciclo de vida permite evaluar impactos desde la extracción o producción de recursos hasta un límite definido.

En alimentación animal puede abarcar:

1. producción agrícola;
2. transformación;
3. transporte;
4. fabricación;
5. distribución;
6. consumo por el animal;
7. gestión de excretas;
8. producción animal.

El resultado depende de la frontera.

Una evaluación “de la cuna a la puerta de la fábrica” no incluye las diferencias de digestibilidad o emisiones del animal. Una evaluación hasta la explotación puede omitir procesado posterior y distribución del alimento humano.

Toda cifra ambiental debe declarar su frontera.

11.5. Unidad funcional

La unidad funcional define qué se compara.

Puede ser:

- una tonelada de pienso;
- un kilogramo de proteína digestible;
- un kilogramo de peso vivo;
- un litro de leche;
- un kilogramo de huevo;
- un kilogramo de pescado producido.

La selección modifica el resultado.

Una materia prima puede presentar baja huella por kilogramo y elevada huella por unidad de proteína digestible.

Para nutrición, las unidades basadas únicamente en masa pueden ser insuficientes.

Puede utilizarse:

$$I_{\text{proteína}} \frac{\text{impacto}}{\text{kg de proteína digestible}}$$

o una función que incorpore varios nutrientes.

11.6. Asignación de impactos

Muchos ingredientes son coproductos:

- salvados;
- pulpas;
- harinas;
- tortas;
- subproductos lácteos;
- coproductos de fermentación.

El impacto del proceso debe repartirse entre productos.

Los métodos incluyen:

- asignación económica;
- masa;
- energía;
- expansión del sistema.

Cada método puede producir resultados distintos.

La inteligencia artificial no resuelve esta decisión normativa. Puede calcular escenarios, pero la asignación debe declararse y justificarse.

11.7. Calidad de los inventarios ambientales

Los modelos necesitan datos sobre:

- fertilización;
- rendimiento;
- energía;
- transporte;
- secado;
- cambio de uso del suelo;
- emisiones;
- procesado.

Estos datos pueden ser:

- primarios;
- secundarios;
- regionales;
- estimados;
- antiguos;
- genéricos.

Debe asociarse una calidad:

$$q_i = f(\text{edad, geografía, tecnología, representatividad})$$

No debería presentarse con la misma precisión una cifra procedente de datos específicos del proveedor y otra basada en una media continental.

11.8. Incertidumbre ambiental

La huella no es un valor exacto.

Puede representarse:

$$C \sim P(\mu, \sigma)$$

Las fuentes de incertidumbre incluyen:

- rendimiento agrícola;
- fertilización;
- origen;
- transporte;
- asignación;
- cambio de uso del suelo;
- digestibilidad;
- respuesta animal.

La comparación entre dos dietas debe considerar si la diferencia supera la incertidumbre.

Si:

$$|\mu_A - \mu_B| < U_A + U_B$$

no existe base sólida para afirmar una superioridad inequívoca.

11.9. Análisis de sensibilidad

El análisis de sensibilidad identifica qué variables dominan el resultado:

$$S_i = \frac{\partial Y}{\partial X_i}$$

Puede revelar que la huella depende principalmente de:

- origen de la soja;
- fertilizante;
- energía de secado;
- conversión;
- metano.

Esto permite priorizar datos y acciones.

La IA puede utilizar métodos globales para explorar relaciones no lineales, pero la interpretación debe seguir vinculada a mecanismos físicos.

11.10. Emisiones de gases de efecto invernadero

Las emisiones pueden incluir:

- dióxido de carbono;
- metano;
- óxido nitroso.

Se expresan habitualmente como:

$$CO_2e = CO_2 + GWP_{CH_4}CH_4 + GWP_{N_2O}N_2O$$

Los factores de equivalencia dependen del horizonte temporal y del marco utilizado.

Las comparaciones deben utilizar la misma metodología.

No es correcto combinar cifras construidas con factores o periodos diferentes sin normalización.

11.11. Emisiones de la producción agrícola

Las materias primas pueden incorporar emisiones de:

- fertilizantes;
- maquinaria;
- riego;
- secado;
- transformación;
- transporte;
- cambio de uso del suelo.

La variabilidad dentro de un mismo ingrediente puede ser mayor que la diferencia entre ingredientes.

Por ello, la denominación “maíz”, “soja” o “trigo” no constituye una huella única.

La inteligencia artificial puede estimar impactos por lote a partir de:

- origen;
- campaña;
- rendimiento;
- prácticas;
- transporte;
- energía.

Pero el resultado debe diferenciar datos observados de inferencias.

11.12. Cambio directo e indirecto de uso del suelo

El cambio directo ocurre cuando un terreno se transforma para producir una materia prima.

El cambio indirecto intenta estimar desplazamientos de producción causados por la demanda.

Ambos presentan alta complejidad.

Los resultados dependen de:

- modelos económicos;
- supuestos;
- horizonte;
- región.

La IA puede manejar grandes modelos, pero no elimina la controversia metodológica.

Las cifras deben comunicarse como escenarios y no como propiedades intrínsecas inmutables.

11.13. Carbono biogénico

Los flujos de carbono biogénico requieren tratamiento diferenciado según:

- origen;
- almacenamiento;
- uso;
- liberación;
- temporalidad.

La utilización de biomasa no implica automáticamente neutralidad climática.

El sistema debe contabilizar:

- emisiones de producción;
- transformación;
- transporte;
- oportunidad de uso;
- cambios de reservas.

11.14. Metano entérico

En rumiantes, el metano se produce durante la fermentación.

Puede estimarse:

$$CH_4 = f(\text{ingestión, fibra, digestibilidad, grasa, microbiota, producción})$$

Las estrategias nutricionales pueden incluir:

- mejora de digestibilidad;
- grasas;
- aditivos;
- ajuste de forraje;
- mayor productividad.

La reducción debe medirse en términos absolutos y por unidad de producto.

Un animal puede emitir más metano al día y menos por litro de leche si produce considerablemente más.

11.15. Persistencia de la reducción de metano

Un efecto observado durante semanas puede disminuir por:

- adaptación microbiana;
- variación de consumo;
- cambio de dieta;
- pérdida de actividad;
- incumplimiento de dosis.

Los modelos deben considerar duración.

La reducción anual no debe extrapolarse desde un ensayo corto sin evaluar persistencia.

11.16. Efectos secundarios de los mitigadores

Un aditivo reductor de metano debe evaluarse respecto de:

- consumo;
- digestibilidad;
- producción;
- salud;
- residuos;
- coste;
- fabricación;
- estabilidad.

La función no debe ser:

$$\text{min}CH_4$$

sino:

$$\min CH_4$$

sujeto a:

salud adecuada

11.17. Nitrógeno

El exceso de proteína o aminoácidos aumenta nitrógeno excretado.

El balance puede expresarse:

$$N_{\text{retenido}} = N_{\text{ingerido}} - N_{\text{fecal}} - N_{\text{urinario}}$$

La reducción de proteína bruta, acompañada de aminoácidos correctamente equilibrados, puede disminuir excreción.

Pero una reducción excesiva puede comprometer:

- crecimiento;
- inmunidad;
- producción;
- recuperación.

La IA puede ajustar el suministro con mayor precisión, pero debe modelar incertidumbre en necesidades y materias primas.

11.18. Forma de excreción del nitrógeno

No toda excreción tiene el mismo efecto.

El nitrógeno urinario puede transformarse más fácilmente en amoníaco y óxido nitroso que determinadas fracciones fecales.

La nutrición puede modificar:

- cantidad;
- proporción;
- pH;
- fermentación.

El análisis ambiental debe ir más allá del nitrógeno total.

11.19. Amoníaco

Las emisiones de amoníaco dependen de:

- nitrógeno urinario;
- pH;

- temperatura;
- humedad;
- ventilación;
- manejo de estiércol.

La dieta es una de varias palancas.

Un modelo puede predecir:

$$NH_3 = f(N_w, pH, T, H, M)$$

La reducción de proteína puede ser eficaz, pero no compensará una gestión deficiente del estiércol.

11.20. Fósforo

El fósforo no digestible se excreta y puede contribuir a eutrofización.

La estrategia incluye:

- evaluación de fósforo digestible;
- fitasas;
- ajuste por especie y fase;
- control de materias.

El balance:

$$P_{\text{excretado}} = P_{\text{ingerido}} - P_{\text{retenido}}$$

La suplementación con márgenes excesivos puede reducir riesgo nutricional inmediato y aumentar impacto ambiental.

La formulación probabilística permite ajustar el margen a la incertidumbre real.

11.21. Enzimas y matriz ambiental

Las enzimas pueden mejorar disponibilidad y reducir necesidad de nutrientes suplementarios.

Su valor ambiental depende de:

- sustrato;
- actividad;
- dosis;
- estabilidad;
- respuesta;
- reformulación efectiva.

Añadir una enzima sin reducir nutrientes de la fórmula puede no generar toda la reducción ambiental prevista.

Debe diferenciarse entre:

- efecto biológico potencial;
- crédito de matriz aplicado;
- resultado real.

11.22. Minerales traza

Los minerales traza son esenciales, pero su exceso puede acumularse en suelos.

La precisión debe considerar:

- biodisponibilidad;
- fuente;
- antagonismos;
- margen;
- especie.

Una fuente más biodisponible puede permitir menor inclusión. Sin embargo, la evaluación debe incluir la huella de producción y no solo la excreción.

11.23. Agua

La huella hídrica puede distinguir:

- agua azul;
- agua verde;
- agua gris.

Su relevancia depende del lugar.

Un litro consumido en una región con abundancia no tiene el mismo impacto que en una cuenca con estrés hídrico.

La IA debe utilizar factores regionalizados.

La suma de litros sin contexto puede inducir a decisiones equivocadas.

11.24. Uso de suelo

El uso de suelo puede medirse en:

- superficie;
- tiempo;
- calidad;
- transformación;
- ocupación.

Una materia prima con alto rendimiento puede utilizar menos superficie por tonelada, pero presentar mayor intensidad de insumos.

El análisis debe considerar:

- productividad;
- biodiversidad;
- carbono;
- erosión;
- alternativas.

11.25. Biodiversidad

La biodiversidad es difícil de reducir a una cifra.

Los impactos pueden proceder de:

- cambio de uso;
- intensificación;
- pesticidas;
- fragmentación;
- extracción marina;
- introducción de especies.

Los modelos pueden utilizar indicadores de riesgo, pero deben evitar afirmar precisión superior a los datos.

La ausencia de una métrica perfecta no justifica excluir la biodiversidad.

11.26. Acidificación y eutrofización

Las emisiones de:

- amoníaco;
- óxidos de nitrógeno;
- fósforo;
- nitratos;

contribuyen a acidificación y eutrofización.

Una estrategia climáticamente favorable puede empeorar estas categorías.

La optimización debe conservar varias dimensiones:

$$J = w_C C + w_E E + w_A A$$

donde:

- (C): cambio climático;
- (E): eutrofización;
- (A): acidificación.

Pero los pesos no deberían ocultar umbrales críticos.

11.27. Materias primas circulares

La alimentación animal puede valorizar:

- coproductos;
- excedentes;
- subproductos;
- corrientes de fabricación;
- biomasa no apta para consumo humano.

Esta función circular reduce residuos y competencia directa por alimentos.

Pero las materias circulares pueden presentar:

- variabilidad;
- humedad;
- inestabilidad;
- contaminantes;
- logística compleja;
- menor densidad.

La circularidad debe demostrarse mediante balance completo.

Un coproducto que requiere secado intensivo y transporte prolongado puede perder parte de su ventaja.

11.28. Jerarquía de valorización

No todo residuo debe destinarse automáticamente a alimentación animal.

La decisión debe evaluar:

- seguridad;
- valor nutricional;
- uso alternativo;
- procesamiento;
- estabilidad.

La IA puede comparar rutas:

$$U_r = V_{\text{nutricional}} C_{\text{proceso}} R_{\text{seguridad}} I_{\text{ambiental}}$$

La valorización no debe introducir peligros en la cadena alimentaria.

11.29. Competencia alimento-pienso

La comparación entre alimentos utilizados por humanos y animales requiere matices.

No todo ingrediente es directamente consumible por personas. Además, los animales pueden convertir:

- pastos;
- fibras;

- coproductos;

en alimentos de alto valor nutricional.

Pueden utilizarse indicadores como:

$$FCR_{\text{humano}} \frac{\text{proteína potencialmente comestible}}{\text{proteína animal producida}}$$

Pero dependen de:

- definición de comestibilidad;
- calidad proteica;
- mercado;
- región.

La IA debe evitar clasificaciones universales.

11.30. Calidad nutricional del producto final

La sostenibilidad no debe evaluarse únicamente por masa.

Un producto animal aporta:

- proteína;
- aminoácidos;
- micronutrientes;
- energía;
- funcionalidad.

Comparar productos solo por kilogramo puede ignorar diferencias nutricionales.

Sin embargo, incorporar calidad nutricional no debe utilizarse para excluir impactos ambientales.

Ambas dimensiones deben mostrarse.

11.31. Formulación de mínimo impacto

La formulación puede incorporar coeficientes ambientales:

$$\min \sum_i c_i x_i + \lambda \sum_i e_i x_i$$

donde:

- (c_i): coste;
- (e_i): impacto;
- (x_i): inclusión.

Pero una única penalización (λ) traduce el impacto a una preferencia económica.

Puede resultar más transparente establecer límites:

$$\sum_i e_i x_i \leq E_{\max}$$

y comparar costes dentro de ese límite.

11.32. Frontera de Pareto

En problemas multiobjetivo no suele existir una solución óptima única.

Una solución es Pareto-óptima si no puede mejorarse un objetivo sin empeorar otro.

La frontera puede mostrar alternativas:

- menor coste;
- menor carbono;
- menor nitrógeno;
- mayor circularidad.

La decisión corresponde a la organización, dentro de límites obligatorios.

La IA debe presentar las compensaciones, no ocultarlas en una puntuación.

11.33. Restricciones no compensables

Ciertos criterios deben actuar como límites:

- seguridad;
- salud;
- requisitos nutricionales;
- máximos legales;
- bienestar.

No puede aceptarse una dieta insegura porque tenga menor huella.

La estructura correcta es:

$$\min J_{\text{ambiental}}$$

sujeto a:

$$X \in \Omega_{\text{segura}}$$

11.34. Formulación robusta

Los impactos ambientales de los ingredientes son variables.

Una formulación robusta busca buen desempeño bajo varios escenarios:

$$\min_x \max_{\omega} J(x, \omega)$$

Esto evita seleccionar una dieta aparentemente excelente basada en un factor ambiental muy incierto.

La robustez puede incrementar ligeramente el coste o la huella media, pero reducir el riesgo de resultados extremos.

11.35. Actualización por lote

Si se dispone de origen y proceso, el factor ambiental puede actualizarse por lote:

$$e_{i,l}f(\text{origen, transporte, campaña, energía})$$

Esto mejora precisión frente a valores genéricos.

Pero aumenta dependencia de datos externos y riesgo de inconsistencias.

La metodología debe ser estable para permitir comparación temporal.

11.36. Compra con criterios ambientales

La compra puede incorporar:

- huella;
- certificaciones;
- trazabilidad;
- riesgo de deforestación;
- prácticas;
- distancia.

La puntuación no debe depender exclusivamente de declaraciones del proveedor.

Debe definirse evidencia mínima:

- datos verificados;
- metodología;
- periodo;
- alcance;
- auditoría.

11.37. Riesgo de fuga de carbono

Una empresa puede reducir su huella aparente externalizando procesos intensivos.

Por ejemplo:

- comprar un ingrediente más procesado;
- trasladar secado;
- contratar transporte externo.

La huella organizacional disminuye y la huella de producto puede permanecer igual.

El análisis debe evitar desplazar emisiones fuera de la frontera.

11.38. Scope 1, Scope 2 y Scope 3

Las emisiones corporativas se agrupan habitualmente en:

- emisiones directas;
- energía adquirida;
- cadena de valor.

En la industria de piensos, gran parte puede encontrarse en materias primas y uso posterior.

La mejora exclusiva de energía de fábrica puede ser importante, pero insuficiente para modificar la huella total.

La IA debe priorizar según contribución real.

11.39. Descarbonización de la fábrica

Las medidas pueden incluir:

- eficiencia de molienda;
- recuperación térmica;
- optimización de vapor;
- electrificación;
- renovables;
- reducción de pérdidas;
- mantenimiento.

El modelo puede identificar:

$$E_{\text{esperada}} E_{\text{real}}$$

y detectar desviaciones.

Pero la energía ahorrada debe medirse frente a una línea basal ajustada por:

- volumen;
- fórmula;
- clima;
- equipo.

11.40. Pérdidas y mermas

Las mermas representan impacto ambiental incorporado sin valor productivo.

Pueden proceder de:

- polvo;
- derrames;
- roturas;

- producto no conforme;
- caducidad;
- mala previsión.

La prevención suele tener doble beneficio:

- económico;
- ambiental.

La IA puede localizar dónde se concentran las pérdidas, pero necesita balances fiables.

11.41. Desperdicio en la explotación

Una dieta sostenible en fábrica puede desperdiciarse por:

- comederos mal ajustados;
- rechazo;
- finos;
- sobrellenado;
- deterioro.

La huella debe considerar el alimento realmente ingerido.

$$I_{\text{efectivo}} = \frac{I_{\text{producido}}}{1 - \text{pérdida}}$$

Pequeñas pérdidas pueden aumentar significativamente la huella por unidad consumida.

11.42. Vida productiva

En reproductoras y vacuno lechero, la longevidad influye en la huella porque distribuye el coste de cría y mantenimiento sobre más producción.

La nutrición puede afectar:

- salud;
- fertilidad;
- condición;
- desgaste.

Optimizar rendimiento inmediato a costa de reducir vida útil puede empeorar la sostenibilidad global.

Los modelos deben usar horizontes suficientes.

11.43. Mortalidad y decomisos

Los animales que mueren o cuyos productos se descartan incorporan recursos sin generar la producción prevista.

La prevención sanitaria y nutricional tiene un valor ambiental importante.

La IA puede estimar impacto evitado por detección temprana, pero debe evitar contabilizar beneficios hipotéticos sin evidencia.

11.44. Bienestar y sostenibilidad

Bienestar y sostenibilidad pueden alinearse:

- menor enfermedad;
- mejor supervivencia;
- menor desperdicio.

Pero también pueden existir tensiones:

- mayor espacio;
- menor densidad;
- crecimiento más lento;
- mayor consumo energético.

No debe utilizarse la sostenibilidad para justificar condiciones incompatibles con el bienestar.

El bienestar funciona como límite ético y técnico.

11.45. Sostenibilidad económica

Una intervención ambiental que destruye la viabilidad de la explotación puede no ser sostenible a largo plazo.

Debe evaluarse:

$$VAN = \sum_{t=0}^T \frac{B_t - C_t}{(1 + r)^t}$$

Pero el análisis económico debe incluir:

- volatilidad;
- incentivos;
- riesgo regulatorio;
- valor reputacional;
- coste de inacción.

11.46. Coste marginal de reducción

Para cada medida:

$$MAC = \frac{C_{\text{medida}} - C_{\text{base}}}{E_{\text{base}} - E_{\text{medida}}}$$

Permite ordenar intervenciones por coste por unidad reducida.

Algunas medidas pueden tener coste negativo porque también mejoran eficiencia.

El orden económico no debe ignorar urgencia o límites ambientales.

11.47. Escenarios de transición

La empresa puede simular:

- situación actual;
- reducción moderada;
- objetivo avanzado;
- estrés de precio;
- escasez de ingrediente.

Para cada escenario debe analizar:

- coste;
- disponibilidad;
- impacto;
- riesgo;
- capacidad.

La IA puede generar muchas combinaciones, pero la estrategia debe ser comprensible y ejecutable.

11.48. Curvas de aprendizaje

El coste de tecnologías puede disminuir con:

- escala;
- experiencia;
- competencia;
- mejora.

Los modelos de transición deben evitar asumir precios constantes durante décadas.

Pero tampoco deberían dar por segura una reducción futura sin evidencia.

Es preferible utilizar rangos.

11.49. Rebound effect

Una mejora de eficiencia puede reducir costes y aumentar producción, compensando parte del ahorro ambiental.

Este efecto rebote debe considerarse.

La eficiencia tecnológica no garantiza reducción absoluta si no existe una estrategia de volumen o límites.

11.50. Medición frente a estimación

Pueden distinguirse:

- datos medidos;

- factores calculados;
- valores estimados;
- supuestos.

La salida debería etiquetar cada componente.

Un indicador compuesto que mezcla mediciones y estimaciones sin diferenciarlas crea falsa precisión.

11.51. Monitorización, reporte y verificación

Un sistema creíble requiere:

- metodología;
- línea basal;
- indicadores;
- frecuencia;
- evidencia;
- verificación.

La IA puede automatizar captura y cálculo, pero la verificación debe comprobar:

- integridad;
- coherencia;
- cambios;
- exclusiones.

No basta con reproducir automáticamente una cifra.

11.52. Línea basal

La línea basal debe corresponder a condiciones comparables.

Si cambia:

- volumen;
- especie;
- fórmula;
- perímetro;
- metodología;

la comparación puede perder sentido.

Puede utilizarse una línea ajustada:

$$E_{\text{base ajustada}} f(\text{producción, mix, clima})$$

Los cambios metodológicos deben documentarse.

11.53. Adicionalidad

Una reducción es adicional cuando no habría ocurrido sin la intervención.

Si la mejora ya estaba prevista por razones económicas, atribuirla totalmente a un programa ambiental puede exagerar el impacto.

La IA puede construir contrafactuales, pero estos siguen siendo estimaciones.

11.54. Evitación, reducción y compensación

Debe mantenerse una jerarquía:

1. evitar;
2. reducir;
3. sustituir;
4. compensar emisiones residuales.

La compensación no debe utilizarse para ocultar impactos evitables.

Los modelos deben presentar por separado:

- emisiones brutas;
- reducciones internas;
- compensaciones;
- emisiones netas.

11.55. Riesgo de doble contabilización

Una misma reducción puede ser reclamada por:

- proveedor;
- fabricante;
- granja;
- procesador;
- minorista.

El intercambio de datos debe definir derechos de atribución.

La suma de claims a lo largo de la cadena no debería superar la reducción real.

11.56. Créditos ambientales en la formulación

Asignar un valor económico al carbono puede introducirse:

$$c_i^* c_i + p_c e_i$$

donde:

- (p_c) : precio interno del carbono;
- (e_i) : huella.

Esto permite incorporar el impacto en decisiones.

Pero el precio interno es una elección empresarial, no una verdad física.

Debe revisarse y utilizarse junto con límites ambientales.

11.57. Claims ambientales

Afirmaciones como:

- bajo carbono;
- sostenible;
- regenerativo;
- circular;
- carbono neutro;

requieren definiciones y evidencia.

La IA generativa puede producir mensajes convincentes que excedan los datos.

Toda afirmación debería especificar:

- producto;
- comparación;
- unidad;
- frontera;
- periodo;
- metodología;
- verificación.

“Reduce la huella un 20 %” carece de sentido sin indicar respecto de qué.

11.58. Greenwashing algorítmico

Existe greenwashing algorítmico cuando un sistema:

- selecciona indicadores favorables;
- omite impactos;
- utiliza factores desactualizados;
- presenta estimaciones como mediciones;
- oculta incertidumbre;
- genera claims no sustentados.

El problema no es únicamente comunicativo. Puede afectar a decisiones de compra e inversión.

La auditoría debe revisar tanto el modelo como la narrativa producida.

11.59. Transparencia de los modelos ambientales

El usuario debe conocer:

- fuente de datos;
- fronteras;
- asignación;
- factores;

- versión;
- incertidumbre;
- exclusiones.

Un proveedor puede proteger su código sin ocultar la metodología esencial.

La sostenibilidad no es verificable si depende de una puntuación propietaria cuya construcción no puede evaluarse.

11.60. Comparabilidad

Dos herramientas pueden producir cifras diferentes por:

- bases;
- fronteras;
- asignación;
- factores;
- unidades.

Antes de comparar debe armonizarse la metodología.

La IA puede mapear diferencias, pero no debe fusionar resultados incompatibles como si fueran equivalentes.

11.61. Temporalidad de las emisiones

No todas las emisiones tienen el mismo momento ni permanencia.

Los modelos tradicionales suelen agregarlas en una cifra, pero determinadas decisiones pueden requerir considerar:

- emisión inmediata;
- almacenamiento;
- reversibilidad;
- horizonte.

La selección del horizonte afecta especialmente al metano.

La metodología utilizada debe declararse.

11.62. Regionalización

Los impactos dependen de:

- mix eléctrico;
- estrés hídrico;
- suelo;
- clima;
- rendimiento;
- biodiversidad.

Un factor global puede ser insuficiente para una decisión local.

La IA facilita trabajar con datos espaciales, pero aumenta la exigencia de calidad geográfica.

11.63. Teledetección y datos geospaciales

Satélites y sensores pueden estimar:

- cobertura;
- rendimiento;
- humedad;
- deforestación;
- estrés;
- uso de suelo.

Estos datos pueden reforzar la trazabilidad de materias primas.

Pero la clasificación remota presenta errores por:

- resolución;
- nubosidad;
- similitud espectral;
- cambios estacionales.

Una alerta geoespacial requiere verificación.

11.64. Riesgo climático físico

El cambio climático puede afectar:

- disponibilidad;
- calidad;
- micotoxinas;
- precio;
- logística.

La IA puede analizar escenarios de:

- sequía;
- inundación;
- calor;
- nuevos patógenos.

La sostenibilidad también implica adaptación, no solo reducción de emisiones.

11.65. Riesgo de transición

Las empresas pueden enfrentarse a:

- nuevas reglas;
- impuestos;

- demandas de clientes;
- restricciones de materias;
- cambios tecnológicos.

El modelo debe valorar:

$$R_T = P(\text{cambio}) \times C(\text{exposición})$$

Una materia prima barata hoy puede representar un riesgo futuro elevado.

11.66. Resiliencia y sostenibilidad

Una dieta de huella mínima puede depender de un ingrediente escaso o de un único proveedor.

La sostenibilidad debe incorporar:

- disponibilidad;
- estabilidad;
- sustituibilidad;
- riesgo.

Puede definirse:

$$J = C_{\text{ambiental}} + C_{\text{económico}} + C_{\text{riesgo}}$$

Una solución ligeramente menos favorable en carbono puede ser más sostenible si mantiene continuidad y seguridad.

11.67. Datos del proveedor

La obtención de huellas específicas puede mejorar precisión.

Pero debe controlarse:

- metodología;
- verificación;
- periodo;
- representatividad;
- asignación.

No deberían aceptarse factores específicos únicamente porque sean inferiores a las bases genéricas.

11.68. Modelos de recomendación ambiental

Un sistema puede sugerir:

- cambiar ingrediente;
- modificar origen;
- aplicar enzima;
- reducir proteína;
- mejorar conversión;

- ajustar proceso.

Cada recomendación debe mostrar:

- reducción prevista;
- intervalo;
- coste;
- efectos secundarios;
- evidencia.

La recomendación no debe ser una puntuación aislada.

11.69. Verificación experimental

Las mejoras formuladas deben confirmarse mediante:

- consumo;
- rendimiento;
- digestibilidad;
- excreción;
- emisiones, cuando proceda;
- estabilidad de proceso.

Una reducción teórica de nitrógeno no garantiza el resultado si el consumo o la retención difieren.

11.70. Gemelo ambiental

El gemelo puede integrar:

- flujos;
- fórmulas;
- energía;
- animales;
- emisiones;
- estiércol.

Permite simular:

- cambios de dieta;
- tecnología;
- volumen;
- clima.

Debe actualizarse con datos reales.

Un gemelo ambiental desactualizado puede producir una imagen coherente y falsa.

11.71. Aprendizaje causal

La predicción puede identificar que explotaciones con determinado aditivo tienen menor huella.

Pero puede existir confusión por:

- mejor manejo;
- genética;
- instalaciones;
- tamaño.

La inferencia causal intenta estimar:

$$E[Y(1) - Y(0)]$$

es decir, la diferencia entre aplicar y no aplicar la intervención.

La IA puede apoyar este análisis, pero requiere diseño y supuestos explícitos.

11.72. Optimización por explotación

La solución ambiental óptima depende de:

- especie;
- dieta;
- clima;
- estiércol;
- energía;
- recursos.

Una recomendación universal puede ser inadecuada.

La personalización debe respetar estándares comunes de medición para mantener comparabilidad.

11.73. Jerarquía de calidad de la evidencia

Puede establecerse:

1. medición directa validada;
2. datos específicos verificados;
3. estimación calibrada localmente;
4. factor regional;
5. factor genérico;
6. supuesto experto.

El resultado debe indicar qué proporción procede de cada nivel.

11.74. Semáforo de confianza ambiental

Tabla 17. Síntesis de nivel, evidencia y uso.

Nivel	Evidencia	Uso
Alto	Datos específicos verificados	Claim cuantitativo prudente
Medio	Datos regionales y estimación validada	Decisión interna

Nivel	Evidencia	Uso
Bajo	Factores genéricos	Cribado
Muy bajo	Supuestos incompletos	No comunicar externamente

11.75. Indicadores clave

Tabla 18. Síntesis de dimensión y indicador.

Dimensión	Indicador
Clima	kg CO ₂ e/t de pienso
Producto	kg CO ₂ e/kg de producto
Nitrógeno	N excretado
Fósforo	P excretado
Metano	g/día e intensidad
Agua	consumo ponderado por escasez
Suelo	ocupación y transformación
Circularidad	porcentaje de coproductos
Energía	kWh/t
Merma	porcentaje de pérdida
Incertidumbre	intervalo del resultado
Datos	porcentaje específico verificado

11.76. Modelo de madurez ambiental

Nivel 1. Cumplimiento

Registro de consumos y residuos.

Nivel 2. Medición

Inventario de impactos.

Nivel 3. Integración

Huella incorporada a compras y formulación.

Nivel 4. Optimización

Decisiones multiobjetivo.

Nivel 5. Verificación

Resultados contrastados con producción real.

Nivel 6. Adaptación

Modelos por lote, explotación y escenario.

La madurez no debe medirse por el número de indicadores publicados, sino por la capacidad de demostrar reducciones reales.

11.77. Cuadro de riesgos

Tabla 19. Síntesis de riesgo, manifestación y control.

Riesgo	Manifestación	Control
Frontera estrecha	Impacto desplazado	Ampliar ciclo de vida
Factor genérico	Falsa precisión	Calidad de dato
Objetivo único	Mejora carbono, empeora eutrofización	Multiobjetivo
Claim excesivo	Greenwashing	Revisión y verificación
Doble cómputo	Misma reducción reclamada varias veces	Gobernanza
Rebote	Más producción total	Indicadores absolutos
Materia circular insegura	Introducción de peligros	Evaluación previa
Reducción proteica excesiva	Menor rendimiento o salud	Restricciones nutricionales
Mitigador inestable	Efecto temporal	Seguimiento
Modelo opaco	Resultado no auditable	Transparencia metodológica

11.78. Arquitectura de decisión sostenible

Capa de datos

- materias;
- procesos;
- transporte;
- animales;
- estiércol;
- energía.

Capa metodológica

- frontera;
- unidad;
- asignación;
- factores;
- incertidumbre.

Capa analítica

- huella;
- sensibilidad;
- escenarios;
- causalidad.

Capa de optimización

- coste;
- nutrición;
- ambiente;
- resiliencia.

Capa de validación

- resultados;
- auditoría;
- verificación;
- mejora.

11.79. Principios para una IA ambientalmente responsable

1. Declarar siempre la frontera y la unidad funcional.
2. Diferenciar medición, estimación y supuesto.
3. Incorporar incertidumbre.
4. Evitar optimización ambiental de un solo indicador.
5. Mantener salud, seguridad y bienestar como restricciones.
6. Considerar impactos absolutos e intensidades.
7. Verificar las mejoras en condiciones reales.
8. Evitar doble contabilización.
9. Comunicar las compensaciones.
10. Prohibir claims más precisos que la evidencia.

11.80. Conclusión: optimizar dentro de los límites del sistema, no fuera de ellos

La inteligencia artificial puede convertir la sostenibilidad de una declaración general en un problema cuantificable. Puede integrar materias primas, digestibilidad, rendimiento, emisiones, transporte, energía y excreción. Puede construir escenarios, identificar variables dominantes y mostrar soluciones de compromiso que serían difíciles de obtener mediante formulación convencional.

Pero la capacidad de calcular no elimina las decisiones metodológicas. La frontera, la unidad funcional, la asignación, los factores de emisión y los criterios de comparación determinan el resultado tanto como el algoritmo.

Una cifra ambiental no es una propiedad natural del producto. Es el resultado de una metodología aplicada a datos de calidad variable.

La nutrición animal sostenible no consiste simplemente en seleccionar ingredientes con menor puntuación de carbono. Consiste en suministrar los nutrientes necesarios con la menor utilización razonable de recursos, reduciendo pérdidas y emisiones, preservando la salud y aprovechando de forma segura materiales que no compiten directamente con la alimentación humana.

La IA será útil cuando haga visibles las compensaciones:

- menor carbono, pero mayor coste;
- menor nitrógeno, pero menor margen nutricional;
- mayor circularidad, pero mayor variabilidad;

- mayor eficiencia, pero mayor dependencia;
- menor intensidad, pero mayor impacto absoluto.

Ocultar estas tensiones tras una calificación única no es inteligencia, sino simplificación.

La verdadera función de la inteligencia artificial ambiental consiste en ayudar a decidir dentro de límites múltiples y, en ocasiones, contradictorios. Debe mostrar qué se gana, qué se pierde, qué datos sostienen el resultado y qué incertidumbre permanece.

Una nutrición animal ambientalmente responsable no será aquella que proclame una huella perfecta, sino aquella que pueda demostrar, de forma verificable, que utiliza menos recursos, genera menos impacto y mantiene al mismo tiempo la seguridad, el bienestar, la funcionalidad nutricional y la viabilidad del sistema productivo.

12. Gobernanza, regulación y responsabilidad de la inteligencia artificial en nutrición animal: del cumplimiento formal al control efectivo del riesgo

La incorporación de inteligencia artificial a la nutrición animal no constituye únicamente una cuestión tecnológica. Cada modelo que selecciona materias primas, modifica una formulación, clasifica un lote, prioriza una alerta sanitaria, ajusta un proceso industrial o recomienda una intervención introduce una nueva capa de decisión dentro de una actividad sometida a obligaciones de seguridad, higiene, trazabilidad y responsabilidad.

La empresa no deja de responder por sus productos porque una decisión haya sido propuesta por un algoritmo. Tampoco puede justificar una desviación alegando que el sistema funcionó conforme a su programación. La automatización modifica la forma en que se toman las decisiones, pero no elimina las obligaciones jurídicas y técnicas que recaen sobre los operadores de la cadena de piensos.

En la Unión Europea, el Reglamento (UE) 2024/1689 —AI Act— establece un marco horizontal basado en el riesgo para el desarrollo, comercialización y utilización de sistemas de inteligencia artificial. Este marco debe interpretarse juntamente con la normativa sectorial aplicable a piensos, seguridad alimentaria, higiene, protección de datos, ciberseguridad, productos y responsabilidad civil.

La dificultad principal reside en que una misma aplicación puede estar sometida simultáneamente a varias lógicas regulatorias:

- como sistema de inteligencia artificial;
- como componente de software;
- como parte de una máquina;
- como herramienta de control de proceso;
- como elemento del sistema APPCC;
- como soporte de una decisión veterinaria;
- como componente de un producto o servicio defectuoso;
- como tratamiento de datos personales;
- como infraestructura digital crítica.

La gobernanza adecuada no debe limitarse a preguntar si el sistema está formalmente clasificado como de alto riesgo bajo el AI Act. Debe determinar qué daño puede producir, qué decisiones condiciona, qué controles necesita y qué evidencia permitirá reconstruir su actuación.

12.1. La regulación sectorial continúa siendo aplicable

El Reglamento (CE) n.º 178/2002 establece los principios generales de la legislación alimentaria, incluye los piensos dentro de su arquitectura de seguridad y atribuye a los operadores la responsabilidad primaria de garantizar que los productos cumplen los requisitos aplicables. También configura la trazabilidad como una obligación esencial de la cadena alimentaria.

El Reglamento (CE) n.º 183/2005 establece requisitos de higiene de los piensos, condiciones de trazabilidad y obligaciones relativas al registro o autorización de establecimientos. Su lógica preventiva exige que los operadores controlen los peligros asociados a sus actividades.

La introducción de IA no modifica esta estructura.

Si un algoritmo:

- acepta una materia prima;
- reduce un control;
- ajusta una dosis;
- modifica una temperatura;
- permite una expedición;

la empresa sigue siendo responsable de que el resultado sea seguro y conforme.

El cumplimiento del AI Act no equivale a cumplimiento de la normativa de piensos. Del mismo modo, cumplir la normativa sectorial no garantiza por sí solo que el sistema de IA se haya gobernado adecuadamente.

12.2. El principio de responsabilidad del operador

Puede expresarse:

$$R_{\text{operador}} \neq 0 \quad \text{aunque} \quad D_{\text{algoritmo}} = 1$$

donde:

- (R_{operador}): responsabilidad del operador;
- ($D_{\text{algoritmo}}$): intervención decisiva del algoritmo.

La empresa debe demostrar que:

1. seleccionó un sistema adecuado;
2. definió su finalidad;
3. validó su desempeño;
4. estableció límites;
5. formó a los usuarios;
6. supervisó su funcionamiento;
7. reaccionó ante desviaciones.

La adquisición de una herramienta comercial no transfiere automáticamente el riesgo al proveedor.

12.3. Clasificación funcional del sistema

Antes de analizar obligaciones, debe describirse qué hace realmente el sistema.

No basta con denominaciones como:

- plataforma inteligente;
- asistente nutricional;
- optimizador;
- gemelo digital;
- sistema predictivo.

Debe identificarse:

- entrada;

- transformación;
- salida;
- usuario;
- decisión;
- consecuencia.

Una ficha funcional mínima puede incluir:

Tabla 20. Síntesis de elemento y descripción.

Elemento	Descripción
Finalidad	Problema que pretende resolver
Entradas	Datos utilizados
Salida	Predicción, clasificación o recomendación
Usuario	Persona o sistema receptor
Acción	Qué ocurre después
Impacto	Consecuencia potencial
Autonomía	Grado de intervención humana
Ámbito	Especies, productos y plantas
Exclusiones	Usos no autorizados

12.4. Sistema de IA frente a software convencional

No todo software utilizado en una fábrica de piensos constituye necesariamente un sistema de IA.

Un programa puede:

- aplicar reglas fijas;
- ejecutar una receta;
- realizar cálculos deterministas;
- almacenar registros.

La inteligencia artificial implica, en términos generales, capacidad para generar salidas como predicciones, recomendaciones o decisiones a partir de entradas, mediante técnicas que pueden mostrar distintos grados de autonomía y adaptación.

La clasificación jurídica debe realizarse atendiendo al funcionamiento real, no a la estrategia comercial del proveedor.

Llamar “IA” a un software convencional puede crear obligaciones innecesarias. Presentar como simple software una herramienta de aprendizaje automático puede ocultar riesgos relevantes.

12.5. Enfoque basado en el riesgo

El AI Act adopta una estructura basada en niveles de riesgo. No todas las aplicaciones reciben el mismo tratamiento.

En nutrición animal pueden existir aplicaciones de bajo impacto, como:

- clasificación documental;
- predicción interna de ventas;
- asistencia en redacción;
- búsqueda técnica.

Otras pueden tener consecuencias significativas:

- formulación automática;
- control térmico;
- clasificación sanitaria;
- predicción de contaminación;
- liberación de producto;
- dosificación de sustancias.

Aunque una aplicación no quede formalmente incluida en una categoría jurídica de alto riesgo, puede ser de elevada criticidad desde la perspectiva sectorial.

Debe distinguirse:

$$R_{\text{jurídico}} \neq R_{\text{operativo}}$$

La ausencia de clasificación legal como alto riesgo no significa que pueda implantarse sin controles estrictos.

12.6. Riesgo intrínseco y riesgo residual

El riesgo intrínseco es el existente antes de aplicar controles:

$$R_i = P_i \times S_i$$

donde:

- (P_i): probabilidad;
- (S_i): severidad.

El riesgo residual es:

$$R_r = R_i(1 - E_c)$$

donde (E_c) representa la eficacia de los controles.

La gobernanza debe evaluar ambos.

Un sistema que puede alterar una dosis crítica presenta alto riesgo intrínseco, aunque los bloqueos y verificaciones reduzcan sustancialmente el riesgo residual.

12.7. Clasificación por impacto sectorial

Puede utilizarse una matriz interna:

Clase A. Impacto informativo

El sistema ordena, resume o visualiza información.

Clase B. Apoyo a decisión reversible

Propone ajustes que requieren aprobación.

Clase C. Decisión operativa automática

Ejecuta cambios reversibles dentro de límites.

Clase D. Impacto sanitario o de seguridad

Puede afectar a composición, tratamiento, liberación o exposición.

Clase E. Decisión irreversible

Produce consecuencias que no pueden revertirse fácilmente.

La intensidad de validación y supervisión debe aumentar con la clase.

12.8. Finalidad prevista

La finalidad prevista define:

- qué puede hacer;
- para quién;
- en qué condiciones;
- con qué datos;
- sobre qué población.

Un modelo validado para estimar proteína en harina de soja no debe utilizarse automáticamente para:

- colza;
- subproductos;
- materias fermentadas;
- producto terminado.

El uso fuera de finalidad puede invalidar la evidencia disponible.

12.9. Uso razonablemente previsible

La gobernanza debe anticipar usos incorrectos previsibles:

- aplicar el modelo a otra especie;
- aceptar recomendaciones sin revisión;
- utilizarlo con datos incompletos;
- omitir análisis;
- ampliar dosis;
- exportar resultados a otro país.

El diseño debe incorporar advertencias, bloqueos o controles frente a estos usos.

No basta con incluir una prohibición en un manual que el usuario nunca consulta.

12.10. Proveedor, desplegador e integrador

En una aplicación industrial pueden intervenir:

- desarrollador del modelo;
- proveedor de plataforma;
- integrador;
- fabricante de maquinaria;
- empresa de piensos;
- consultor;
- usuario final.

Cada actor controla una parte.

El proveedor puede controlar el modelo, pero la empresa decide:

- datos;
- configuración;
- umbral;
- entorno;
- actuación.

La responsabilidad debe asignarse contractualmente sin crear vacíos.

12.11. Modificación sustancial

Una empresa puede dejar de ser un simple usuario cuando modifica de manera relevante:

- finalidad;
- arquitectura;
- umbrales;
- variables;
- población;
- nivel de autonomía.

Una modificación sustancial puede alterar el perfil regulatorio y convertir al integrador o usuario en responsable de nuevas obligaciones.

Toda modificación debe pasar por gestión de cambios.

12.12. Inventario corporativo de IA

La organización debe mantener un inventario de sistemas.

Puede incluir:

- nombre;
- propietario;
- proveedor;

- finalidad;
- versión;
- datos;
- criticidad;
- estado;
- responsable;
- fecha de revisión.

Sin inventario, es imposible gobernar herramientas introducidas informalmente por departamentos o empleados.

12.13. IA en la sombra

La denominada shadow AI aparece cuando personal utiliza herramientas no aprobadas para:

- formular;
- resumir informes;
- interpretar análisis;
- generar claims;
- responder a clientes;
- procesar datos.

Los riesgos incluyen:

- filtración;
- errores;
- falta de trazabilidad;
- uso de versiones no controladas.

La respuesta no debe limitarse a prohibir. Debe proporcionar alternativas seguras y formación.

12.14. Comité de gobernanza

La gobernanza debe ser multidisciplinar.

Puede incluir:

- dirección;
- nutrición;
- veterinaria;
- calidad;
- regulación;
- producción;
- IT;
- ciberseguridad;
- protección de datos;
- legal.

El comité debe aprobar:

- clasificación;

- implantación;
- cambios;
- excepciones;
- retirada.

La IA no debe quedar bajo control exclusivo del departamento tecnológico.

12.15. Propietario del sistema

Cada sistema debe tener un responsable funcional.

Sus funciones incluyen:

- mantener documentación;
- revisar desempeño;
- coordinar incidencias;
- asegurar formación;
- proponer cambios.

El proveedor externo no sustituye al propietario interno.

12.16. Propietario del riesgo

Puede no coincidir con el propietario técnico.

Ejemplo:

- IT administra la plataforma;
- nutrición es responsable de la fórmula;
- calidad libera el producto;
- producción ejecuta.

La organización debe definir quién acepta el riesgo residual.

12.17. Datos de entrenamiento

La calidad del modelo depende de:

- representatividad;
- exactitud;
- completitud;
- etiquetado;
- equilibrio;
- origen.

Debe documentarse:

$$D = X, Y, M$$

donde:

- (X): variables;
- (Y): resultados;
- (M): metadatos.

Sin metadatos, los datos pierden contexto.

12.18. Procedencia de los datos

Debe conocerse:

- fuente;
- fecha;
- método;
- derechos;
- transformaciones.

La procedencia permite evaluar:

- legalidad;
- calidad;
- sesgo;
- reproducibilidad.

Un conjunto descargado de internet o recibido de un proveedor no debe utilizarse para una aplicación crítica sin verificar su origen.

12.19. Derechos sobre datos

Los contratos deben determinar:

- propiedad;
- licencia;
- reutilización;
- entrenamiento;
- conservación;
- devolución;
- eliminación.

Los datos de clientes, explotaciones o proveedores no deben incorporarse a modelos externos sin base contractual suficiente.

12.20. Datos personales

Algunas aplicaciones pueden tratar datos de:

- empleados;
- transportistas;
- veterinarios;
- clientes;
- operarios.

Aunque el objeto principal sea animal o industrial, la monitorización puede identificar personas.

La organización debe aplicar:

- minimización;
- finalidad;
- acceso;
- conservación;
- seguridad.

No debe suponerse que un sistema queda fuera de protección de datos porque analiza animales.

12.21. Datos derivados e inferidos

La IA puede generar:

- puntuación de proveedor;
- riesgo de operario;
- predicción de incumplimiento;
- evaluación de desempeño.

Estas inferencias pueden tener efectos relevantes.

Deben existir mecanismos para:

- revisar;
- impugnar;
- corregir;
- contextualizar.

12.22. Calidad de datos en operación

No basta con validar el entrenamiento.

En producción deben controlarse:

- rangos;
- valores perdidos;
- unidades;
- duplicados;
- retrasos;
- identidad;
- deriva.

Puede definirse:

$$Q_t = f(C_t, A_t, V_t, T_t)$$

donde:

- (C): completitud;

- (A): exactitud;
- (V): validez;
- (T): actualidad.

El sistema debe abstenerse cuando la calidad cae por debajo del mínimo.

12.23. Validación técnica

La validación debe evaluar:

- discriminación;
- calibración;
- error;
- robustez;
- estabilidad;
- subgrupos;
- condiciones extremas.

La métrica debe corresponder al uso.

Un buen error medio puede ocultar desviaciones graves en ingredientes minoritarios o especies concretas.

12.24. Validación sectorial

Debe comprobarse que la salida tiene sentido nutricional, veterinario o industrial.

Un modelo puede ser estadísticamente correcto y proponer:

- inclusión inviable;
- dosis insegura;
- temperatura incompatible;
- diagnóstico inespecífico.

La validación sectorial requiere expertos del dominio.

12.25. Validación externa

Debe evaluarse en datos no utilizados durante desarrollo.

Idealmente:

- otra campaña;
- otra planta;
- otros proveedores;
- otras razas;
- otros equipos.

La validación interna tiende a sobreestimar el desempeño.

12.26. Validación prospectiva

La prueba prospectiva observa el sistema durante utilización real.

Debe registrar:

- predicción;
- decisión;
- intervención;
- resultado.

Esta fase permite detectar problemas de interacción con usuarios que no aparecen en laboratorio.

12.27. Ensayo en sombra

Antes de automatizar, el sistema puede operar sin intervenir.

Se comparan:

- recomendación algorítmica;
- decisión humana;
- resultado.

El ensayo en sombra permite medir valor y riesgo sin modificar todavía el proceso.

12.28. Criterios de aceptación

Los criterios deben definirse antes de probar.

Ejemplos:

- error máximo;
- sensibilidad mínima;
- tasa de abstención;
- falsas alarmas;
- latencia;
- disponibilidad.

No debe aprobarse un sistema ajustando los criterios después de observar los resultados.

12.29. Explicabilidad

La explicación debe adaptarse al usuario.

Un nutricionista puede necesitar:

- nutrientes determinantes;
- restricciones activas;
- incertidumbre.

Un operario puede necesitar:

- variable desviada;
- acción;
- límite.

Un auditor puede necesitar:

- versión;
- datos;
- lógica;
- registro.

No existe una única explicación válida.

12.30. Explicación local y global

Global

Describe el comportamiento general.

Local

Explica una decisión concreta.

Ambas son necesarias.

La explicación global no permite justificar por qué se rechazó un lote específico. La explicación local no demuestra que el sistema se comporte adecuadamente en general.

12.31. Límites de la explicabilidad

Métodos como SHAP o importancia de variables explican la contribución al resultado del modelo.

No demuestran:

- causalidad;
- corrección biológica;
- legalidad;
- seguridad.

Una variable importante puede ser un proxy o una correlación espuria.

12.32. Transparencia al usuario

El usuario debe saber:

- que interactúa con IA;
- finalidad;
- limitaciones;
- supervisión;
- procedimiento de error.

La transparencia no debe reducirse a un aviso genérico.

Debe ser accionable.

12.33. Documentación técnica

La documentación debe incluir:

- diseño;
- finalidad;
- arquitectura;
- datos;
- validación;
- riesgos;
- controles;
- mantenimiento;
- cambios.

Un sistema no puede auditarse si su conocimiento reside únicamente en los desarrolladores.

12.34. Registro automático

Debe conservarse evidencia de:

- entrada;
- salida;
- versión;
- usuario;
- tiempo;
- acción;
- override;
- resultado.

Puede representarse:

$$L_t = X_t, M_v, Y_t, U_t, A_t$$

donde:

- (M_v): versión;
- (U_t): usuario;
- (A_t): acción.

12.35. Trazabilidad decisional

La trazabilidad convencional explica el movimiento del producto.

La trazabilidad decisional explica por qué se tomó una decisión.

Debe responder:

- qué datos había;
- qué modelo se utilizó;
- qué recomendó;
- quién aprobó;
- qué ocurrió.

Esta evidencia resulta esencial en:

- auditorías;
- reclamaciones;
- retiradas;
- litigios;
- aprendizaje.

12.36. Conservación de registros

El periodo debe considerar:

- vida útil;
- plazo de reclamación;
- requisitos sectoriales;
- responsabilidad;
- investigación.

Eliminar registros de IA antes de que termine la vida comercial puede impedir reconstruir una incidencia.

12.37. Supervisión humana

La supervisión debe ser efectiva.

No basta con mostrar un botón de aceptación.

El usuario necesita:

- competencia;
- tiempo;
- información;
- autoridad;
- posibilidad real de detener.

Una supervisión meramente formal crea ilusión de control.

12.38. Automation bias

Las personas pueden aceptar una recomendación porque procede de un sistema percibido como avanzado.

El sesgo de automatización aumenta cuando:

- la interfaz transmite certeza;
- el modelo acierta con frecuencia;
- existe presión;

- el usuario no conoce límites.

La formación debe incluir errores reales y ejercicios de contradicción.

12.39. Aversión algorítmica

También puede ocurrir lo contrario: abandonar un sistema útil después de observar un error.

La gobernanza debe comunicar que:

- ningún modelo es infalible;
- el rendimiento es probabilístico;
- los fallos se analizan;
- el valor se evalúa globalmente.

12.40. Sobrecarga cognitiva

Una explicación excesiva puede impedir decidir.

La interfaz debe jerarquizar:

1. riesgo;
2. causa;
3. acción;
4. incertidumbre;
5. detalle.

La información completa puede quedar disponible para auditoría sin saturar la operación.

12.41. Niveles de autonomía

Tabla 21. Síntesis de nivel y función.

Nivel	Función
0	Solo registro
1	Información
2	Recomendación
3	Ejecución tras aprobación
4	Ejecución automática reversible
5	Autonomía amplia dentro de límites

La autonomía debe depender de:

- severidad;
- reversibilidad;
- validación;
- detectabilidad del error.

12.42. Principio de mínima autonomía necesaria

Debe elegirse el menor nivel capaz de obtener el beneficio esperado.

Si una recomendación supervisada produce el mismo resultado que el control autónomo, no existe justificación suficiente para aumentar autonomía.

12.43. Abstención

El sistema debe poder declarar:

- datos insuficientes;
- fuera de dominio;
- baja confianza;
- conflicto.

Puede definirse:

$$\text{actuar} \quad \text{si} \quad P_{\max} \geq \tau$$

En caso contrario:

abstenerse

La abstención es una función de seguridad.

12.44. Límites duros

Determinadas condiciones no deben quedar bajo aprendizaje:

- máximos legales;
- incompatibilidades;
- especies prohibidas;
- dosis máximas;
- rutas de contaminación;
- temperaturas de seguridad.

Estas restricciones deben aplicarse mediante reglas independientes.

12.45. Defensa en profundidad

No debe existir un único control.

Ejemplo en dosificación:

1. receta aprobada;
2. identificación;
3. límite;
4. báscula;
5. verificación;
6. análisis.

Si el modelo falla, otras barreras deben evitar el daño.

12.46. Fail-safe

Ante fallo, el sistema debe pasar a un estado seguro.

Puede implicar:

- detener;
- mantener último valor seguro;
- transferir a manual;
- bloquear liberación;
- generar alerta.

El estado seguro depende del proceso. Detener un ventilador puede ser más peligroso que mantenerlo.

12.47. Ciberseguridad

La manipulación de datos o modelos puede alterar:

- formulación;
- clasificación;
- alarmas;
- dosificación;
- trazabilidad.

La seguridad debe incluir:

- acceso;
- integridad;
- disponibilidad;
- segmentación;
- registros;
- recuperación.

Un modelo preciso pero vulnerable no es un sistema seguro.

12.48. Actualizaciones

Las actualizaciones pueden afectar a:

- rendimiento;
- variables;
- interfaz;
- compatibilidad;
- explicación.

Deben someterse a:

1. evaluación;
2. prueba;

3. aprobación;
4. despliegue controlado;
5. seguimiento.

No debería actualizarse automáticamente una aplicación crítica sin capacidad de reversión.

12.49. Aprendizaje continuo

El aprendizaje continuo puede adaptarse a nuevos datos.

Pero también puede:

- incorporar errores;
- normalizar fallos;
- olvidar patrones;
- degradar subgrupos.

En aplicaciones críticas es preferible separar:

- modelo operativo estable;
- modelo candidato;
- proceso de validación.

12.50. Deriva

La deriva puede afectar a:

- entradas;
- relaciones;
- prevalencia;
- objetivos.

Debe monitorizarse:

$$D(P_t, P_0)$$

Si supera un umbral, debe revisarse el modelo.

La deriva no implica automáticamente necesidad de reentrenamiento. Puede indicar un problema de proceso.

12.51. Recalibración

En ocasiones el modelo conserva discriminación, pero las probabilidades dejan de ser correctas.

Puede ser suficiente recalibrar.

La organización debe distinguir entre:

- ajuste de umbral;
- recalibración;

- reentrenamiento;
- rediseño.

Cada cambio tiene un nivel de impacto diferente.

12.52. Gestión de incidentes

Un incidente de IA puede incluir:

- recomendación insegura;
- omisión;
- degradación;
- pérdida de datos;
- acceso indebido;
- automatización fuera de límites.

El procedimiento debe definir:

- detección;
- contención;
- análisis;
- comunicación;
- corrección;
- cierre.

12.53. Incidente tecnológico e incidente de producto

Un fallo del modelo puede no producir producto afectado.

Un producto no conforme puede originarse sin fallo tecnológico.

Deben analizarse por separado, pero conectarse cuando exista relación.

12.54. Causa raíz

La investigación debe distinguir:

- dato;
- sensor;
- modelo;
- configuración;
- interfaz;
- usuario;
- organización.

Atribuir el incidente a “error humano” puede ocultar un diseño deficiente.

12.55. CAPA

Las acciones correctivas y preventivas pueden incluir:

- reparar datos;
- modificar interfaz;
- cambiar umbral;
- formar;
- limitar uso;
- retirar modelo.

La eficacia debe verificarse posteriormente.

12.56. Responsabilidad por productos defectuosos

La Directiva (UE) 2024/2853 actualiza el régimen europeo de responsabilidad por productos defectuosos e incluye el software dentro del concepto de producto, con independencia de su forma de suministro. Este marco amplía la relevancia jurídica de los sistemas de IA integrados en productos o procesos.

En nutrición animal pueden plantearse cadenas de responsabilidad entre:

- fabricante del software;
- integrador;
- fabricante de equipo;
- productor de pienso;
- proveedor de datos.

La prueba de causalidad puede ser compleja cuando varios componentes interactúan.

12.57. Contratos con proveedores de IA

Los contratos deben regular:

- finalidad;
- niveles de servicio;
- rendimiento;
- seguridad;
- actualizaciones;
- auditoría;
- datos;
- propiedad intelectual;
- responsabilidad;
- salida.

No debe aceptarse una cláusula que atribuya al cliente toda responsabilidad mientras el proveedor mantiene control exclusivo sobre el modelo y sus cambios.

12.58. Auditoría del proveedor

La evaluación puede incluir:

- desarrollo;
- calidad;
- seguridad;
- personal;

- continuidad;
- subcontratistas;
- historial de incidentes.

La certificación externa puede aportar evidencia, pero no sustituye la evaluación del uso concreto.

12.59. Dependencia tecnológica

La empresa debe poder:

- exportar datos;
- conservar registros;
- operar en contingencia;
- sustituir proveedor.

El vendor lock-in puede convertirse en riesgo operativo y regulatorio.

12.60. Modelos fundacionales y generativos

Los modelos generativos pueden apoyar:

- documentación;
- investigación;
- borradores;
- análisis exploratorio.

Sus riesgos incluyen:

- alucinaciones;
- referencias inexistentes;
- pérdida de contexto;
- variabilidad;
- fuga de información.

No deberían tomar directamente decisiones críticas de formulación, liberación o tratamiento sin capas adicionales de validación.

12.61. Recuperación aumentada

La conexión del modelo con documentación interna puede mejorar precisión.

Pero debe controlarse:

- versión;
- autorización;
- fuente;
- actualidad.

Una respuesta basada en un procedimiento obsoleto puede parecer correcta y ser peligrosa.

12.62. Verificación de contenido generado

Toda salida técnica debe comprobar:

- hechos;
- cálculos;
- unidades;
- referencias;
- vigencia normativa.

La fluidez lingüística no es evidencia de corrección.

12.63. Propiedad intelectual

La IA puede generar conflictos sobre:

- fórmulas;
- bases de datos;
- documentos;
- modelos;
- resultados.

Los contratos deben aclarar si el proveedor puede entrenar con:

- recetas;
- resultados;
- datos comerciales;
- incidencias.

Las formulaciones y procesos pueden constituir secretos empresariales.

12.64. Confidencialidad

No debe introducirse información sensible en herramientas públicas sin autorización.

Puede incluir:

- composiciones;
- precios;
- proveedores;
- clientes;
- ensayos;
- estrategias.

La política debe especificar herramientas permitidas y categorías de datos.

12.65. Competencia y colusión algorítmica

Los sistemas de precios o compras pueden reaccionar entre sí de forma problemática.

La empresa debe evitar:

- intercambio indebido;
- coordinación;
- uso de información competitivamente sensible.

La automatización no legitima conductas que serían ilícitas si fueran humanas.

12.66. Sesgo y equidad

En nutrición animal, el sesgo puede afectar a:

- pequeños proveedores;
- granjas menos digitalizadas;
- razas minoritarias;
- regiones con menos datos.

Un sistema puede asignar peor puntuación no por mayor riesgo real, sino por menor disponibilidad de información.

Debe distinguirse:

ausencia de datos $\neq$ evidencia de riesgo

12.67. Bienestar animal

Una optimización centrada en producción puede perjudicar:

- hambre;
- confort;
- salud;
- conducta.

El bienestar debe incorporarse como restricción.

Las decisiones que afectan a animales no deben justificarse exclusivamente por eficiencia algorítmica.

12.68. Ética de la vigilancia

La monitorización continua puede mejorar bienestar, pero también transformar la explotación en un entorno donde toda desviación se interpreta como fallo productivo.

Debe preservarse una concepción del animal como ser biológico, no como máquina de rendimiento.

La variabilidad no siempre requiere corrección.

12.69. Sostenibilidad y ética

Un sistema puede recomendar soluciones con menor huella, pero mayores riesgos sociales o de bienestar.

La gobernanza debe considerar:

- ambiente;

- salud;
- trabajo;
- dependencia;
- equidad.

La sostenibilidad no debe reducirse a carbono.

12.70. Auditoría interna

La auditoría debe revisar:

- inventario;
- clasificación;
- documentación;
- desempeño;
- incidentes;
- cambios;
- formación.

Debe utilizar muestras reales de decisiones.

No basta con revisar políticas.

12.71. Auditoría del modelo

Puede incluir:

- reproducibilidad;
- sesgo;
- robustez;
- calibración;
- seguridad;
- explicación.

La auditoría debe adaptarse al riesgo y finalidad.

12.72. Auditoría de proceso

Incluso un modelo correcto puede implantarse mal.

Debe verificarse:

- integración;
- interfaz;
- actuación;
- supervisión;
- contingencia.

El sistema completo es la unidad real de riesgo.

12.73. Evidencia de cumplimiento

La organización debe poder presentar:

- evaluación;
- validación;
- registros;
- formación;
- incidencias;
- seguimiento.

La existencia de una política genérica no demuestra cumplimiento efectivo.

12.74. Formación y alfabetización en IA

La alfabetización debe adaptarse al puesto.

Dirección

Riesgo, estrategia y responsabilidad.

Usuarios técnicos

Funcionamiento, límites y verificación.

Operarios

Alertas, actuación y contingencia.

IT

Seguridad, integración y mantenimiento.

El AI Act incorpora expresamente la alfabetización en IA dentro de su arquitectura de obligaciones y gobernanza.

12.75. Competencia verificable

No basta con impartir un curso.

Debe comprobarse que el usuario sabe:

- reconocer error;
- interpretar confianza;
- abstenerse;
- escalar;
- documentar.

La competencia puede evaluarse mediante casos prácticos.

12.76. Indicadores de gobernanza

Tabla 22. Síntesis de dimensión y indicador.

Dimensión	Indicador
Inventario	Sistemas registrados
Validación	Modelos con aprobación vigente
Datos	Incidencias de calidad
Supervisión	Overrides revisados
Desempeño	Error y calibración
Seguridad	Vulnerabilidades
Formación	Usuarios competentes
Incidentes	Frecuencia y severidad
Trazabilidad	Decisiones reconstruibles
Proveedor	Auditorías y SLA
Deriva	Alertas atendidas
Contingencia	Pruebas superadas

12.77. Modelo de madurez de gobernanza

Nivel 1. Uso informal

Herramientas sin inventario ni política.

Nivel 2. Control documental

Registro básico y aprobación.

Nivel 3. Gestión del riesgo

Clasificación, validación y responsables.

Nivel 4. Monitorización continua

Deriva, incidentes y auditoría.

Nivel 5. Integración empresarial

Gobernanza conectada con calidad y APPCC.

Nivel 6. Gobernanza adaptativa

Revisión dinámica basada en evidencia.

12.78. Matriz de controles

Tabla 23. Síntesis de riesgo, control preventivo, control detectivo y respuesta.

Riesgo	Control preventivo	Control detectivo	Respuesta
Datos erróneos	Validación de entrada	Alerta de calidad	Abstención
Uso fuera de dominio	Restricción de finalidad	Detector OOD	Bloqueo
Recomendación insegura	Límites duros	Revisión	Override
Deriva	Monitorización	Test estadístico	Recalibración
Ciberataque	Segmentación	Registros	Aislamiento
Actualización defectuosa	Prueba previa	Canary deployment	Rollback
Sesgo	Datos representativos	Métricas por grupo	Reentrenamiento
Alucinación generativa	Fuentes controladas	Verificación	Rechazo
Fallo de proveedor	SLA y salida	Monitorización	Contingencia
Falta de trazabilidad	Logging	Auditoría	CAPA

12.79. Arquitectura de gobernanza

Capa estratégica

- apetito de riesgo;
- política;
- prioridades;
- recursos.

Capa regulatoria

- clasificación;
- obligaciones;
- contratos;
- evidencias.

Capa técnica

- datos;
- modelos;
- seguridad;
- integración.

Capa operativa

- usuarios;
- procedimientos;
- supervisión;
- contingencia.

Capa de aseguramiento

- auditoría;
- incidentes;
- CAPA;
- revisión.

12.80. Expediente del sistema

Cada aplicación crítica debería disponer de un expediente que incluya:

1. descripción;
2. finalidad;
3. clasificación;
4. datos;
5. validación;
6. riesgos;
7. controles;
8. formación;
9. versiones;
10. seguimiento;
11. incidentes;
12. retirada.

Este expediente debe mantenerse durante toda la vida del sistema.

12.81. Integración con APPCC

Cuando la IA interviene en un control relacionado con peligros, debe incorporarse al sistema APPCC.

Debe determinarse:

- peligro;
- medida;
- límite;
- vigilancia;
- corrección;
- verificación;
- registro.

La IA puede formar parte de la vigilancia o predicción, pero no elimina la estructura preventiva.

12.82. IA como prerequisite o medida de control

No toda aplicación constituye un punto crítico de control.

Puede actuar como:

- apoyo;
- prerequisite;
- verificación;
- vigilancia;
- medida de control.

La clasificación debe depender de su relación real con el peligro.

Sobredimensionar su papel puede crear dependencia. Infravalorarlo puede ocultar una función crítica.

12.83. Verificación independiente

Cuando una IA controla un peligro significativo, debe existir verificación independiente:

- análisis;
- inspección;
- segundo sensor;
- revisión.

El sistema no debe verificar exclusivamente su propio desempeño.

12.84. Revisión periódica

La revisión debe activarse por:

- calendario;
- cambio;
- incidente;
- deriva;
- nueva normativa;
- nueva población.

Una revisión anual puede ser insuficiente para sistemas que cambian frecuentemente.

12.85. Retirada del sistema

La empresa debe saber cuándo suspender una aplicación.

Criterios posibles:

- error superior al límite;
- fallo de seguridad;
- datos no fiables;
- ausencia de soporte;
- cambio regulatorio;
- beneficio no demostrado.

La retirada debe conservar registros y asegurar continuidad operativa.

12.86. Proporcionalidad

La gobernanza debe ser proporcional al riesgo.

Un asistente de redacción interna no necesita la misma validación que un sistema de microdosificación.

Pero proporcionalidad no significa ausencia de control.

Incluso herramientas de bajo impacto necesitan:

- uso definido;
- confidencialidad;
- revisión.

12.87. Innovación controlada

La regulación no debe impedir experimentar.

Puede utilizarse:

- entorno de pruebas;
- datos anonimizados;
- modo sombra;
- límites;
- aprobación temporal.

La innovación segura separa exploración y operación.

12.88. Prueba de valor

Además de cumplir, el sistema debe demostrar utilidad.

Puede evaluarse:

$$V = B - (C_{\text{tecnología}} + C_{\text{control}} + C_{\text{error}})$$

Una aplicación que requiere una estructura de control desproporcionada puede no ser viable.

12.89. Confianza justificada

La confianza no debe basarse en:

- marca;
- complejidad;
- apariencia;
- precisión declarada.

Debe basarse en:

- evidencia;
- transparencia;
- desempeño;
- control;
- experiencia.

La confianza justificada es revisable.

12.90. Principios de gobernanza responsable

1. La empresa conserva la responsabilidad por sus decisiones.
2. La clasificación jurídica no sustituye la evaluación sectorial.
3. Todo sistema debe tener finalidad y propietario.
4. Los datos deben ser trazables y representativos.
5. La validación debe preceder al uso.
6. La autonomía debe ser mínima y proporcional.
7. Las restricciones críticas deben ser deterministas.
8. Toda decisión relevante debe poder reconstruirse.
9. Los cambios deben controlarse.
10. Los incidentes deben alimentar la mejora.

12.91. Conclusión: gobernar la decisión, no solo el algoritmo

La regulación de la inteligencia artificial en nutrición animal no puede abordarse como un ejercicio aislado de cumplimiento tecnológico. Los sistemas operan dentro de una cadena ya regulada por obligaciones de seguridad, higiene, trazabilidad, sanidad, responsabilidad y control.

El riesgo no reside únicamente en que un modelo se equivoque. También puede surgir cuando:

- el dato es incorrecto;
- la finalidad se amplía;
- el usuario confía demasiado;
- la interfaz oculta incertidumbre;
- el proveedor actualiza sin control;
- la organización carece de contingencia.

Por ello, la unidad real de gobernanza no es el algoritmo, sino el sistema sociotécnico formado por datos, software, personas, procedimientos, equipos y decisiones.

Una IA jurídicamente bien clasificada puede estar mal gobernada. Una aplicación no considerada legalmente de alto riesgo puede controlar una operación crítica en una fábrica de piensos. La empresa debe combinar el marco horizontal europeo con una evaluación sectorial propia, más próxima a las consecuencias reales.

La mejor gobernanza no es la que produce más documentos, sino la que permite contestar:

- para qué se utiliza;
- con qué datos;
- dentro de qué límites;
- quién responde;
- cómo se verifica;
- qué sucede cuando falla.

La inteligencia artificial debe aumentar la capacidad de control de la organización, no disminuirla.

Cuando una empresa no puede explicar por qué el sistema tomó una decisión, no puede reconstruir qué versión se utilizó o no dispone de un procedimiento para operar sin él, la digitalización ha creado dependencia, no inteligencia.

La gobernanza responsable exige conservar la autoridad humana, pero también mejorarla. No basta con situar a una persona al final de un proceso automatizado. Debe disponer de conocimiento, evidencia, tiempo y capacidad efectiva para revisar.

El propósito final no es impedir que la IA decida, sino asegurar que ninguna decisión relevante quede fuera de una cadena clara de legitimidad, evidencia, supervisión y responsabilidad.

Solo entonces la innovación podrá integrarse en la nutrición animal sin debilitar los principios que sostienen la seguridad de los piensos, la salud de los animales y la confianza de toda la cadena alimentaria.

13. Economía, implantación y escalabilidad de la inteligencia artificial en nutrición animal: del proyecto piloto al valor industrial verificable

La adopción de inteligencia artificial en nutrición animal suele comenzar con una promesa de eficiencia: formular mejor, predecir antes, reducir costes, automatizar controles o mejorar la productividad. Sin embargo, entre una demostración técnica y una implantación rentable existe una distancia considerable.

Numerosos proyectos alcanzan resultados satisfactorios en entornos experimentales y fracasan al integrarse en la operación diaria. Las causas rara vez se limitan al algoritmo. Con frecuencia proceden de:

- datos incompletos;
- falta de integración;
- procesos no estandarizados;
- objetivos ambiguos;
- resistencia organizativa;
- costes ocultos;
- dependencia del proveedor;
- ausencia de responsables;
- falta de validación;
- incapacidad para escalar.

La economía de la inteligencia artificial no puede evaluarse únicamente mediante el precio de la licencia o el ahorro teórico atribuido al modelo. Debe considerar el sistema completo necesario para producir, verificar y mantener la decisión.

Una aplicación aparentemente económica puede requerir nuevas sondas, conectividad industrial, limpieza de datos, interfaces, especialistas, ciberseguridad, formación, auditoría y soporte continuo. Del mismo modo, un sistema con inversión inicial elevada puede generar valor significativo si reduce fallos de alta severidad o mejora de forma sostenida el rendimiento de una operación de gran volumen.

El análisis debe responder a cuatro preguntas:

1. ¿Qué problema económico o técnico se pretende resolver?
2. ¿Qué parte de ese problema puede atribuirse realmente a la IA?
3. ¿Cuál es el coste total de implantar y mantener la solución?
4. ¿Qué evidencia demuestra que el beneficio es real y sostenible?

La inteligencia artificial no debe implantarse porque sea tecnológicamente posible, sino cuando su contribución marginal supera el coste, el riesgo y la complejidad que introduce.

13.1. El problema antes que la tecnología

El punto de partida no debe ser:

¿Dónde podemos utilizar inteligencia artificial?

La pregunta correcta es:

¿Qué decisión o proceso presenta una pérdida, variabilidad o riesgo que no estamos resolviendo adecuadamente?

Los problemas susceptibles de intervención pueden incluir:

- sobredosificación de nutrientes;
- variabilidad de materias primas;
- paradas no planificadas;
- mala predicción de demanda;
- exceso de finos;
- mortalidad evitable;
- desviaciones de mezcla;
- coste elevado de formulación;
- deterioro de inventario;
- retraso en detección sanitaria.

Cada problema debe describirse con una línea basal.

Si no se conoce el rendimiento actual, no puede medirse la mejora.

13.2. Definición económica del caso de uso

Un caso de uso debe vincularse a una función de valor:

$$V = f(\text{ahorro, ingreso, riesgo evitado, capacidad, calidad})$$

El valor puede proceder de:

- reducción de costes;
- aumento de producción;
- reducción de mermas;
- menor consumo energético;
- prevención de incidentes;
- liberación más rápida;
- menor inventario;
- diferenciación comercial.

No todos los beneficios son directamente monetizables. La mejora de trazabilidad, cumplimiento o bienestar puede tener valor estratégico y preventivo.

Sin embargo, incluso estos beneficios deben expresarse mediante indicadores observables.

13.3. Beneficio bruto y beneficio atribuible

El beneficio observado después de implantar un sistema no puede atribuirse automáticamente a la IA.

Durante el proyecto pueden producirse simultáneamente:

- formación;
- limpieza de datos;
- revisión de procedimientos;

- mantenimiento;
- cambio de proveedor;
- nueva formulación;
- mayor atención del personal.

El beneficio atribuible debe estimarse mediante:

$$B_{IA} B_{\text{observado}} B_{\text{otras intervenciones}}$$

En la práctica, esta separación puede ser difícil. Por ello, deben utilizarse:

- grupos de comparación;
- fases;
- análisis temporal;
- pruebas controladas;
- diseños cuasiexperimentales.

13.4. Línea basal

La línea basal debe representar el proceso antes de la intervención.

Puede incluir:

- coste por tonelada;
- consumo energético;
- tasa de errores;
- tiempo de parada;
- conversión;
- variabilidad;
- reclamaciones;
- tiempo de liberación.

La línea basal debe ajustarse por factores externos:

$$Y_{\text{base ajustada}} f(\text{volumen, mix, precio, clima, campaña})$$

Comparar periodos no equivalentes puede atribuir al modelo efectos que proceden de cambios del entorno.

13.5. Coste total de propiedad

El coste total de propiedad puede expresarse:

$$TCO = C_{\text{adquisición}} + C_{\text{integración}} + C_{\text{datos}} + C_{\text{operación}} + C_{\text{mantenimiento}} + C_{\text{riesgo}}$$

Adquisición

- licencias;
- hardware;
- sensores;
- servidores.

Integración

- ERP;
- MES;
- SCADA;
- laboratorio;
- interfaces.

Datos

- limpieza;
- etiquetado;
- almacenamiento;
- validación.

Operación

- soporte;
- computación;
- conectividad;
- supervisión.

Mantenimiento

- recalibración;
- actualizaciones;
- reentrenamiento;
- auditoría.

Riesgo

- indisponibilidad;
- ciberseguridad;
- errores;
- dependencia contractual.

El precio comercial representa solo una parte del coste real.

13.6. Costes de datos

Los datos no son un recurso gratuito.

Su coste incluye:

- captura;
- sensor;
- calibración;
- almacenamiento;
- curación;
- acceso;
- gobernanza.

Puede calcularse:

$$C_D = C_{\text{captura}} + C_{\text{calidad}} + C_{\text{infraestructura}} + C_{\text{cumplimiento}}$$

Un proyecto puede fracasar económicamente si necesita un nivel de datos que la organización no puede sostener.

La viabilidad debe evaluarse con la calidad de datos que existirá en operación, no con un conjunto extraordinariamente limpio preparado para el piloto.

13.7. Coste de oportunidad

Los recursos dedicados a un proyecto no pueden utilizarse en otros.

Debe compararse la IA con alternativas:

- mantenimiento;
- sensores convencionales;
- formación;
- mejora de proceso;
- laboratorio;
- automatización determinista.

La pregunta no es únicamente si la IA produce beneficio, sino si produce más beneficio que la mejor alternativa disponible.

13.8. Valor actual neto

Para proyectos plurianuales puede utilizarse:

$$VAN = \sum_{t=0}^T \frac{B_t - C_t}{(1 + r)^t}$$

donde:

- (B_t): beneficios;
- (C_t): costes;
- (r): tasa de descuento;
- (T): horizonte.

El modelo debe incluir escenarios de:

- beneficio bajo;
- esperado;
- alto;
- abandono;
- crecimiento;
- fallo.

Un VAN positivo basado en una única previsión optimista no constituye evidencia suficiente.

13.9. Retorno sobre la inversión

El retorno puede expresarse:

$$ROI = \frac{B - C}{C} \times 100$$

Pero este indicador tiene limitaciones:

- no considera el tiempo;
- depende del periodo;
- puede omitir riesgo;
- puede exagerarse con beneficios no recurrentes.

Debe acompañarse de:

- VAN;
- plazo de recuperación;
- sensibilidad;
- probabilidad de éxito.

13.10. Plazo de recuperación

El payback indica el tiempo necesario para recuperar la inversión:

$$PP = \min \left\{ t: \sum_{\tau=0}^t (B_{\tau} - C_{\tau}) \geq 0 \right\}$$

Es útil en entornos de incertidumbre tecnológica.

Pero favorece proyectos de corto plazo y puede infravalorar soluciones estratégicas.

13.11. Beneficio esperado ajustado por probabilidad

Los beneficios deben ponderarse por probabilidad:

$$E[B] = \sum_i p_i B_i$$

Ejemplo:

- reducción de energía con alta probabilidad;
- prevención de incidente grave con baja probabilidad;
- aumento de capacidad con probabilidad media.

Los beneficios raros pero severos deben evaluarse mediante análisis de riesgo, no solo mediante promedio.

13.12. Valor del riesgo evitado

Puede definirse:

$$V_R = P_0 L_0 - P_1 L_1$$

donde:

- (P_0): probabilidad antes;
- (L_0): pérdida antes;
- (P_1): probabilidad después;
- (L_1): pérdida después.

Esto permite valorar:

- retirada evitada;
- parada;
- incumplimiento;
- mortalidad;
- error de dosificación.

La dificultad reside en estimar probabilidades con pocos incidentes.

Debe evitarse inflar el caso de negocio utilizando eventos extremos sin base suficiente.

13.13. Valor de la información

Un sistema puede no ejecutar decisiones y, aun así, generar valor al reducir incertidumbre.

El valor de la información es:

$$VOI = E[U \mid \text{información}] - E[U \mid \text{sin información}]$$

$E[U \mid \text{sin información}]$

$C_{\text{información}}$

]

Puede aplicarse a:

- análisis rápido;
- alerta sanitaria;
- predicción de calidad;
- estimación de demanda.

La información solo tiene valor si modifica una decisión.

Un cuadro de mando que no conduce a ninguna acción produce información sin utilidad económica.

13.14. Coste de falsas alarmas

Las falsas alarmas generan:

- tiempo;
- muestreo;
- paradas;
- fatiga;
- pérdida de confianza.

Puede calcularse:

$$C_{FP} = N_{FP} \cdot c_{FP}$$

Pero el coste no es solo directo. Un exceso de falsas alarmas puede hacer que se ignore una alerta verdadera.

13.15. Coste de falsos negativos

Los falsos negativos pueden producir:

- producto no conforme;
- enfermedad;
- pérdida productiva;
- retirada;
- daño reputacional.

$$C_{FN} = N_{FN} \cdot c_{FN}$$

En aplicaciones críticas:

$$c_{FN} \gg c_{FP}$$

Por ello, la métrica económica debe reflejar asimetría.

13.16. Función económica de umbral

El umbral óptimo puede buscar minimizar:

$$C(\tau) = c_{FP}FP(\tau) + c_{FN}FN(\tau)$$

No debe elegirse únicamente para maximizar exactitud.

En control sanitario o seguridad, el umbral también debe respetar límites de riesgo, aunque no sea el mínimo económico.

13.17. Métricas operativas y métricas financieras

Las métricas operativas son necesarias, pero no equivalen automáticamente a valor financiero.

Ejemplos:

- menor error;
- mayor precisión;
- menor latencia;
- más alertas.

Debe demostrarse la cadena:

mejora del modelo → mejor decisión → mejor resultado → valor

Una mejora estadística sin cambio operativo carece de retorno.

13.18. Productividad laboral

La IA puede reducir tareas repetitivas:

- consolidación de datos;
- generación de informes;
- revisión documental;
- monitorización.

Pero el ahorro teórico no siempre se convierte en reducción real de costes.

Si el tiempo liberado se utiliza en actividades de mayor valor, existe ganancia de productividad. Si se añaden nuevas tareas de revisión y corrección, el beneficio puede ser menor.

13.19. Aumento de capacidad

Un sistema puede aumentar toneladas por hora mediante:

- ajuste de proceso;
- menor parada;
- menor cambio;
- mejor planificación.

El valor depende de que exista demanda suficiente.

Aumentar capacidad no genera beneficio si la planta ya opera por debajo de su límite por falta de pedidos.

13.20. Calidad y precio

La mejora de calidad puede producir:

- menor reclamación;
- mayor fidelidad;
- prima;
- acceso a mercado.

Debe evitarse asumir automáticamente que el cliente pagará más.

El valor comercial requiere evidencia de:

- disposición a pagar;
- contrato;
- diferenciación;
- reducción de riesgo del cliente.

13.21. Optimización y transferencia de margen

Una mejora de eficiencia puede beneficiar a:

- fabricante;
- cliente;
- proveedor;
- integrador.

Por ejemplo, reducir el coste de formulación puede trasladarse parcialmente al precio.

El caso de negocio debe identificar quién captura el valor.

No todo beneficio generado se convierte en margen para quien financia el sistema.

13.22. Piloto

El piloto debe diseñarse para probar:

- viabilidad técnica;
- integración;
- adopción;
- impacto;
- coste.

Un piloto que solo demuestra que el modelo puede predecir una variable es incompleto.

Debe incluir el ciclo:

1. dato;
2. recomendación;
3. acción;
4. resultado;
5. evaluación económica.

13.23. Piloto ornamental

Un proyecto es ornamental cuando:

- no tiene propietario;
- no modifica decisiones;
- utiliza datos extraordinarios;
- no integra sistemas;
- no tiene presupuesto de escalado;
- se mantiene como demostración.

Estos proyectos pueden producir presentaciones y visibilidad, pero no transformación.

13.24. Criterios de paso de piloto a producción

Deben definirse antes de comenzar.

Pueden incluir:

- desempeño mínimo;
- ahorro;
- aceptación;
- estabilidad;
- coste;
- seguridad;
- integración;
- contingencia.

La decisión debe ser:

- escalar;
- modificar;
- mantener en observación;
- abandonar.

Mantener indefinidamente un piloto consume recursos sin generar valor.

13.25. Kill criteria

El proyecto debe tener criterios de terminación.

Ejemplos:

- datos insuficientes;
- beneficio inferior al mínimo;
- coste excesivo;
- desempeño inestable;
- riesgo no controlable;
- dependencia inaceptable.

Abandonar a tiempo es una decisión económicamente racional.

13.26. Prueba en sombra

El modo sombra permite evaluar sin afectar la operación.

Puede medir:

- precisión;
- oportunidad;
- discrepancias;
- efecto potencial.

Pero no demuestra adopción ni impacto real.

Un sistema puede predecir correctamente y fracasar porque la recomendación llega tarde o no es aceptada.

13.27. Despliegue gradual

La implantación puede avanzar por:

1. planta;
2. línea;
3. producto;
4. especie;
5. autonomía.

El despliegue gradual limita exposición y facilita aprendizaje.

No debería ampliarse simultáneamente el ámbito y la autonomía.

13.28. Diseño modular

La arquitectura modular permite sustituir componentes:

- sensor;
- modelo;
- interfaz;
- base;
- proveedor.

La modularidad reduce dependencia y facilita escalado.

Pero puede aumentar complejidad de integración.

La decisión debe equilibrar flexibilidad y simplicidad.

13.29. Escalabilidad técnica

Un modelo que funciona con:

- una planta;
- cien lotes;
- una especie;

puede no funcionar con:

- varias plantas;
- millones de registros;
- múltiples equipos;
- diferentes protocolos.

La escalabilidad técnica incluye:

- capacidad;
- latencia;
- disponibilidad;
- almacenamiento;
- interoperabilidad.

13.30. Escalabilidad estadística

Al ampliar el sistema aparecen poblaciones nuevas.

La precisión media puede ocultar peor desempeño en:

- planta minoritaria;
- proveedor nuevo;
- materia poco frecuente;
- clima distinto.

La validación debe repetirse por dominio.

13.31. Escalabilidad organizativa

Cada planta puede tener:

- procesos;
- cultura;
- datos;
- equipos;
- nomenclatura.

Copiar una solución sin adaptar el contexto suele fracasar.

Debe definirse qué elementos son:

- estándar corporativo;
- configuración local;
- excepción.

13.32. Economías de escala

El coste unitario puede disminuir:

$$C_u = \frac{C_f}{N} + C_v$$

donde:

- (C_f): coste fijo;
- (N): número de unidades;
- (C_v): coste variable.

Las plataformas comunes pueden repartir:

- desarrollo;
- seguridad;
- soporte;
- gobernanza.

Pero la centralización excesiva puede ignorar diferencias locales.

13.33. Coste marginal de escalado

El coste de añadir una nueva planta no siempre es bajo.

Puede requerir:

- nuevos sensores;
- mapeo;
- validación;
- formación;
- interfaz.

Debe calcularse:

$$C_{\text{marginal},j} = C_{\text{total con } j} - C_{\text{total sin } j}$$

La expansión debe priorizar unidades con mayor relación entre valor y esfuerzo.

13.34. Efecto de red

Algunos sistemas mejoran con más datos y usuarios.

Pero el efecto de red no es automático.

Más datos pueden introducir:

- heterogeneidad;
- ruido;
- sesgo;
- conflictos.

El valor aumenta cuando existe estandarización y gobernanza.

13.35. Plataforma frente a solución puntual

Una plataforma ofrece:

- integración;
- reutilización;
- gobierno común.

Una solución puntual puede ser:

- más rápida;

- específica;
- barata.

La elección depende del portafolio.

Adquirir una plataforma empresarial para resolver un único problema puede ser excesivo. Acumular aplicaciones aisladas puede crear fragmentación.

13.36. Portafolio de casos de uso

Los proyectos deben priorizarse según:

$$P_i = \frac{V_i \cdot F_i}{C_i \cdot R_i}$$

donde:

- (V_i): valor;
- (F_i): factibilidad;
- (C_i): coste;
- (R_i): riesgo.

Una matriz puede diferenciar:

- alto valor, alta factibilidad;
- alto valor, baja factibilidad;
- bajo valor, alta factibilidad;
- bajo valor, baja factibilidad.

Los primeros proyectos deben generar aprendizaje y credibilidad, no solo visibilidad.

13.37. Quick wins

Un quick win debe:

- resolver un problema real;
- tener bajo riesgo;
- utilizar datos disponibles;
- producir resultado rápido;
- ser escalable.

No debería confundirse con una demostración superficial.

Ejemplos posibles:

- predicción de consumo energético;
- clasificación documental;
- alerta de inventario;
- mantenimiento de equipo no crítico.

13.38. Casos estratégicos

Algunos proyectos requieren mayor plazo:

- formulación adaptativa;
- gemelo digital;
- microbioma;
- control autónomo;
- trazabilidad integral.

Deben descomponerse en etapas con valor intermedio.

13.39. Dependencias entre proyectos

Un sistema de formulación por lote puede depender de:

- NIRS;
- integración de laboratorio;
- identificación;
- base nutricional;
- ERP.

El portafolio debe representar dependencias:

$$G_P = (V_P, E_P)$$

No tiene sentido priorizar una aplicación avanzada si faltan sus capas básicas.

13.40. Hoja de ruta

Una hoja de ruta puede estructurarse en:

Fase 1. Fundamentos

- datos;
- integración;
- gobernanza;
- formación.

Fase 2. Analítica

- visualización;
- control estadístico;
- alertas.

Fase 3. Predicción

- calidad;
- demanda;
- mantenimiento.

Fase 4. Optimización

- formulación;
- producción;
- logística.

Fase 5. Autonomía controlada

- ajustes dentro de límites.

13.41. Gestión del cambio

La implantación modifica:

- tareas;
- autoridad;
- evaluación;
- conocimiento.

La resistencia puede proceder de:

- miedo;
- desconfianza;
- pérdida de autonomía;
- experiencia con sistemas deficientes;
- sobrecarga.

No debe interpretarse automáticamente como falta de innovación.

La resistencia puede revelar riesgos reales ignorados por el proyecto.

13.42. Mapa de grupos de interés

Deben identificarse:

- dirección;
- usuarios;
- calidad;
- IT;
- mantenimiento;
- proveedores;
- clientes.

Para cada grupo:

- beneficio;
- coste;
- temor;
- influencia;
- formación.

La implantación fracasa cuando el beneficio es corporativo y el esfuerzo recae sobre usuarios que no reciben ninguna mejora visible.

13.43. Participación del usuario

Los usuarios deben participar en:

- definición;
- prueba;
- interfaz;
- límites;
- evaluación.

La participación no significa aceptar cualquier preferencia. Significa incorporar conocimiento operativo.

13.44. Diseño centrado en la decisión

La interfaz debe responder:

- qué ocurre;
- por qué importa;
- qué hacer;
- en qué plazo;
- con qué confianza.

Un sistema técnicamente avanzado puede fracasar por presentar información de forma inútil.

13.45. Incentivos

Si los incentivos premian únicamente producción, el personal puede ignorar alertas de calidad.

Si premian ausencia de incidentes, puede ocultarse información.

Los indicadores deben equilibrar:

- producción;
- calidad;
- seguridad;
- aprendizaje.

13.46. Formación

La formación debe cubrir:

- uso;
- interpretación;
- límites;
- contingencia;
- responsabilidad.

Debe adaptarse al rol.

La formación única al inicio es insuficiente cuando el sistema cambia.

13.47. Curva de adopción

La adopción puede seguir:

$$A(t) = \frac{K}{1 + e^{-r(t-t_0)}}$$

Al inicio existe uso limitado, seguido de crecimiento y estabilización.

La organización debe planificar soporte intensivo en las primeras fases.

13.48. Uso nominal y uso efectivo

Un sistema puede estar instalado y no utilizarse realmente.

Debe medirse:

- frecuencia;
- decisiones influenciadas;
- overrides;
- acciones;
- abandono.

La tasa de login no demuestra adopción.

13.49. Override

La modificación humana puede indicar:

- conocimiento superior;
- mala calibración;
- resistencia;
- interfaz deficiente.

Debe analizarse:

$$OR = \frac{\text{recomendaciones modificadas}}{\text{recomendaciones totales}}$$

Un override alto no siempre es negativo. Puede ser apropiado en situaciones fuera de dominio.

13.50. Confianza calibrada

La confianza adecuada no es máxima ni mínima.

Debe corresponder al rendimiento real.

La organización debe evitar:

- confianza ciega;
- rechazo sistemático.

Los usuarios necesitan retroalimentación sobre aciertos, errores y límites.

13.51. Desaprendizaje profesional

Una dependencia prolongada puede reducir habilidades.

Deben conservarse:

- entrenamiento manual;
- revisión;
- ejercicios de contingencia;
- rotación.

La automatización no debe eliminar la capacidad de operar cuando el sistema falla.

13.52. Nuevos perfiles

La implantación puede requerir:

- responsable de producto de IA;
- ingeniero de datos;
- especialista de validación;
- traductor entre dominio y tecnología.

No todas las empresas necesitan crear todos los puestos. Algunas funciones pueden integrarse en roles existentes.

13.53. Compra o desarrollo

Compra

Ventajas:

- rapidez;
- soporte;
- producto probado.

Riesgos:

- dependencia;
- menor personalización;
- opacidad.

Desarrollo interno

Ventajas:

- control;

- adaptación;
- conocimiento.

Riesgos:

- coste;
- escasez de talento;
- mantenimiento.

Puede existir un modelo híbrido.

13.54. Make, buy or partner

La decisión puede evaluarse:

$$S = w_1C + w_2T + w_3K + w_4R$$

donde:

- (C): coste;
- (T): tiempo;
- (K): control del conocimiento;
- (R): riesgo.

Las capacidades estratégicas, como formulación o datos propios, pueden justificar mayor control interno.

13.55. Contratación por resultados

Los contratos pueden vincular pago a:

- ahorro;
- disponibilidad;
- precisión;
- reducción.

Pero deben definir:

- línea basal;
- atribución;
- periodo;
- factores externos.

Una contratación por resultados mal diseñada puede incentivar al proveedor a optimizar la métrica y no el proceso.

13.56. Acuerdos de nivel de servicio

El SLA debe incluir:

- disponibilidad;
- latencia;

- soporte;
- recuperación;
- actualización;
- seguridad.

Para sistemas críticos, el tiempo de recuperación debe alinearse con la capacidad de contingencia.

13.57. Salida del proveedor

Debe existir un plan para:

- exportar datos;
- conservar modelos;
- migrar;
- operar temporalmente;
- archivar registros.

El coste de salida forma parte del TCO.

13.58. Infraestructura local o nube

Local

- control;
- latencia;
- operación sin conexión.

Nube

- escalabilidad;
- mantenimiento;
- acceso.

La decisión debe considerar:

- criticidad;
- conectividad;
- seguridad;
- coste;
- soberanía.

Puede utilizarse una arquitectura híbrida.

13.59. Edge computing

Procesar cerca del equipo reduce latencia y dependencia de red.

Puede ser útil para:

- visión;
- control;

- sensores.

Pero aumenta la necesidad de gestionar múltiples dispositivos y versiones.

13.60. Coste computacional

Los modelos complejos pueden consumir:

- energía;
- hardware;
- tiempo;
- mantenimiento.

Debe evaluarse si una técnica más simple produce resultado equivalente.

La complejidad debe justificarse por valor incremental.

13.61. Deuda técnica

Las soluciones rápidas pueden generar:

- código difícil de mantener;
- integraciones frágiles;
- dependencia de personas;
- documentación deficiente.

La deuda técnica acumula coste futuro:

$$D_{t+1}D_t + d_{\text{nuevo}}d_{\text{resuelto}}$$

Debe presupuestarse su reducción.

13.62. Deuda de datos

Incluye:

- campos inconsistentes;
- etiquetas dudosas;
- silos;
- ausencia de metadatos;
- históricos rotos.

Un proyecto nuevo puede revelar deuda acumulada durante años.

La mejora de datos puede generar valor más allá del caso de uso inicial.

13.63. Deuda de modelo

Un modelo puede quedar:

- obsoleto;

- sin propietario;
- sin documentación;
- sin monitorización.

Cada modelo desplegado crea una obligación de mantenimiento.

La empresa debe limitar su número a aquellos que pueda gobernar.

13.64. ModelOps

La operación del modelo incluye:

- despliegue;
- versión;
- monitorización;
- actualización;
- retirada.

Debe conectarse con:

- calidad;
- IT;
- cambio;
- incidentes.

La fase operativa suele ser más costosa que el desarrollo inicial.

13.65. Reutilización

Los componentes reutilizables pueden incluir:

- conectores;
- validación;
- logging;
- seguridad;
- interfaces;
- catálogo de datos.

La reutilización reduce tiempo y riesgo.

Pero no debe confundirse con reutilizar sin validar el modelo en un dominio distinto.

13.66. Estandarización

Los estándares internos deben definir:

- nomenclatura;
- unidades;
- metadatos;
- métricas;
- documentación;

- aprobación.

La estandarización aumenta escalabilidad y auditabilidad.

13.67. Métrica norte

Cada caso de uso debe tener una métrica principal vinculada al valor.

Ejemplos:

- coste por tonelada;
- tiempo de parada;
- desviación nutricional;
- mortalidad;
- finos;
- energía.

Debe acompañarse de métricas de protección para evitar efectos indeseados.

13.68. Guardrail metrics

Si el objetivo es reducir coste, deben vigilarse:

- calidad;
- salud;
- reclamaciones;
- seguridad.

La mejora económica solo es aceptable si:

$$Y_{\text{objetivo}} \downarrow$$

y simultáneamente:

$$G_j \in \Omega_j$$

para todas las métricas de protección.

13.69. Cuadro de mando de implantación

Tabla 24. Síntesis de dimensión y indicador.

Dimensión	Indicador
Técnica	Precisión y disponibilidad
Operación	Decisiones influenciadas
Adopción	Uso efectivo
Economía	Ahorro y ROI
Calidad	No conformidades

Dimensión	Indicador
Riesgo	Incidentes
Datos	Compleitud
Escalado	Coste marginal
Organización	Formación
Proveedor	Cumplimiento SLA

13.70. Evaluación posterior

La revisión después de implantación debe comprobar:

- beneficio real;
- costes reales;
- efectos no previstos;
- adopción;
- riesgos;
- continuidad.

Debe compararse con el caso de negocio aprobado.

Una desviación negativa no implica siempre fracaso, pero exige explicación y decisión.

13.71. Beneficio erosionado

El beneficio puede disminuir con el tiempo por:

- deriva;
- cambios;
- menor uso;
- competencia;
- costes crecientes.

Debe monitorizarse:

$$B_t = B_0 e^{-\lambda t}$$

si existe erosión.

La renovación del sistema debe basarse en valor actual, no en el éxito inicial.

13.72. Escalado prematuro

Escalar antes de resolver:

- datos;
- integración;
- adopción;
- seguridad;

multiplica los problemas.

La velocidad de expansión debe limitarse por la capacidad de gobernanza.

13.73. Escalado demasiado lento

Mantener durante años aplicaciones útiles en piloto también destruye valor.

Puede deberse a:

- falta de decisión;
- perfeccionismo;
- financiación fragmentada;
- miedo al cambio.

La organización debe definir plazos y responsables.

13.74. Portafolio equilibrado

Debe combinar:

- mejoras rápidas;
- infraestructura;
- investigación;
- proyectos estratégicos.

Invertir solo en casos visibles puede descuidar datos y gobernanza. Invertir solo en infraestructura puede retrasar la demostración de valor.

13.75. Presupuesto por etapas

La financiación puede vincularse a hitos:

1. problema validado;
2. datos suficientes;
3. piloto;
4. impacto;
5. escalado.

Esto reduce riesgo de comprometer capital antes de obtener evidencia.

13.76. Valor estratégico

Algunas capacidades pueden no generar retorno inmediato, pero proporcionar:

- autonomía;
- conocimiento;
- diferenciación;
- preparación regulatoria;
- barrera competitiva.

El valor estratégico debe describirse explícitamente y no utilizarse como justificación vaga para cualquier gasto.

13.77. Ventaja competitiva

Un modelo genérico accesible a todos difícilmente crea ventaja sostenible.

La ventaja puede residir en:

- datos propios;
- integración;
- proceso;
- velocidad;
- conocimiento;
- confianza.

La tecnología comercial se convierte en ventaja cuando se integra con capacidades difíciles de imitar.

13.78. Commoditización

Las herramientas de IA tienden a abarataarse y estandarizarse.

La empresa debe evitar pagar una prima permanente por funciones que pronto serán comunes.

Debe diferenciar entre:

- capacidad estratégica;
- commodity tecnológica.

13.79. Innovación abierta

La colaboración con:

- universidades;
- centros;
- startups;
- proveedores;
- clientes;

puede acelerar aprendizaje.

Debe definir:

- propiedad;
- datos;
- publicación;
- explotación;
- confidencialidad.

13.80. Prueba de concepto académica e implantación industrial

Un estudio académico busca demostrar una hipótesis.

La implantación industrial debe garantizar:

- continuidad;
- integración;
- soporte;
- seguridad;
- coste.

Ambos objetivos son legítimos, pero distintos.

No debe exigirse a una prueba científica que opere como producto, ni aceptar un prototipo como sistema industrial.

13.81. Benchmarking

La comparación con otras empresas puede ayudar, pero debe considerar:

- escala;
- especie;
- geografía;
- madurez;
- datos.

Copiar objetivos de una organización distinta puede ser contraproducente.

13.82. Inflación de expectativas

Las expectativas suelen evolucionar desde entusiasmo a decepción y, posteriormente, uso realista.

La dirección debe comunicar:

- alcance;
- límites;
- fases;
- incertidumbre.

Prometer autonomía total genera rechazo cuando aparecen las primeras limitaciones.

13.83. Narrativa interna

La implantación debe explicarse como:

- mejora de decisiones;
- reducción de trabajo improductivo;
- apoyo técnico;
- seguridad.

Presentarla como sustitución de profesionales aumenta resistencia y puede empobrecer el conocimiento.

13.84. Ética económica

La reducción de costes no debe producir:

- precarización;
- vigilancia desproporcionada;
- pérdida de responsabilidad;
- deterioro del bienestar.

La eficiencia debe evaluarse junto con sus efectos distributivos.

13.85. Distribución del beneficio

Debe analizarse quién gana y quién asume el coste:

- empresa;
- trabajador;
- proveedor;
- cliente;
- productor;
- animal.

Una implantación sostenible necesita una distribución razonable de incentivos.

13.86. Decisión de no automatizar

No automatizar puede ser correcto cuando:

- el volumen es bajo;
- el proceso cambia mucho;
- el error es severo;
- los datos son insuficientes;
- el juicio experto es esencial.

La madurez tecnológica incluye reconocer dónde la IA no aporta valor.

13.87. Simplicidad preferible

Un modelo simple puede ser superior si:

- es interpretable;
- requiere menos datos;
- se mantiene fácilmente;
- obtiene rendimiento suficiente.

La comparación debe incluir:

valor neto rendimiento complejidad

13.88. Matriz de decisión de inversión

Tabla 25. Síntesis de criterio y pregunta.

Criterio	Pregunta
Problema	¿Está cuantificado?
Datos	¿Son suficientes y sostenibles?
Acción	¿La salida cambia una decisión?
Valor	¿Existe beneficio verificable?
Riesgo	¿Puede controlarse?
Integración	¿Es viable?
Usuario	¿Adoptará el sistema?
Escala	¿Puede replicarse?
Proveedor	¿Existe salida?
Gobierno	¿Puede mantenerse?

13.89. Modelo de madurez económica

Nivel 1. Experimentación

Proyectos sin caso económico estructurado.

Nivel 2. Evaluación

Costes y beneficios básicos.

Nivel 3. Portafolio

Priorización y criterios de avance.

Nivel 4. Escalado

Plataformas y reutilización.

Nivel 5. Optimización

Valor monitorizado continuamente.

Nivel 6. Capital dinámico

Recursos reasignados según evidencia real.

13.90. Principios de implantación rentable

1. Definir el problema antes que la solución.
2. Medir la línea basal.
3. Calcular el coste total.

4. Separar beneficio observado y atribuible.
5. Diseñar pilotos que incluyan acción.
6. Establecer criterios de abandono.
7. Escalar gradualmente.
8. Medir adopción efectiva.
9. Mantener métricas de protección.
10. Revisar el valor durante toda la vida del sistema.

13.91. Conclusión: la IA solo crea valor cuando transforma una decisión sostenible

La inteligencia artificial aplicada a nutrición animal puede generar beneficios importantes. Puede reducir costes de formulación, anticipar fallos, mejorar la utilización de nutrientes, disminuir mermas, aumentar capacidad y prevenir incidentes.

Sin embargo, el valor no reside en la precisión aislada del modelo. Surge cuando una predicción se integra en una decisión, la decisión modifica una acción y la acción mejora un resultado que puede demostrarse.

La cadena de valor puede resumirse:

dato → modelo → decisión → acción → resultado → valor

Cualquier ruptura en esta secuencia destruye la rentabilidad.

Una organización puede disponer de modelos excelentes y obtener poco beneficio si:

- no confía en ellos;
- no modifica procesos;
- no integra sistemas;
- no mide resultados;
- no mantiene los datos.

La implantación responsable exige también reconocer los costes invisibles: curación de datos, validación, soporte, formación, ciberseguridad, gobernanza y dependencia tecnológica. Ignorarlos produce casos de negocio artificialmente favorables.

El piloto debe considerarse una hipótesis empresarial, no una celebración tecnológica. Debe demostrar que el sistema funciona con datos reales, que los usuarios pueden operarlo, que el riesgo es aceptable y que el beneficio supera el coste total.

Escalar no consiste en copiar software. Consiste en reproducir una capacidad de decisión dentro de contextos diferentes sin perder control, calidad o responsabilidad.

La organización madura no es la que acumula más proyectos de IA, sino la que selecciona mejor, abandona a tiempo, escala con disciplina y mantiene solo los sistemas que continúan generando valor.

La inteligencia artificial debe competir por recursos frente a otras inversiones. Si una calibración, un mantenimiento, un cambio de procedimiento o una formación convencional resuelven el problema con menor coste y riesgo, esa será la decisión correcta.

La innovación tecnológica no constituye por sí misma una estrategia. Solo se convierte en estrategia cuando se vincula con prioridades, capacidades y resultados.

En nutrición animal, el criterio final debe ser especialmente exigente. La mejora económica no puede separarse de la calidad del pienso, la salud de los animales, la seguridad de la cadena y la capacidad de explicar cada decisión relevante.

La IA rentable no es aquella que parece más avanzada, sino aquella que resuelve un problema real, se integra en la operación, conserva el conocimiento profesional y produce beneficios verificables sin trasladar costes ocultos al futuro.

14. Capital humano, competencias y organización del conocimiento: el profesional de la nutrición animal en sistemas aumentados por inteligencia artificial

La transformación digital de la nutrición animal no depende exclusivamente de sensores, plataformas, algoritmos o capacidad de cálculo. Su eficacia está condicionada por la competencia de las personas que formulan, producen, validan, interpretan, mantienen y supervisan los sistemas.

La inteligencia artificial modifica la distribución del trabajo cognitivo. Algunas tareas que antes exigían cálculo, búsqueda o revisión manual pueden automatizarse parcialmente. Otras adquieren mayor relevancia:

- formulación del problema;
- evaluación de la calidad del dato;
- interpretación contextual;
- validación biológica;
- gestión de excepciones;
- supervisión del riesgo;
- comunicación de incertidumbre;
- responsabilidad decisional.

Este cambio no elimina la necesidad de expertos. Modifica el tipo de pericia que la organización necesita y la forma en que esa pericia se integra en los procesos.

Un modelo puede evaluar millones de combinaciones nutricionales, pero no comprende por sí mismo el significado industrial, sanitario, económico o regulatorio de cada alternativa. Puede detectar una correlación entre un patrón de consumo y una reducción de productividad, pero necesita contexto para distinguir entre enfermedad, cambio ambiental, error de sensor, alteración del pienso o una transición fisiológica esperable.

La inteligencia artificial amplía la capacidad analítica. El conocimiento profesional determina si esa capacidad se utiliza de manera pertinente.

La cuestión central no consiste en decidir si las máquinas sustituirán a los nutricionistas, veterinarios, responsables de calidad u operarios. Consiste en diseñar organizaciones en las que personas y sistemas se complementen sin que la automatización degrade el conocimiento, diluya la responsabilidad o transforme al profesional en un mero aprobador formal de decisiones que ya no comprende.

14.1. Del trabajo manual al trabajo cognitivo supervisado

La automatización clásica sustituyó principalmente tareas físicas o repetitivas. La IA interviene también sobre actividades cognitivas:

- clasificación;
- predicción;
- optimización;
- redacción;
- interpretación preliminar;
- búsqueda de patrones.

Esto desplaza el trabajo desde la ejecución directa hacia:

- definición de objetivos;
- revisión;
- resolución de excepciones;
- evaluación de consecuencias.

Puede representarse:

$$T_{\text{profesional}} T_{\text{ejecución}} + T_{\text{interpretación}} + T_{\text{supervisión}} + T_{\text{decisión}}$$

Con la automatización:

$$T_{\text{ejecución}} \downarrow$$

mientras que deberían aumentar:

$$T_{\text{interpretación}}, T_{\text{supervisión}}, T_{\text{decisión}}$$

El riesgo aparece cuando la organización reduce el tiempo de ejecución, pero no asigna recursos suficientes a la supervisión.

14.2. El profesional aumentado

El profesional aumentado utiliza la IA para ampliar:

- memoria;
- velocidad;
- comparación;
- detección;
- simulación.

No delega sin control la finalidad ni la responsabilidad.

En nutrición animal, un profesional aumentado puede:

- comparar miles de formulaciones;
- detectar desviaciones de materias;
- simular respuestas;
- anticipar riesgos;
- consultar evidencia;
- generar escenarios.

Su ventaja no procede de competir con el algoritmo en capacidad de cálculo, sino de combinar la potencia computacional con:

- criterio biológico;
- experiencia industrial;
- conocimiento regulatorio;
- comprensión económica;
- juicio ético.

14.3. Competencia técnica y competencia decisional

La competencia técnica permite utilizar una herramienta.

La competencia decisional permite determinar:

- cuándo utilizarla;
- cuándo desconfiar;
- cuándo abstenerse;
- cuándo escalar;
- cuándo rechazar la salida.

Una persona puede manejar correctamente la interfaz y carecer de capacidad para evaluar el resultado.

La formación debe superar la enseñanza instrumental.

14.4. Alfabetización en inteligencia artificial

La alfabetización en IA no exige que todos los profesionales sepan programar modelos.

Sí requiere comprender conceptos como:

- dato de entrenamiento;
- validación;
- probabilidad;
- incertidumbre;
- sesgo;
- sobreajuste;
- deriva;
- correlación;
- causalidad;
- explicabilidad;
- límites de dominio.

La profundidad debe adaptarse a cada función.

14.5. Mapa de competencias

Puede organizarse en cinco dominios.

Competencia de dominio

- nutrición;
- veterinaria;
- tecnología de piensos;
- calidad;
- regulación.

Competencia de datos

- calidad;

- unidades;
- trazabilidad;
- interpretación;
- estadística.

Competencia algorítmica

- funcionamiento;
- métricas;
- limitaciones;
- validación.

Competencia operativa

- integración;
- procedimientos;
- contingencia;
- documentación.

Competencia ética y jurídica

- responsabilidad;
- seguridad;
- confidencialidad;
- bienestar;
- transparencia.

La organización necesita una combinación de estos dominios, aunque no todos deban concentrarse en una única persona.

14.6. Perfil del nutricionista aumentado

El nutricionista deberá conservar el dominio de:

- fisiología;
- requerimientos;
- digestibilidad;
- materias primas;
- interacciones;
- tecnología;
- formulación.

A ello se añaden nuevas competencias:

- interpretar intervalos;
- evaluar modelos;
- revisar datos;
- formular objetivos multicriterio;
- detectar extrapolaciones;
- documentar decisiones.

Su función se desplaza desde calcular una fórmula hacia gobernar un sistema de decisiones nutricionales.

14.7. Del formulador al arquitecto de restricciones

La formulación asistida por IA exige definir correctamente:

- objetivos;
- límites;
- penalizaciones;
- escenarios;
- incertidumbre.

El profesional se convierte en arquitecto de restricciones.

Una función mal definida puede producir una solución matemáticamente óptima y biológicamente inadecuada.

$$x^* \underset{x}{\operatorname{argmin}} J(x)$$

solo tiene valor si:

$$x \in \Omega_{\text{nutricional}} \cap \Omega_{\text{tecnológica}} \cap \Omega_{\text{seguridad}}$$

El conocimiento experto define (Ω).

14.8. Perfil del veterinario aumentado

El veterinario puede utilizar IA para:

- detección temprana;
- estratificación;
- vigilancia;
- análisis de comportamiento;
- apoyo diagnóstico.

Pero debe conservar la capacidad para:

- explorar;
- integrar signos;
- valorar historia;
- interpretar pruebas;
- descartar causas;
- decidir tratamiento.

La predicción no equivale a diagnóstico.

14.9. Perfil del responsable de calidad

La calidad debe evolucionar desde la revisión documental hacia la supervisión de sistemas digitales.

Nuevas funciones incluyen:

- validar datos;
- revisar modelos;
- auditar logs;
- evaluar cambios;
- investigar incidentes algorítmicos;
- conectar IA con APPCC.

La calidad no debe limitarse a comprobar que existe documentación. Debe evaluar si el sistema funciona de acuerdo con su finalidad.

14.10. Perfil del operario digital

El operario continúa siendo una fuente esencial de conocimiento.

Puede detectar:

- sonido;
- olor;
- textura;
- vibración;
- comportamiento anormal.

Muchos de estos indicios no están completamente sensorizados.

El operario digital debe saber:

- interpretar alarmas;
- verificar condiciones;
- operar en manual;
- documentar excepciones;
- cuestionar recomendaciones.

La automatización no debe convertirlo en espectador pasivo.

14.11. Perfil del técnico de mantenimiento

El mantenimiento predictivo requiere combinar:

- mecánica;
- electricidad;
- automatización;
- datos.

El técnico debe interpretar:

- tendencias;
- probabilidad de fallo;
- vida útil estimada;
- falsos positivos.

La experiencia física sigue siendo esencial para distinguir un patrón algorítmico de un fallo real.

14.12. Nuevos perfiles híbridos

Pueden surgir funciones como:

- especialista en datos nutricionales;
- responsable de validación de modelos;
- product owner de IA;
- ingeniero de conocimiento;
- auditor de sistemas algorítmicos;
- traductor entre ciencia y tecnología.

Estas funciones no siempre requieren crear nuevos departamentos. Pueden distribuirse entre equipos existentes.

Lo importante es que estén asignadas.

14.13. El traductor de dominio

Uno de los perfiles más críticos es quien puede convertir un problema sectorial en un problema analítico.

Debe comprender:

- necesidad;
- dato;
- decisión;
- métrica;
- consecuencia.

Un científico de datos puede optimizar una métrica incorrecta si el problema no se ha formulado adecuadamente.

El traductor de dominio evita esta desconexión.

14.14. Equipos multidisciplinarios

Los proyectos deben integrar, según su alcance:

- nutrición;
- veterinaria;
- producción;
- calidad;
- datos;
- IT;
- regulación;
- economía.

La multidisciplinariedad no consiste en reunir personas al final para aprobar el sistema.

Debe intervenir desde:

- definición;

- diseño;
- validación;
- implantación;
- revisión.

14.15. Lenguajes profesionales diferentes

Cada disciplina utiliza conceptos distintos.

El científico de datos puede hablar de:

- accuracy;
- recall;
- drift;
- feature importance.

El nutricionista puede hablar de:

- digestibilidad;
- margen;
- respuesta;
- antagonismo.

El operario puede describir:

- atasco;
- vibración;
- textura;
- comportamiento de la línea.

La organización debe crear un vocabulario común.

14.16. Diccionario corporativo

Un diccionario puede definir:

- variable;
- unidad;
- significado;
- fuente;
- responsable;
- uso.

Esto evita que distintos equipos utilicen el mismo término con significados diferentes.

La semántica es una infraestructura del conocimiento.

14.17. Conocimiento explícito y tácito

El conocimiento explícito puede documentarse:

- procedimientos;
- fórmulas;
- especificaciones;
- límites.

El conocimiento tácito procede de la experiencia:

- señales débiles;
- excepciones;
- intuición;
- contexto.

La IA utiliza con mayor facilidad conocimiento explícito.

La transformación digital debe capturar parte del conocimiento tácito sin asumir que puede formalizarse por completo.

14.18. Riesgo de pérdida de conocimiento

Cuando una tarea se automatiza, los profesionales pueden dejar de practicarla.

Con el tiempo disminuye la capacidad para:

- detectar error;
- operar manualmente;
- formar a nuevos empleados;
- reconstruir el razonamiento.

Puede expresarse:

$$K_{t+1} = K_t + A_t D_t$$

donde:

- (A_t): aprendizaje;
- (D_t): degradación.

Si la automatización reduce (A_t), el conocimiento puede erosionarse.

14.19. Desaprendizaje por automatización

El desaprendizaje ocurre cuando el sistema realiza habitualmente una tarea y la persona pierde competencia.

Ejemplos:

- formular manualmente;
- interpretar curvas;
- diagnosticar por observación;
- ajustar equipos;
- reconstruir trazabilidad.

La organización debe identificar capacidades críticas que deben conservarse.

14.20. Ejercicios en modo manual

Pueden realizarse pruebas periódicas sin asistencia total:

- formulación;
- contingencia;
- retirada;
- control de proceso;
- diagnóstico técnico.

El objetivo no es renunciar a la IA, sino verificar que la empresa puede operar cuando falla.

14.21. Automatización y autoridad

La introducción de IA puede alterar quién tiene autoridad.

Un sistema central puede reducir la autonomía de:

- nutricionistas locales;
- responsables de planta;
- veterinarios de campo.

La centralización puede mejorar consistencia y eliminar conocimiento contextual.

Debe definirse qué decisiones son:

- corporativas;
- locales;
- compartidas.

14.22. Autoridad formal y autoridad real

Puede existir una persona formalmente responsable, mientras la decisión real viene determinada por el sistema.

Si el profesional no dispone de capacidad para modificar o rechazar, la supervisión es aparente.

La responsabilidad debe corresponder con autoridad efectiva.

14.23. Delegación algorítmica

La delegación debe especificar:

- qué se delega;
- dentro de qué límites;
- durante cuánto tiempo;
- bajo qué supervisión.

No debe ser una transferencia indefinida y ambigua.

14.24. Matriz RACI

Puede utilizarse una matriz:

- Responsible;
- Accountable;
- Consulted;
- Informed.

Para cada sistema debe definirse quién:

- desarrolla;
- valida;
- aprueba;
- utiliza;
- mantiene;
- audita.

Una misma decisión no debe quedar sin responsable porque intervienen muchos actores.

14.25. Responsabilidad distribuida

La colaboración multidisciplinar puede diluir responsabilidad.

Frases como:

- “lo decidió el modelo”;
- “lo configuró IT”;
- “lo aprobó calidad”;
- “lo pidió producción”;

revelan fragmentación.

La organización debe conservar una cadena clara de responsabilidad.

14.26. Diseño del trabajo

La automatización debe analizar cómo cambia:

- carga;
- ritmo;
- variedad;
- autonomía;
- responsabilidad.

Eliminar tareas repetitivas puede mejorar el trabajo. Pero añadir monitorización constante y alarmas puede aumentar estrés.

El diseño debe evaluar el puesto completo.

14.27. Carga cognitiva

La carga puede representarse:

$$CL = f(N_{\text{alertas}}, C_{\text{decisión}}, T_{\text{disponible}}, U)$$

donde (U) representa incertidumbre.

El sistema debe reducir la carga irrelevante y preservar la atención para decisiones críticas.

14.28. Fatiga de alarmas

La fatiga aparece cuando la frecuencia supera la capacidad de respuesta.

Consecuencias:

- retraso;
- ignorancia;
- desactivación;
- aceptación automática.

Debe medirse:

$$AR = \frac{\text{alertas atendidas}}{\text{alertas emitidas}}$$

Pero una alta tasa de atención no garantiza calidad si la respuesta es superficial.

14.29. Priorización de alertas

Las alertas deben clasificarse según:

- severidad;
- urgencia;
- confianza;
- reversibilidad.

Puede definirse:

$$P_a = S \cdot U \cdot C$$

Una alerta de baja confianza y elevada severidad puede requerir verificación inmediata, no ignorancia.

14.30. Interfaz humano-máquina

La interfaz debe mostrar:

- estado;
- recomendación;
- fundamento;
- confianza;

- acción;
- consecuencias.

Debe evitar:

- exceso de precisión;
- colores engañosos;
- mensajes absolutos;
- confirmaciones automáticas.

El diseño visual condiciona la conducta.

14.31. Efecto de encuadre

Presentar:

90 % de probabilidad de seguridad

no produce la misma percepción que:

10 % de riesgo de fallo.

La interfaz debe comunicar el riesgo de forma equilibrada.

14.32. Automatización complaciente

Cuando el sistema funciona durante largos periodos, disminuye la vigilancia humana.

La probabilidad de detectar un fallo raro puede reducirse precisamente porque el modelo suele acertar.

Deben utilizarse:

- pruebas;
- simulaciones;
- revisión de excepciones;
- rotación.

14.33. Confianza calibrada

La confianza profesional debería aproximarse al desempeño real:

$$C_h \approx P(\text{acierto})$$

Si:

$$C_h > P(\text{acierto})$$

existe sobreconfianza.

Si:

$$C_h < P(\text{acierto})$$

existe infrautilización.

La calibración requiere transparencia y retroalimentación.

14.34. Formación basada en errores

La formación no debe mostrar únicamente ejemplos exitosos.

Debe incluir:

- falsos positivos;
- falsos negativos;
- datos incompletos;
- deriva;
- conflictos;
- alucinaciones.

Aprender a reconocer el fallo es más importante que memorizar funciones.

14.35. Aprendizaje por casos

Los casos deben reproducir situaciones reales:

- lote atípico;
- señal contradictoria;
- recomendación inviable;
- alerta urgente;
- fallo de conexión.

El usuario debe practicar decisión, no solo navegación.

14.36. Evaluación de competencia

La competencia puede medirse mediante:

- casos;
- simulaciones;
- observación;
- auditoría;
- revisión de decisiones.

La asistencia a un curso no demuestra capacidad.

14.37. Niveles de formación

Nivel básico

Conceptos, riesgos y uso permitido.

Nivel usuario

Interpretación, verificación y escalado.

Nivel especialista

Validación, métricas y configuración.

Nivel responsable

Gobernanza, riesgo y responsabilidad.

Nivel auditor

Evidencia, trazabilidad y control.

14.38. Formación continua

La competencia debe actualizarse cuando cambien:

- modelo;
- interfaz;
- finalidad;
- regulación;
- datos.

La formación no es un evento inicial, sino parte del ciclo de vida.

14.39. Gestión del conocimiento documental

La documentación debe incluir:

- procedimientos;
- guías;
- ejemplos;
- decisiones;
- errores;
- lecciones.

Debe ser:

- accesible;
- versionada;
- actual;
- comprensible.

Una base documental extensa pero obsoleta puede aumentar el riesgo.

14.40. Recuperación aumentada del conocimiento

Los asistentes internos pueden facilitar consulta sobre:

- procedimientos;
- fichas;
- legislación;
- incidencias.

Pero deben recuperar fuentes aprobadas y mostrar su origen.

El sistema no debe responder con seguridad cuando la documentación es insuficiente o contradictoria.

14.41. Curación del conocimiento

La incorporación de documentos debe pasar por:

- selección;
- revisión;
- clasificación;
- versión;
- retirada.

La IA no corrige automáticamente una base documental deficiente.

14.42. Conocimiento vivo

El conocimiento operativo cambia con:

- materias;
- equipos;
- regulación;
- experiencia.

Debe existir un proceso para convertir incidencias y mejoras en documentación.

$$K_{t+1}K_t + L_{\text{incidentes}} + L_{\text{proyectos}}K_{\text{obsoleto}}$$

14.43. Comunidades de práctica

Los profesionales pueden compartir:

- casos;
- errores;
- interpretaciones;
- configuraciones;
- soluciones.

Esto evita que el conocimiento quede aislado por planta o departamento.

La comunidad debe distinguir entre aprendizaje y cambio formal de procedimiento.

14.44. Lecciones aprendidas

Cada incidente o proyecto debe generar una lección que responda:

- qué ocurrió;
- por qué;
- cómo se detectó;
- qué se cambió;
- dónde más puede ocurrir.

La lección debe traducirse en una acción verificable.

14.45. Retención del conocimiento experto

La jubilación o salida de especialistas puede provocar pérdida crítica.

La IA puede apoyar entrevistas estructuradas, organización de casos y recuperación de experiencias.

Pero no debe reducir al experto a una fuente de datos sin reconocimiento ni participación.

14.46. Mentorización aumentada

Un sistema puede apoyar a profesionales menos experimentados mediante:

- recomendaciones;
- casos similares;
- alertas;
- explicaciones.

La mentorización humana sigue siendo necesaria para transmitir:

- criterio;
- prudencia;
- cultura;
- responsabilidad.

14.47. Riesgo de homogeneización

Si toda la organización utiliza el mismo sistema, las decisiones pueden volverse más consistentes.

También pueden compartir el mismo error.

La diversidad de criterios puede actuar como defensa.

14.48. Disenso profesional

Debe existir espacio para contradecir al sistema y a la mayoría.

El disenso razonado puede detectar:

- deriva;
- sesgo;
- error de datos;
- simplificación.

La cultura no debe penalizar el override justificado.

14.49. Registro del desacuerdo

Cuando un profesional rechaza una recomendación, debería registrar:

- razón;
- evidencia;
- acción;
- resultado.

Esto transforma el desacuerdo en aprendizaje.

14.50. Aprendizaje de overrides

Los overrides pueden utilizarse como datos, pero no incorporarse automáticamente.

Algunos serán correctos y otros reflejarán resistencia o error.

Deben revisarse y etiquetarse.

14.51. Cultura de seguridad psicológica

Las personas deben poder comunicar:

- dudas;
- errores;
- limitaciones;
- usos indebidos.

Si reconocer un fallo tiene consecuencias desproporcionadas, los problemas se ocultarán.

La seguridad psicológica es una condición de gobernanza.

14.52. Cultura de evidencia

Las decisiones deben apoyarse en:

- datos;
- razonamiento;
- documentación;
- resultado.

La experiencia sigue siendo válida, pero debe poder explicarse.

La IA no debe utilizarse como argumento de autoridad.

14.53. Mitos de objetividad

Los modelos reflejan:

- selección de datos;
- objetivos;
- etiquetas;
- umbrales;
- decisiones humanas.

No son neutrales por ser matemáticos.

La formación debe desmontar la idea de que el algoritmo elimina el juicio.

14.54. Ética profesional

Los profesionales deben considerar:

- salud;
- bienestar;
- seguridad;
- sostenibilidad;
- honestidad.

La IA puede recomendar la solución económicamente óptima, pero no determinar por sí sola qué es aceptable.

14.55. Conflicto entre objetivos

Puede existir presión para maximizar:

- rendimiento;
- margen;
- velocidad.

El profesional debe poder detener o cuestionar decisiones que comprometan:

- seguridad;
- bienestar;
- legalidad.

La autoridad ética debe estar respaldada organizativamente.

14.56. Vigilancia de trabajadores

Los sistemas pueden registrar:

- productividad;
- movimientos;
- respuestas;
- errores.

Esto puede mejorar seguridad, pero también generar vigilancia desproporcionada.

Debe existir:

- finalidad;
- proporcionalidad;
- transparencia;
- límites;
- acceso.

14.57. Evaluación algorítmica del desempeño

Una puntuación automática puede ignorar contexto:

- turno;
- equipo;
- carga;
- incidencias;
- formación.

No debería utilizarse como único criterio para sanciones o promociones.

14.58. Impacto sobre empleo

La IA puede:

- sustituir tareas;
- transformar puestos;
- crear funciones;
- aumentar productividad.

El impacto no es uniforme.

La organización debe anticipar:

- reconversión;
- formación;
- movilidad;
- pérdida de funciones.

14.59. Automatización y polarización

Puede aumentar la demanda de perfiles altamente cualificados y reducir tareas intermedias.

Esto puede producir:

- dependencia de pocos especialistas;
- desigualdad;
- dificultad de sucesión.

La estrategia de talento debe evitar concentrar todo el conocimiento técnico en una pequeña élite.

14.60. Democratización del conocimiento

Los asistentes pueden facilitar acceso a:

- literatura;
- procedimientos;
- cálculos;
- interpretación preliminar.

Esto puede reducir barreras.

Pero existe riesgo de confundir acceso a información con competencia profesional.

14.61. Desarrollo de carrera

Los itinerarios profesionales deben incluir capacidades digitales.

Ejemplo:

- técnico de formulación;
- especialista de datos nutricionales;
- responsable de modelos;
- director de sistemas de decisión.

La progresión debe reconocer tanto experiencia de dominio como competencia tecnológica.

14.62. Atracción de talento

La industria compite por perfiles de:

- datos;
- automatización;
- bioinformática;
- sostenibilidad.

Debe ofrecer proyectos con:

- impacto real;
- acceso a datos;
- desarrollo;
- gobernanza.

La tecnología obsoleta y los datos desorganizados dificultan atraer y retener talento.

14.63. Colaboración con universidades

Puede apoyar:

- formación;
- investigación;
- prácticas;
- doctorados;
- validación.

La colaboración debe conectar resultados académicos con problemas industriales sin reducir la independencia científica.

14.64. Formación dual

La combinación de empresa y centro educativo puede preparar perfiles que comprendan:

- ciencia;
- proceso;
- datos;
- operación.

La formación exclusivamente teórica o exclusivamente instrumental puede ser insuficiente.

14.65. Certificación de competencias

Las certificaciones pueden acreditar conocimientos básicos, pero no sustituyen experiencia contextual.

La empresa debe evaluar competencia específica para cada sistema.

14.66. Rotación entre funciones

La rotación temporal entre:

- formulación;
- fábrica;
- calidad;
- granja;
- datos;

mejora comprensión sistémica.

Los modelos fallan con frecuencia en las interfaces entre departamentos.

14.67. Equipos centralizados y distribuidos

Modelo centralizado

Ventajas:

- estándar;
- economía de escala;
- especialización.

Riesgos:

- distancia del proceso;
- lentitud;
- soluciones genéricas.

Modelo distribuido

Ventajas:

- contexto;
- rapidez;
- apropiación.

Riesgos:

- duplicidad;
- inconsistencia;
- shadow AI.

Puede utilizarse un modelo federado.

14.68. Centro de excelencia

Un centro de excelencia puede proporcionar:

- estándares;
- arquitectura;
- validación;
- formación;
- soporte.

No debe convertirse en un cuello de botella ni aislarse de la operación.

14.69. Modelo federado

Puede combinar:

- gobierno central;
- propiedad local;
- componentes comunes;
- adaptación controlada.

La matriz debe definir qué puede modificarse localmente.

14.70. Product owner del sistema

El product owner conecta:

- usuario;
- negocio;
- tecnología;
- riesgo.

Debe priorizar:

- necesidades;
- mejoras;
- incidencias;

- deuda.

No debe limitarse a gestionar un calendario tecnológico.

14.71. Ciclo de aprendizaje organizativo

Puede representarse:

observar → interpretar → decidir → actuar → aprender

La IA puede acelerar observación e interpretación.

La organización debe conservar la capacidad de decidir y aprender.

14.72. Aprendizaje de circuito simple y doble

Circuito simple

Corrige la desviación sin cuestionar el objetivo.

Circuito doble

Revisa:

- objetivo;
- supuesto;
- procedimiento;
- modelo.

La IA puede optimizar un proceso incorrecto si la organización solo practica aprendizaje de circuito simple.

14.73. Métricas de capital humano

Tabla 26. Síntesis de dimensión y indicador.

Dimensión	Indicador
Competencia	Usuarios evaluados
Adopción	Uso efectivo
Calidad	Errores de interpretación
Supervisión	Overrides justificados
Conocimiento	Procedimientos actualizados
Resiliencia	Capacidad manual
Formación	Recertificación
Cultura	Incidentes comunicados
Colaboración	Proyectos multidisciplinarios
Sucesión	Roles críticos cubiertos

14.74. Matriz de competencias por función

Tabla 27. Síntesis de función, dominio, datos, ia, riesgo y operación.

Función	Dominio	Datos	IA	Riesgo	Operación
Dirección	Medio	Básico	Medio	Alto	Medio
Nutrición	Alto	Alto	Medio-alto	Alto	Medio
Veterinaria	Alto	Medio-alto	Medio	Alto	Medio
Calidad	Alto	Alto	Medio-alto	Alto	Alto
Producción	Alto	Medio	Medio	Alto	Alto
IT/datos	Medio	Alto	Alto	Alto	Alto
Operario	Alto local	Básico	Básico-medio	Alto	Alto

14.75. Indicadores de supervisión efectiva

La supervisión puede evaluarse mediante:

- tiempo disponible;
- porcentaje de decisiones revisadas;
- calidad del override;
- detección de fallos;
- competencia;
- autoridad.

Puede definirse:

$$H_{\text{efectiva}} = C \cdot T \cdot A \cdot I$$

donde:

- (C): competencia;
- (T): tiempo;
- (A): autoridad;
- (I): información.

Si uno de estos factores se aproxima a cero, la supervisión pierde eficacia.

14.76. Riesgos organizativos

Tabla 28. Síntesis de riesgo, manifestación y control.

Riesgo	Manifestación	Control
Desaprendizaje	Pérdida de capacidad manual	Simulaciones
Sobreconfianza	Aceptación automática	Formación
Rechazo	Infrautilización	Evidencia y participación
Dilución de responsabilidad	Nadie responde	RACI

Riesgo	Manifestación	Control
Fatiga de alarmas	Alertas ignoradas	Priorización
Shadow AI	Herramientas no controladas	Alternativas aprobadas
Pérdida de conocimiento	Salida de expertos	Captura y mentoría
Homogeneización	Error común	Revisión independiente
Vigilancia excesiva	Deterioro laboral	Proporcionalidad
Brecha de capacidades	Dependencia externa	Desarrollo interno

14.77. Modelo de madurez del capital humano

Nivel 1. Uso intuitivo

Herramientas utilizadas sin formación estructurada.

Nivel 2. Formación instrumental

Se enseña a manejar la interfaz.

Nivel 3. Competencia crítica

Los usuarios comprenden límites y riesgos.

Nivel 4. Organización multidisciplinar

Roles, responsabilidades y aprendizaje formalizados.

Nivel 5. Conocimiento aumentado

La IA se integra en comunidades y procesos.

Nivel 6. Organización adaptativa

Personas y sistemas aprenden de forma coordinada sin perder control.

14.78. Plan de desarrollo de capacidades

Diagnóstico

- inventario de funciones;
- brechas;
- riesgos;
- dependencia.

Diseño

- perfiles;
- formación;
- responsabilidades;

- carrera.

Implantación

- cursos;
- casos;
- simulaciones;
- mentoría.

Evaluación

- competencia;
- decisiones;
- incidentes;
- adopción.

Actualización

- nuevos modelos;
- cambios;
- lecciones.

14.79. Principios para una colaboración humano-máquina responsable

1. Automatizar tareas, no responsabilidad.
2. Mantener competencia suficiente para detectar el error.
3. Diseñar la supervisión como función efectiva.
4. Incorporar al usuario desde el inicio.
5. Registrar y aprender del desacuerdo.
6. Proteger el conocimiento crítico.
7. Evitar alarmas que superen la capacidad humana.
8. Formar sobre limitaciones, no solo sobre funciones.
9. Alinear autoridad y responsabilidad.
10. Conservar capacidad de operación en contingencia.

14.80. Conclusión: la ventaja decisiva no será el algoritmo, sino la organización que sepa gobernarlo

La inteligencia artificial puede realizar cálculos, reconocer patrones, generar escenarios y automatizar operaciones con una velocidad difícilmente alcanzable por una persona. Pero no posee por sí sola la comprensión completa del contexto biológico, industrial, económico, jurídico y ético en el que se aplica la nutrición animal.

El valor aparece cuando la capacidad algorítmica se combina con profesionales capaces de:

- formular correctamente el problema;
- evaluar la evidencia;
- interpretar la incertidumbre;
- reconocer excepciones;
- anticipar consecuencias;
- asumir responsabilidad.

La transformación no reduce la necesidad de conocimiento. La hace más exigente.

Cuando las tareas simples se automatizan, las personas se enfrentan con mayor frecuencia a los casos difíciles, ambiguos o excepcionales. Esto significa que el trabajo restante puede requerir más competencia, no menos.

Una organización que automatiza sin invertir en capacidades puede generar una paradoja: depender cada vez más de sistemas que comprende cada vez menos.

La preservación del conocimiento profesional no implica mantener procesos manuales innecesarios. Implica conservar la capacidad de cuestionar, verificar y operar cuando la automatización se equivoca o deja de estar disponible.

El nutricionista del futuro no será menos científico porque utilice IA. Deberá comprender mejor la relación entre datos, modelos, biología y decisión. El veterinario no será sustituido por una alerta predictiva; tendrá que integrar esa alerta con una evaluación clínica más amplia. El operario no debe convertirse en ejecutor pasivo, sino en supervisor competente de un sistema industrial más complejo.

Las empresas que obtendrán mayor ventaja no serán necesariamente las que adquieran antes la herramienta más avanzada. Serán aquellas que construyan equipos capaces de integrarla con:

- conocimiento sectorial;
- disciplina de datos;
- cultura de evidencia;
- responsabilidad clara;
- aprendizaje continuo.

La inteligencia artificial puede codificar una parte del conocimiento, pero no sustituye la capacidad organizativa para producirlo, discutirlo, actualizarlo y aplicarlo con prudencia.

La auténtica transformación de la nutrición animal no consistirá en reemplazar a los profesionales por algoritmos, sino en elevar la calidad de las decisiones mediante una cooperación en la que cada componente aporte aquello que hace mejor.

La máquina aporta escala, velocidad y consistencia.

La persona aporta finalidad, contexto, juicio y responsabilidad.

Si esta relación se diseña correctamente, la IA ampliará el conocimiento de la organización. Si se diseña mal, puede ocultarlo, debilitarlo y hacerlo depender de sistemas que nadie está en condiciones de explicar.

Por ello, el capital humano no es un elemento auxiliar de la digitalización. Es su principal infraestructura crítica.

15. Fronteras emergentes y escenarios de futuro: hacia sistemas nutricionales autónomos, multimodales y biológicamente adaptativos

La inteligencia artificial aplicada a la nutrición animal se encuentra todavía en una fase temprana de integración. Las aplicaciones actuales se concentran principalmente en predicción, clasificación, optimización, automatización parcial y apoyo a la decisión. Sin embargo, la convergencia entre inteligencia artificial, sensores, ciencias ómicas, robótica, biología sintética, modelización mecanística y computación distribuida apunta hacia sistemas mucho más integrados.

La evolución previsible no consistirá únicamente en disponer de modelos más precisos. El cambio cualitativo surgirá cuando diferentes capas de información puedan operar de forma coordinada:

- composición de materias primas;
- microbiota;
- genómica;
- comportamiento;
- salud;
- ambiente;
- proceso industrial;
- economía;
- sostenibilidad;
- regulación.

En lugar de optimizar una fórmula estática, los sistemas futuros podrán ajustar estrategias nutricionales en función de la respuesta real de animales, lotes, explotaciones y cadenas productivas.

Esta transición plantea oportunidades considerables, pero también riesgos nuevos. A medida que aumenta la autonomía, la complejidad del sistema puede superar la capacidad de comprensión de sus usuarios. A medida que los modelos integran más datos, aumenta la dependencia de infraestructuras, proveedores y estándares. A medida que la personalización se hace más precisa, también puede crecer la fragmentación, la desigualdad tecnológica y la dificultad de validar cada decisión.

El futuro de la nutrición animal aumentada por IA no debe analizarse como una secuencia inevitable. Es un espacio de decisiones tecnológicas, económicas y regulatorias.

La cuestión no es qué tecnologías serán posibles, sino cuáles deberán incorporarse, bajo qué condiciones y con qué límites.

15.1. De modelos aislados a sistemas cognitivos integrados

La primera generación de aplicaciones utiliza modelos separados para:

- demanda;
- formulación;
- calidad;
- salud;
- proceso;
- logística.

La siguiente etapa conectará estos modelos.

Puede representarse un sistema integrado:

$$S = M_{\text{materias}}, M_{\text{nutrición}}, M_{\text{animal}}, M_{\text{proceso}}, M_{\text{mercado}}$$

Las salidas de un modelo se convierten en entradas de otro.

Por ejemplo:

1. se predice la composición de una materia prima;
2. se ajusta la formulación;
3. se estima la respuesta animal;
4. se calcula el impacto ambiental;
5. se reprograma producción;
6. se actualiza compras.

La integración aumenta valor, pero también propaga errores.

15.2. Propagación de incertidumbre

En una arquitectura encadenada, la incertidumbre debe transferirse.

Si:

$$Y_1 = f_1(X)$$

y:

$$Y_2 = f_2(Y_1)$$

la incertidumbre de (Y_1) afecta a (Y_2).

No debe utilizarse la predicción intermedia como si fuera un dato exacto.

Puede expresarse:

$$\text{Var}(Y_2) \approx \left(\frac{\partial f_2}{\partial Y_1} \right)^2 \text{Var}(Y_1)$$

Los sistemas futuros deberán gestionar no solo predicciones, sino cadenas completas de incertidumbre.

15.3. Modelos multimodales

Los modelos multimodales integran diferentes tipos de información:

- texto;
- imagen;
- sonido;
- espectros;
- series temporales;

- datos tabulares;
- secuencias genómicas.

En una explotación podrían combinar:

- imagen corporal;
- sonido respiratorio;
- consumo;
- temperatura;
- composición del pienso;
- historial sanitario.

La integración puede detectar patrones que no aparecen en una sola modalidad.

Pero cada modalidad tiene:

- ruido;
- sesgo;
- frecuencia;
- resolución;
- cobertura.

La fusión multimodal debe evitar que una señal dominante o de mayor volumen eclipse variables biológicamente más importantes.

15.4. Visión y sonido como biomarcadores

La visión artificial puede estimar:

- condición corporal;
- locomoción;
- comportamiento;
- distribución;
- lesiones;
- consumo.

El análisis acústico puede identificar:

- tos;
- vocalización;
- estrés;
- fallos mecánicos;
- masticación.

Estas señales pueden actuar como biomarcadores no invasivos.

Sin embargo, deben validarse frente a referencias clínicas o productivas.

Un patrón visual no constituye por sí mismo una enfermedad ni una necesidad nutricional.

15.5. Modelos de lenguaje especializados

Los modelos de lenguaje podrán integrarse con:

- legislación;
- bibliografía;
- procedimientos;
- bases de formulación;
- históricos;
- registros de explotación.

Pueden convertirse en interfaces para consultar sistemas complejos.

Un profesional podría preguntar:

¿Qué factores explican la caída de consumo del lote 24 y qué acciones son compatibles con la formulación, el estado sanitario y las restricciones regulatorias?

La respuesta podría sintetizar datos, escenarios y evidencia.

El riesgo reside en que la fluidez verbal oculte:

- incertidumbre;
- datos ausentes;
- inferencias;
- fuentes contradictorias.

La interfaz conversacional no debe convertirse en sustituto de la validación.

15.6. Agentes de inteligencia artificial

Un agente no se limita a responder. Puede:

- buscar;
- planificar;
- ejecutar;
- verificar;
- comunicar.

En nutrición animal, un agente podría:

1. detectar una desviación;
2. consultar inventarios;
3. proponer una reformulación;
4. simular impacto;
5. solicitar aprobación;
6. actualizar el plan.

La autonomía agéntica aumenta la capacidad de coordinación.

También amplía la superficie de fallo.

15.7. Orquestación de agentes

Podrían coexistir agentes especializados:

- nutrición;
- calidad;
- compras;
- producción;
- sostenibilidad;
- logística.

Cada agente optimizaría su dominio.

Se necesitaría un mecanismo de resolución de conflictos:

$$\max U = \sum_k w_k U_k$$

sujeito a restricciones no compensables.

Pero los pesos no deberían permitir que un objetivo comercial supere una condición de seguridad.

La orquestación debe incluir jerarquías y derecho de veto.

15.8. Agentes y autoridad

Un agente puede proponer, negociar o ejecutar.

La organización debe definir:

- identidad;
- permisos;
- límites;
- responsabilidad;
- registro.

No debería existir un agente con acceso simultáneo e irrestricto a:

- formulación;
- compras;
- pagos;
- liberación.

La separación de funciones también es necesaria en entornos algorítmicos.

15.9. Nutrición cerrada en bucle

El sistema de control cerrado utiliza la respuesta del animal para ajustar la dieta.

$$u_{t+1} \pi(x_t, y_t, r_t)$$

donde:

- (u): intervención nutricional;
- (x): estado estimado;
- (y): respuesta observada;
- (r): objetivo.

El sistema puede actualizar:

- densidad;
- aminoácidos;
- energía;
- fibra;
- aditivos.

El riesgo es reaccionar a variaciones transitorias y generar inestabilidad.

15.10. Estabilidad del control nutricional

Un controlador demasiado agresivo puede provocar oscilaciones.

Ejemplo:

1. cae el consumo;
2. se aumenta densidad;
3. cambia respuesta;
4. se reduce;
5. vuelve a caer.

La política debe incluir:

- límites;
- tiempo de observación;
- histéresis;
- suavizado.

La nutrición animal tiene retardos biológicos. No debe tratarse como un sistema instantáneo.

15.11. Horizonte temporal múltiple

Las decisiones operan en distintos horizontes:

- segundos: control de equipo;
- horas: consumo;
- días: salud;
- semanas: crecimiento;
- meses: reproducción;
- años: genética y sostenibilidad.

Un sistema integrado debe evitar optimizar el corto plazo a costa del largo.

$$J = \sum_{t=0}^T \gamma^t R_t$$

El factor (γ) representa la importancia relativa del futuro.

15.12. Aprendizaje por refuerzo

El aprendizaje por refuerzo busca políticas que maximicen una recompensa acumulada.

Puede utilizarse para:

- control de proceso;
- dosificación;
- programación;
- alimentación adaptativa.

La recompensa debe incorporar:

- producción;
- salud;
- coste;
- bienestar;
- riesgo.

Una recompensa mal diseñada puede conducir a estrategias indeseables.

15.13. Riesgo de explotación no segura

El aprendizaje por refuerzo explora alternativas.

En animales o procesos reales, una exploración inadecuada puede producir daño.

Por ello, deben utilizarse:

- simulación;
- restricciones;
- aprendizaje offline;
- safe reinforcement learning;
- supervisión.

La explotación real no debe convertirse en un laboratorio sin límites.

15.14. Gemelos digitales de nueva generación

El gemelo digital futuro integrará:

- anatomía;
- metabolismo;
- microbiota;
- ambiente;

- proceso;
- economía.

No será únicamente una copia virtual del equipo, sino una representación dinámica del sistema productivo.

Puede actualizarse mediante:

$$x_{t+1}f(x_t, u_t, \theta_t) + \varepsilon_t$$

donde (θ_t) representa parámetros adaptativos.

15.15. Gemelo del animal

Un gemelo animal podría estimar:

- reservas;
- crecimiento;
- producción;
- riesgo sanitario;
- requerimientos.

Sería una representación probabilística, no una réplica exacta.

La individualización completa puede ser viable en animales de alto valor o explotaciones intensivamente sensorizadas.

En otras especies, el gemelo se aplicará por grupo.

15.16. Gemelo del lote

El lote constituye una unidad intermedia entre individuo y población.

Puede incluir:

- variabilidad interna;
- distribución de pesos;
- consumo;
- respuesta;
- salud.

La formulación puede orientarse a:

$$\min E[L(N_i, R_i)]$$

para todos los individuos (i) del lote.

La dieta óptima para la media puede no minimizar la pérdida del conjunto.

15.17. Gemelo de explotación

El gemelo de explotación integrará:

- animales;
- instalaciones;
- energía;
- agua;
- alimento;
- emisiones;
- economía.

Permitirá simular:

- cambio de dieta;
- densidad;
- clima;
- ventilación;
- tratamiento;
- inversión.

La dificultad será separar relaciones causales de correlaciones históricas.

15.18. Gemelo de cadena

La integración desde materia prima hasta producto final permitirá evaluar:

- coste;
- riesgo;
- huella;
- disponibilidad;
- respuesta.

Una decisión sobre origen de cereal podría propagarse hasta:

- formulación;
- proceso;
- rendimiento;
- emisiones;
- precio final.

Este nivel de integración requiere estándares comunes y gobernanza entre empresas.

15.19. Biología computacional

La modelización biológica evolucionará desde ecuaciones agregadas hacia representaciones más mecanísticas.

Podrán integrarse:

- metabolismo;
- señalización;
- expresión;
- microbiota;
- inmunidad.

La IA puede aproximar funciones complejas que los modelos mecanísticos no resuelven eficientemente.

Pero la interpretabilidad biológica seguirá siendo esencial.

15.20. Modelos híbridos

Los modelos híbridos combinan:

- conocimiento mecanístico;
- aprendizaje automático.

$$y = f_{\text{mecánico}}(x, \theta) + f_{\text{datos}}(x)$$

El componente mecanístico aporta coherencia.

El componente de datos corrige desviaciones y relaciones no modelizadas.

Esta combinación puede ser superior a modelos puramente estadísticos.

15.21. Restricciones físicas y biológicas

Los modelos informados por física o biología pueden incorporar:

- balances;
- conservación;
- límites;
- relaciones metabólicas.

La pérdida puede incluir:

$$L = L_{\text{predicción}} + \lambda L_{\text{restricción}}$$

Esto reduce resultados imposibles.

Pero las restricciones incorrectas también pueden limitar el aprendizaje.

15.22. Ómicas de alta resolución

La integración de:

- genómica;
- transcriptómica;
- proteómica;
- metabolómica;
- microbiómica;

puede permitir una caracterización profunda de la respuesta.

El reto no será solo volumen de datos, sino:

- dimensionalidad;

- coste;
- variabilidad;
- causalidad;
- reproducibilidad.

La correlación ómica debe traducirse a una intervención validada para adquirir valor industrial.

15.23. Nutrición de precisión genómica

La respuesta a un nutriente puede variar según:

- genotipo;
- línea;
- raza;
- epigenética.

Los sistemas futuros podrían ajustar recomendaciones a perfiles genéticos.

Esto puede mejorar:

- eficiencia;
- salud;
- respuesta a aditivos.

Pero requiere evitar que la genética se utilice como explicación determinista de fenómenos complejos.

15.24. Epigenética y programación nutricional

La nutrición temprana puede influir en:

- desarrollo;
- inmunidad;
- metabolismo;
- productividad.

La IA puede identificar ventanas críticas y respuestas diferidas.

El desafío es atribuir efectos a largo plazo en entornos con múltiples factores.

15.25. Microbiota funcional

La microbiota futura será tratada menos como listado taxonómico y más como red funcional.

La atención se desplazará hacia:

- rutas metabólicas;
- metabolitos;
- interacciones;
- estabilidad.

Puede representarse como un grafo:

$$G_m = (V_m, E_m)$$

donde los nodos representan funciones o microorganismos y las aristas interacciones.

La intervención deberá considerar la ecología completa.

15.26. Diseño computacional de consorcios

La IA puede proponer combinaciones de:

- probióticos;
- sustratos;
- metabolitos;
- bacteriófagos.

El objetivo puede ser restaurar funciones, no introducir una única cepa.

Sin embargo, la estabilidad del consorcio depende del entorno y del huésped.

La predicción debe validarse in vivo.

15.27. Postbióticos y metabolitos

La utilización de metabolitos o componentes microbianos puede ofrecer mayor estabilidad que organismos vivos.

La IA puede identificar:

- moléculas;
- combinaciones;
- mecanismos;
- dosis.

El diseño debe incluir:

- seguridad;
- fabricación;
- estabilidad;
- regulación;
- coste.

15.28. Descubrimiento de aditivos

La IA puede acelerar la identificación de:

- enzimas;
- péptidos;
- fitogénicos;
- antimicrobianos;
- moduladores.

Los modelos pueden cribar bibliotecas y predecir:

- actividad;
- toxicidad;
- estabilidad;
- sinergia.

La predicción reduce candidatos, pero no sustituye ensayos.

15.29. Diseño de enzimas

La IA generativa puede proponer variantes con:

- mayor termoestabilidad;
- actividad;
- especificidad;
- resistencia.

Esto es especialmente relevante para condiciones de:

- peletización;
- extrusión;
- pH gastrointestinal.

La optimización debe incluir manufacturabilidad y seguridad.

15.30. Péptidos bioactivos

Los modelos pueden predecir secuencias con actividad:

- antimicrobiana;
- inmunomoduladora;
- digestiva.

El reto incluye:

- degradación;
- biodisponibilidad;
- coste;
- resistencia;
- efectos no deseados.

15.31. Fermentación de precisión

La fermentación puede producir:

- proteínas;
- aminoácidos;
- vitaminas;
- enzimas;
- lípidos.

La IA puede optimizar:

- cepa;
- medio;
- proceso;
- rendimiento;
- purificación.

La huella ambiental dependerá de:

- energía;
- sustrato;
- escala;
- coproductos.

No toda fermentación es automáticamente sostenible.

15.32. Biología sintética

La biología sintética puede diseñar microorganismos para producir o transformar nutrientes.

La IA puede apoyar el diseño de circuitos metabólicos.

Los riesgos incluyen:

- estabilidad genética;
- contención;
- transferencia;
- regulación;
- percepción.

La evaluación debe realizarse caso por caso.

15.33. Proteínas alternativas

Las materias futuras pueden incluir:

- insectos;
- algas;
- proteínas unicelulares;
- fermentación;
- coproductos avanzados.

La IA puede comparar:

- nutrición;
- digestibilidad;
- contaminantes;
- coste;
- huella.

La adopción dependerá también de:

- escala;
- regulación;
- aceptación;
- consistencia.

15.34. Insectos

La producción de insectos puede valorizar corrientes orgánicas y producir proteína y grasa.

La IA puede optimizar:

- sustrato;
- ambiente;
- crecimiento;
- cosecha.

Pero debe controlarse la transferencia de:

- contaminantes;
- patógenos;
- residuos.

La sostenibilidad depende del sustrato y la energía utilizada.

15.35. Algas y biomasa acuática

Las algas pueden aportar:

- proteína;
- pigmentos;
- lípidos;
- compuestos funcionales.

Los retos incluyen:

- cultivo;
- secado;
- digestibilidad;
- variabilidad;
- metales;
- yodo.

La IA puede ayudar a seleccionar cepas y condiciones.

15.36. Proteína unicelular

La proteína microbiana puede utilizar:

- metano;

- metanol;
- azúcares;
- gases.

Su potencial depende de:

- seguridad;
- eficiencia;
- nucleótidos;
- energía;
- escala.

Los modelos deben incluir la cadena completa y no solo el rendimiento del biorreactor.

15.37. Valorización automática de coproductos

Los sistemas futuros podrían identificar en tiempo real:

- composición;
- disponibilidad;
- estabilidad;
- uso óptimo.

Una corriente industrial podría asignarse dinámicamente a:

- alimentación;
- fermentación;
- energía;
- fertilización.

La decisión debe priorizar seguridad y valor total.

15.38. Fabricación distribuida

La producción de determinados ingredientes o premezclas podría acercarse a la explotación.

Esto reduciría transporte y permitiría personalización.

Pero aumentaría:

- número de puntos;
- variabilidad;
- necesidad de control;
- riesgo de dosificación.

La descentralización solo será viable con sistemas robustos de validación y trazabilidad.

15.39. Microfábricas inteligentes

Las microfábricas pueden producir lotes pequeños adaptados.

Podrían utilizar:

- dosificación automática;
- análisis en línea;
- formulación dinámica.

La flexibilidad aumenta, pero se pierden economías de escala.

Su valor será mayor en nichos de alta especialización.

15.40. Impresión y estructuración de alimentos

En acuicultura, mascotas o animales de alto valor podrían desarrollarse formatos personalizados mediante:

- extrusión avanzada;
- impresión;
- encapsulación.

La IA puede adaptar:

- forma;
- densidad;
- liberación;
- palatabilidad.

La complejidad debe justificarse mediante beneficio funcional.

15.41. Liberación dirigida

Las tecnologías de encapsulación pueden liberar compuestos según:

- pH;
- tiempo;
- enzimas;
- localización.

La IA puede diseñar perfiles de liberación.

Esto puede mejorar:

- estabilidad;
- biodisponibilidad;
- eficacia.

Pero aumenta la necesidad de validar interacción con proceso y fisiología.

15.42. Nutrición temporal

La dieta puede adaptarse según:

- hora;
- temperatura;
- actividad;
- fase fisiológica.

Los sistemas podrían variar composición dentro del día.

La optimización temporal debe considerar logística y estabilidad.

15.43. Alimentación individual

La identificación y dosificación individual puede ser viable en:

- vacuno;
- reproductores;
- animales de investigación;
- mascotas.

La fórmula puede adaptarse a:

- producción;
- condición;
- salud;
- consumo.

La rentabilidad dependerá del valor del animal y del coste de infraestructura.

15.44. Robótica alimentaria

La robótica puede automatizar:

- distribución;
- empuje;
- limpieza;
- inspección;
- dosificación.

La coordinación con IA permite ajustar rutas y cantidades.

La seguridad debe contemplar interacción con:

- animales;
- personas;
- instalaciones.

15.45. Drones y plataformas móviles

Pueden utilizarse para:

- monitorizar pastos;
- localizar animales;

- evaluar agua;
- inspeccionar instalaciones.

La nutrición extensiva puede beneficiarse de mejor estimación de biomasa.

Pero la precisión depende de:

- vegetación;
- clima;
- terreno;
- resolución.

15.46. Pastoreo de precisión

La IA puede estimar:

- oferta;
- calidad;
- consumo;
- movimiento.

La suplementación puede ajustarse según la disponibilidad real.

Esto puede mejorar eficiencia, pero requiere modelos capaces de operar con datos incompletos.

15.47. Acuicultura autónoma

La acuicultura presenta condiciones favorables para sistemas cerrados:

- sensores;
- cámaras;
- dosificadores;
- ambiente controlado.

La IA puede ajustar alimentación según:

- biomasa;
- actividad;
- oxígeno;
- temperatura;
- residuos.

El objetivo debe equilibrar crecimiento, conversión, agua y bienestar.

15.48. Pet nutrition hiperpersonalizada

En animales de compañía pueden combinarse:

- raza;
- edad;
- actividad;

- biomarcadores;
- preferencias;
- patología.

La personalización puede mejorar adherencia y manejo.

Pero también puede generar recomendaciones excesivamente complejas o claims sin evidencia.

La prescripción clínica debe permanecer bajo supervisión veterinaria.

15.49. Nutrición clínica digital

Los sistemas pueden apoyar dietas para:

- obesidad;
- renal;
- gastrointestinal;
- alergias;
- recuperación.

La integración con historias y monitorización permite ajustar respuesta.

Estas aplicaciones requieren mayor validación y control por su impacto sanitario.

15.50. Biofeedback nutricional

Los wearables y pruebas podrían generar retroalimentación sobre:

- glucosa;
- actividad;
- temperatura;
- digestión;
- comportamiento.

La intervención se adaptaría a la respuesta.

El riesgo es sobreinterpretar variaciones normales y producir cambios continuos innecesarios.

15.51. Biomarcadores digitales

Un biomarcador digital debe demostrar:

- validez analítica;
- validez biológica;
- utilidad.

Puede existir correlación sin capacidad para mejorar una decisión.

La adopción debe exigir evidencia escalonada.

15.52. Ensayos virtuales

Los modelos pueden simular:

- grupos;
- dosis;
- condiciones;
- respuestas.

Esto permite priorizar ensayos físicos.

Pero un ensayo virtual no sustituye automáticamente la validación experimental.

Su valor principal es reducir el espacio de búsqueda.

15.53. Diseño adaptativo de ensayos

La IA puede modificar:

- asignación;
- dosis;
- tamaño;
- seguimiento;

según resultados intermedios.

Esto puede mejorar eficiencia.

Debe preservarse integridad estadística y evitar cambios oportunistas.

15.54. Evidencia del mundo real

Los datos operativos pueden complementar ensayos.

Permiten observar:

- diversidad;
- largo plazo;
- múltiples contextos.

Pero contienen:

- confusión;
- selección;
- pérdida;
- sesgo.

La causalidad requiere métodos específicos.

15.55. Aprendizaje federado

El aprendizaje federado permite entrenar modelos sin centralizar datos.

Cada participante comparte actualizaciones, no necesariamente registros brutos.

Puede apoyar colaboración entre:

- empresas;
- granjas;
- centros.

Los riesgos incluyen:

- ataques;
- inferencia;
- heterogeneidad;
- gobernanza.

15.56. Privacidad diferencial

Puede añadirse ruido para proteger información.

Pero existe un compromiso:

privacidad ↔ utilidad

En conjuntos pequeños o eventos raros, la pérdida de precisión puede ser importante.

15.57. Computación segura

Técnicas como:

- cifrado homomórfico;
- entornos confiables;
- computación multipartita;

pueden permitir análisis sin revelar datos.

Su adopción dependerá de coste y rendimiento.

15.58. Mercados de datos

Podrían surgir mercados para intercambiar:

- composición;
- respuesta;
- emisiones;
- salud.

Esto puede aumentar innovación.

Pero plantea preguntas sobre:

- propiedad;
- calidad;
- compensación;
- control;
- concentración.

Los datos de pequeños productores no deberían extraerse sin retorno o transparencia.

15.59. Interoperabilidad semántica

El futuro integrado requiere que sistemas compartan significado.

No basta con transferir números.

Debe compartirse:

- especie;
- fase;
- método;
- unidad;
- contexto;
- incertidumbre.

Las ontologías sectoriales serán una infraestructura esencial.

15.60. Ontologías nutricionales

Una ontología puede relacionar:

- ingrediente;
- nutriente;
- especie;
- efecto;
- proceso;
- evidencia.

Esto facilita:

- búsqueda;
- inferencia;
- interoperabilidad;
- trazabilidad.

La ontología debe evolucionar con el conocimiento.

15.61. Grafos de conocimiento

Los grafos pueden integrar:

- literatura;
- ensayos;
- productos;
- mecanismos;
- regulación.

Permiten buscar relaciones y generar hipótesis.

$$G_K = (V_K, E_K)$$

Pero una relación en el grafo puede representar:

- asociación;
- causalidad;
- hipótesis;
- contradicción.

Debe etiquetarse su naturaleza.

15.62. Ciencia autónoma

Los sistemas podrían proponer:

- hipótesis;
- experimentos;
- combinaciones;
- análisis.

En laboratorios automatizados, podrían ejecutar ciclos de descubrimiento.

La autonomía científica debe conservar:

- revisión;
- reproducibilidad;
- ética;
- interpretación.

La velocidad no garantiza relevancia.

15.63. Laboratorios robotizados

La automatización puede realizar:

- preparación;
- análisis;
- cultivo;
- cribado.

Esto aumenta reproducibilidad y volumen.

Pero puede propagar rápidamente un error de protocolo si no existen controles independientes.

15.64. Descubrimiento inverso

En lugar de preguntar qué efecto produce un ingrediente, puede definirse el efecto deseado y buscar la intervención.

$$x^* \arg\min_x (f(x), y_{\text{objetivo}})$$

La solución propuesta debe ser:

- fabricable;
- segura;
- estable;
- autorizable.

15.65. Inteligencia artificial generativa de formulaciones

Los sistemas pueden generar combinaciones novedosas.

Pero la creatividad matemática no equivale a viabilidad.

Las fórmulas deben pasar por:

- restricciones;
- simulación;
- prueba;
- aprobación.

15.66. Formulación autoevolutiva

Un sistema puede aprender del rendimiento de fórmulas anteriores y proponer mejoras.

Esto crea un ciclo:

$$F_{t+1} F_t + \Delta F(Y_t)$$

Debe evitarse que cambios sucesivos reduzcan la capacidad de atribuir efectos.

La experimentación debe estar controlada.

15.67. Sistemas autoexplicativos

Los modelos futuros podrán generar explicaciones contextuales.

Pero la explicación generada debe corresponder al proceso real del modelo.

Una narrativa plausible pero no fiel es más peligrosa que una ausencia de explicación.

15.68. Modelos causales

La evolución desde predicción hacia causalidad será central.

La pregunta cambiará de:

¿Qué ocurrirá?

a:

¿Qué ocurrirá si modificamos la dieta?

La estimación causal requiere:

- intervención;
- confusores;
- supuestos;
- diseño.

La IA puede ampliar métodos, pero no eliminar la necesidad de identificación causal.

15.69. Inferencia contrafactual

El sistema puede estimar:

$$Y_i(1) - Y_i(0)$$

para un animal, lote o explotación.

Esto permitiría seleccionar intervenciones según beneficio esperado individual.

Los contrafactuales no son observables simultáneamente. Deben interpretarse como estimaciones.

15.70. Descubrimiento causal

Los algoritmos pueden proponer estructuras causales a partir de datos.

Estas estructuras deben confrontarse con conocimiento biológico y experimentación.

El descubrimiento automático puede generar hipótesis, no verdades definitivas.

15.71. Automatización normativa

Los sistemas pueden traducir requisitos regulatorios a reglas de operación.

Pueden verificar:

- dosis;
- especies;
- claims;
- mercados;
- etiquetado.

La automatización mejora consistencia.

Pero la norma contiene conceptos abiertos e interpretaciones.

No todo requisito puede convertirse en una regla binaria.

15.72. *Regulatory intelligence*

La IA puede monitorizar cambios y evaluar impacto.

Podría identificar:

- productos afectados;
- fórmulas;
- mercados;
- documentos.

La revisión humana debe confirmar vigencia y alcance.

15.73. Cumplimiento continuo

La empresa puede pasar de auditorías periódicas a monitorización continua de:

- datos;
- versiones;
- límites;
- documentación.

Esto puede reducir desviaciones.

Pero también aumenta dependencia de sistemas y vigilancia.

15.74. Auditoría automatizada

Los auditores podrán utilizar IA para seleccionar muestras y detectar anomalías.

La auditoría no debe reducirse a correlaciones.

Debe conservar:

- independencia;
- contexto;
- materialidad;
- juicio.

15.75. Trazabilidad criptográfica

Firmas digitales y registros verificables pueden reforzar:

- identidad;
- integridad;
- versión;
- custodia.

La criptografía protege el registro, no la veracidad del hecho físico.

15.76. Identidad digital de ingredientes

Cada lote podría incorporar un pasaporte con:

- origen;
- composición;
- huella;
- controles;
- transformaciones.

Esto facilitaría trazabilidad y formulación dinámica.

El pasaporte debe permitir correcciones controladas y reflejar incertidumbre.

15.77. Pasaporte nutricional dinámico

La caracterización de un lote podría actualizarse tras:

- análisis;
- almacenamiento;
- procesamiento;
- mezcla.

El ingrediente tendría un perfil vivo.

La gobernanza debe determinar qué versión se utilizó en cada decisión.

15.78. Certificación algorítmica

Podrían desarrollarse esquemas de certificación para:

- modelos;
- datos;
- procesos;
- gobernanza.

La certificación puede aumentar confianza.

Pero no debe convertirse en una presunción absoluta de seguridad.

El uso concreto sigue requiriendo validación.

15.79. Estándares de desempeño

El sector necesitará definir:

- métricas;
- conjuntos de prueba;
- escenarios;

- documentación.

Sin estándares, las afirmaciones comerciales son difíciles de comparar.

15.80. Regulación adaptativa

La velocidad tecnológica puede favorecer:

- guías;
- sandboxes;
- estándares;
- monitorización.

La regulación deberá equilibrar:

- innovación;
- seguridad;
- competencia;
- evidencia.

Las reglas excesivamente rígidas pueden quedar obsoletas. Las reglas excesivamente abiertas pueden generar inseguridad.

15.81. Sandbox regulatorio

Los entornos controlados pueden permitir probar aplicaciones bajo supervisión.

Deben definir:

- alcance;
- duración;
- datos;
- riesgo;
- salida.

El sandbox no debe convertirse en excepción permanente.

15.82. Armonización internacional

Las cadenas de piensos son globales.

Diferencias en:

- regulación;
- datos;
- claims;
- IA;
- trazabilidad;

pueden fragmentar mercados.

La interoperabilidad futura requerirá acuerdos técnicos y jurídicos.

15.83. Soberanía tecnológica

La dependencia de plataformas externas puede afectar:

- continuidad;
- acceso;
- coste;
- control.

Las empresas y regiones deberán decidir qué capacidades consideran estratégicas.

La soberanía no exige desarrollar todo internamente, sino conservar capacidad de elección y salida.

15.84. Concentración de mercado

Los sistemas más avanzados pueden requerir grandes volúmenes de datos e inversión.

Esto puede favorecer a:

- grandes fabricantes;
- integradores;
- plataformas.

Los pequeños operadores podrían quedar dependientes.

La política sectorial debe promover acceso sin reducir estándares.

15.85. Brecha digital

La adopción será desigual según:

- tamaño;
- región;
- conectividad;
- capital;
- talento.

Una IA entrenada principalmente en explotaciones avanzadas puede funcionar peor en entornos menos digitalizados.

Esto puede ampliar desigualdades.

15.86. Tecnología frugal

No todas las soluciones deben ser complejas.

La tecnología frugal busca:

- pocos sensores;

- modelos simples;
- bajo coste;
- mantenimiento local.

Puede generar mayor impacto en contextos con recursos limitados.

15.87. IA offline y de borde

Los modelos locales pueden operar sin conectividad continua.

Esto resulta relevante en:

- zonas rurales;
- acuicultura remota;
- pastoreo.

La actualización y seguridad deben gestionarse cuidadosamente.

15.88. Democratización frente a dependencia

Las herramientas generativas reducen barreras de acceso.

Pero también pueden aumentar dependencia de plataformas cuyos modelos y políticas no controla el usuario.

La democratización real requiere:

- competencia;
- portabilidad;
- transparencia;
- alternativas.

15.89. Riesgo sistémico

Si múltiples empresas utilizan el mismo modelo o proveedor, un fallo puede propagarse.

Ejemplos:

- error común de formulación;
- vulnerabilidad;
- dato incorrecto;
- actualización defectuosa.

La diversidad tecnológica puede funcionar como defensa sistémica.

15.90. Monocultura algorítmica

La adopción de modelos similares puede homogeneizar decisiones.

Esto puede aumentar eficiencia en condiciones normales y fragilidad ante eventos no previstos.

La organización y el sector deben conservar:

- revisión independiente;
- diversidad;
- capacidad manual;
- proveedores alternativos.

15.91. Ataques adversariales

Los sistemas pueden ser manipulados mediante:

- entradas alteradas;
- documentos;
- imágenes;
- datos contaminados.

Un atacante podría intentar:

- ocultar defecto;
- modificar clasificación;
- provocar rechazo;
- alterar compras.

La seguridad futura deberá cubrir el comportamiento específico del modelo.

15.92. Envenenamiento de datos

Si el modelo aprende continuamente, un actor puede introducir patrones para modificarlo.

Los datos nuevos deben pasar por:

- validación;
- procedencia;
- revisión;
- aislamiento.

15.93. Model inversion y extracción

Un atacante puede intentar inferir:

- datos;
- parámetros;
- fórmulas;
- secretos.

La protección de modelos será también protección del conocimiento empresarial.

15.94. Deepfakes documentales

La falsificación de certificados, imágenes y comunicaciones será más sofisticada.

La confianza deberá basarse en:

- autenticidad;
- firma;
- verificación;
- trazabilidad.

No en apariencia.

15.95. Riesgo de autonomía acumulativa

Cada sistema individual puede tener autonomía limitada.

Pero su combinación puede producir autonomía efectiva elevada.

Ejemplo:

- un modelo predice;
- otro formula;
- otro compra;
- otro programa;
- otro libera.

La gobernanza debe evaluar el flujo completo, no solo cada componente.

15.96. Emergencia de comportamiento

Los sistemas complejos pueden mostrar comportamientos no previstos por sus componentes.

La prueba debe incluir interacciones y escenarios extremos.

15.97. Fragilidad por complejidad

La complejidad puede aumentar precisión y reducir comprensibilidad.

Puede definirse:

$$V_{\text{neto}} B_{\text{predicción}} C_{\text{complejidad}}$$

El modelo más avanzado no siempre es el más adecuado.

15.98. Principio de reversibilidad

Las nuevas aplicaciones deberían permitir:

- rollback;
- modo manual;
- suspensión;
- recuperación.

La irreversibilidad aumenta el riesgo de innovación.

15.99. Diseño para degradación elegante

Un sistema no debe pasar de funcionamiento completo a fallo total.

Puede degradarse:

1. autonomía;
2. recomendación;
3. monitorización;
4. operación manual.

La degradación gradual mejora resiliencia.

15.100. Escenario conservador

En un escenario conservador, la IA:

- mejora predicción;
- automatiza documentos;
- optimiza parcialmente;
- mantiene supervisión intensa.

La transformación es incremental.

Las barreras principales son:

- datos;
- integración;
- confianza;
- regulación.

15.101. Escenario de convergencia

En un escenario intermedio:

- sensores;
- gemelos;
- ómicas;
- agentes;

se integran en plataformas.

La alimentación se adapta por lotes o individuos.

La empresa opera con una arquitectura común de datos y gobernanza.

15.102. Escenario de autonomía avanzada

En un escenario más disruptivo, sistemas autónomos coordinan:

- compra;

- formulación;
- fabricación;
- distribución;
- alimentación.

La intervención humana se concentra en:

- objetivos;
- excepciones;
- auditoría;
- ética.

Este escenario exige controles mucho más fuertes y puede no ser deseable en todas las funciones.

15.103. Escenario fragmentado

La ausencia de estándares puede producir:

- plataformas cerradas;
- datos incompatibles;
- dependencia;
- duplicidad.

La IA crece, pero no genera integración real.

Las empresas acumulan herramientas sin visión común.

15.104. Escenario de reacción regulatoria

Incidentes graves podrían provocar reglas restrictivas.

Esto puede ralentizar innovación y favorecer grandes operadores capaces de asumir cumplimiento.

La prevención de incidentes sectoriales tiene un valor colectivo.

15.105. Escenario de confianza

Un desarrollo responsable puede aumentar:

- transparencia;
- calidad;
- eficiencia;
- seguridad.

La confianza será una ventaja competitiva.

Las empresas capaces de demostrar cómo funcionan sus sistemas podrán diferenciarse.

15.106. Señales tempranas de cambio

La organización debe monitorizar:

- coste de sensores;
- capacidad de modelos;
- regulación;
- adopción;
- talento;
- estándares;
- resultados científicos.

No toda tendencia tecnológica se convertirá en aplicación rentable.

15.107. Vigilancia tecnológica estructurada

Puede clasificarse cada tecnología según:

- madurez;
- impacto;
- plazo;
- dependencia;
- riesgo.

$$P_T = \frac{I \cdot F}{R \cdot D}$$

donde:

- (I): impacto;
- (F): factibilidad;
- (R): riesgo;
- (D): dependencia.

15.108. Horizonte de adopción

Corto plazo

- asistentes;
- predicción;
- visión;
- mantenimiento;
- trazabilidad.

Medio plazo

- gemelos;
- multimodalidad;
- agentes supervisados;
- personalización por lote.

Largo plazo

- autonomía cerrada;
- diseño biológico;

- ciencia automatizada;
- integración de cadena completa.

La clasificación debe revisarse periódicamente.

15.109. Opcionalidad estratégica

La empresa no necesita invertir plenamente en toda tecnología emergente.

Puede conservar opciones mediante:

- pilotos;
- colaboraciones;
- estándares;
- arquitectura modular;
- formación.

La opcionalidad permite adaptarse sin comprometer recursos prematuramente.

15.110. Capacidades no sustituibles

Independientemente de la tecnología, seguirán siendo críticas:

- calidad de datos;
- conocimiento de dominio;
- validación;
- trazabilidad;
- responsabilidad;
- cultura de seguridad.

Estas capacidades constituyen activos duraderos.

15.111. Investigación prioritaria

Las áreas de mayor relevancia incluyen:

- causalidad nutricional;
- modelos híbridos;
- validación multimodal;
- incertidumbre;
- aprendizaje seguro;
- microbiota funcional;
- sostenibilidad integrada;
- bienestar;
- interoperabilidad;
- supervisión humana.

15.112. Criterios para evaluar una tecnología emergente

1. ¿Resuelve un problema real?
2. ¿Existe evidencia más allá de la demostración?

3. ¿Puede validarse?
4. ¿Qué datos necesita?
5. ¿Qué daño puede producir?
6. ¿Puede integrarse?
7. ¿Es reversible?
8. ¿Quién responde?
9. ¿Es económicamente sostenible?
10. ¿Aumenta o reduce dependencia?

15.113. Indicadores de preparación futura

Tabla 29. Síntesis de dimensión y indicador.

Dimensión	Indicador
Datos	Interoperabilidad
Arquitectura	Modularidad
Personas	Competencias híbridas
Ciencia	Validación causal
Tecnología	Pilotos escalables
Riesgo	Contingencia
Regulación	Vigilancia
Proveedores	Portabilidad
Innovación	Opciones activas
Conocimiento	Aprendizaje documentado

15.114. Modelo de madurez prospectiva

Nivel 1. Seguimiento reactivo

La empresa adopta herramientas cuando ya están extendidas.

Nivel 2. Vigilancia

Monitoriza tendencias.

Nivel 3. Experimentación selectiva

Realiza pilotos con criterios.

Nivel 4. Arquitectura preparada

Diseña datos y sistemas para integrar novedades.

Nivel 5. Innovación coordinada

Combina investigación, operación y regulación.

Nivel 6. Configuración del ecosistema

Participa en estándares, ciencia y gobernanza sectorial.

15.115. Principios para construir el futuro de forma responsable

1. No confundir posibilidad con conveniencia.
2. Diseñar para incertidumbre y no solo para precisión.
3. Aumentar autonomía únicamente con evidencia.
4. Mantener restricciones de seguridad independientes.
5. Evitar monoculturas algorítmicas.
6. Conservar reversibilidad y operación manual.
7. Validar las integraciones completas.
8. Distribuir beneficios tecnológicos.
9. Proteger conocimiento y soberanía.
10. Gobernar la innovación antes de que se vuelva infraestructura crítica.

15.116. Conclusión: el futuro no será una fórmula automática, sino un sistema adaptativo bajo responsabilidad humana

La próxima fase de inteligencia artificial en nutrición animal no se limitará a mejorar modelos existentes. Integrará datos biológicos, industriales, ambientales y económicos en sistemas capaces de observar, aprender, simular y actuar.

Estos sistemas podrán formular por lote, ajustar dietas a respuestas reales, diseñar nuevos ingredientes, anticipar enfermedades y coordinar cadenas de suministro. Podrán generar un nivel de personalización y eficiencia difícilmente alcanzable mediante métodos tradicionales.

Pero cada avance ampliará también el espacio de responsabilidad.

Un sistema que observa más variables puede detectar antes una desviación, pero también puede producir más alertas, inferencias y decisiones. Un agente que coordina varias funciones puede reducir tiempos, pero también concentrar autoridad. Un gemelo digital puede permitir experimentos virtuales, pero puede generar una confianza injustificada si su representación es incompleta.

La autonomía futura no debe evaluarse por la cantidad de decisiones que el sistema toma sin intervención, sino por la calidad del control que permanece sobre ellas.

La inteligencia artificial más avanzada no será necesariamente la que actúe sola. Será la que sepa:

- reconocer cuándo no dispone de evidencia;
- mantener incertidumbre visible;
- respetar límites;
- solicitar revisión;
- aprender sin degradar;
- operar de forma reversible.

La nutrición animal es un sistema biológico, industrial y alimentario. Sus objetivos no pueden reducirse a una única recompensa. Debe equilibrar producción, salud, bienestar, seguridad, sostenibilidad y viabilidad.

El futuro tecnológico será más valioso cuanto mejor preserve esta pluralidad.

La empresa preparada no será la que intente predecir exactamente qué herramienta dominará dentro de diez años. Será la que construya ahora las capacidades necesarias para evaluar, integrar y gobernar cualquier tecnología futura:

- datos fiables;
- arquitectura interoperable;
- profesionales competentes;
- validación rigurosa;
- responsabilidad clara;
- resiliencia.

En este contexto, la inteligencia artificial no debe concebirse como un sustituto del sistema de conocimiento de la nutrición animal. Debe convertirse en una nueva infraestructura para ampliar su capacidad científica y decisional.

Si el desarrollo se orienta exclusivamente hacia velocidad y autonomía, puede producir sistemas más potentes y menos gobernables.

Si se orienta hacia evidencia, complementariedad y control, puede contribuir a una nutrición animal más precisa, segura, eficiente y sostenible.

El futuro no estará determinado únicamente por lo que la inteligencia artificial pueda hacer.

Estará determinado por aquello que el sector decida permitirle hacer, por las condiciones bajo las que lo haga y por la capacidad humana para seguir comprendiendo, cuestionando y respondiendo por sus decisiones.

16. Hoja de ruta para la implantación de inteligencia artificial en empresas de nutrición animal: diagnóstico, priorización, validación y escalado

La implantación de inteligencia artificial en una empresa de nutrición animal no debe comenzar con la adquisición de una plataforma ni con la selección de un algoritmo. Debe comenzar con una evaluación rigurosa de la organización, de sus procesos, de sus datos y de las decisiones cuya mejora produciría un impacto técnico, económico, sanitario o ambiental relevante.

La experiencia acumulada en transformación digital demuestra que las iniciativas tecnológicas fracasan con frecuencia cuando se construyen sobre procesos inestables, datos no gobernados o responsabilidades mal definidas. La inteligencia artificial no corrige automáticamente estas deficiencias. Puede amplificarlas y hacerlas menos visibles al envolverlas en resultados aparentemente precisos.

Una hoja de ruta responsable debe evitar dos extremos.

El primero consiste en retrasar indefinidamente cualquier implantación hasta alcanzar una supuesta perfección de datos, procesos e infraestructura que probablemente nunca llegará.

El segundo consiste en desplegar aplicaciones de forma apresurada, sin conocer su finalidad, riesgo, dependencia o capacidad real de generar valor.

La estrategia adecuada es progresiva. Debe permitir experimentar, aprender y capturar beneficios tempranos, pero dentro de una arquitectura común de datos, gobernanza, validación y responsabilidad.

La empresa debe evolucionar desde casos de uso aislados hacia un sistema integrado de decisión. Esa evolución requiere ordenar las iniciativas según sus dependencias y evitar que aplicaciones avanzadas se apoyen sobre fundamentos que todavía no existen.

Puede representarse la secuencia general:

**diagnóstico → priorización → preparación → piloto → validación → despliegue → monitorización
→ escalado**

Cada fase debe concluir con una decisión expresa:

- avanzar;
- corregir;
- mantener en observación;
- abandonar.

La ausencia de estas puertas de decisión convierte la hoja de ruta en una acumulación de proyectos sin dirección.

16.1. Definir la ambición estratégica

Antes de seleccionar casos de uso, la dirección debe establecer qué papel pretende asignar a la inteligencia artificial.

Las ambiciones pueden ser diferentes.

Eficiencia operativa

Reducir:

- costes;
- consumo energético;
- tiempos;
- mermas;
- paradas.

Excelencia nutricional

Mejorar:

- precisión de formulación;
- adaptación;
- digestibilidad;
- consistencia;
- respuesta animal.

Gestión del riesgo

Anticipar:

- contaminación;
- desviaciones;
- fallos;
- enfermedades;
- interrupciones.

Diferenciación comercial

Ofrecer:

- servicios predictivos;
- formulación personalizada;
- trazabilidad;
- sostenibilidad demostrable;
- soporte técnico avanzado.

Transformación del modelo de negocio

Evolucionar desde la venta de productos hacia:

- soluciones;
- plataformas;
- servicios;
- contratos por resultados.

La ambición condiciona la arquitectura y los recursos.

Una empresa que pretende automatizar informes internos no necesita el mismo nivel de infraestructura que otra que aspira a operar una plataforma de nutrición adaptativa para cientos de explotaciones.

16.2. Vinculación con la estrategia empresarial

La IA debe conectarse con objetivos ya existentes.

Puede utilizarse una matriz:

Tabla 30. Síntesis de objetivo empresarial y contribución potencial de ia.

Objetivo empresarial	Contribución potencial de IA
Reducir coste de formulación	Matrices dinámicas y optimización
Aumentar consistencia	Predicción por lote
Mejorar servicio técnico	Recomendaciones personalizadas
Reducir riesgo microbiológico	Alertas predictivas
Disminuir huella	Formulación multiobjetivo
Aumentar capacidad	Optimización de proceso
Reducir inventario	Predicción de demanda
Diferenciar productos	Diseño computacional

Un proyecto sin vínculo con una prioridad estratégica corre mayor riesgo de convertirse en una demostración sin continuidad.

16.3. Patrocinio de dirección

La dirección debe proporcionar:

- prioridad;
- presupuesto;
- autoridad;
- coordinación;
- tolerancia al aprendizaje.

El patrocinio no consiste únicamente en aprobar la inversión.

Debe intervenir cuando el proyecto exige:

- compartir datos;
- modificar procesos;
- resolver conflictos;
- asumir riesgos;
- abandonar prácticas establecidas.

Sin patrocinio real, cada departamento puede proteger sus sistemas y limitar la integración.

16.4. Principios rectores de la hoja de ruta

La empresa debería aprobar principios previos.

Ejemplos:

1. Ningún sistema crítico se desplegará sin validación.
2. La seguridad y el bienestar actuarán como restricciones.
3. Toda aplicación tendrá propietario y responsable del riesgo.
4. Los datos corporativos no se utilizarán sin gobernanza.
5. La autonomía aumentará únicamente con evidencia.
6. Toda decisión relevante deberá ser reconstruible.
7. Se preferirán soluciones simples cuando produzcan valor equivalente.
8. Todo piloto tendrá criterios de avance y abandono.
9. La dependencia de proveedores será evaluada.
10. La organización conservará capacidad de contingencia.

Estos principios reducen decisiones improvisadas.

16.5. Diagnóstico inicial

El diagnóstico debe evaluar cinco dimensiones:

$$D = f(P, I, G, C, R)$$

donde:

- (P): procesos;
- (I): información;
- (G): gobernanza;
- (C): capacidades;
- (R): riesgo.

No debería limitarse a un cuestionario tecnológico.

Debe incluir observación de cómo se toman realmente las decisiones.

16.6. Diagnóstico de procesos

Para cada proceso debe identificarse:

- objetivo;
- entrada;
- decisión;
- salida;
- responsable;
- variabilidad;
- problema;
- control.

Los procesos prioritarios pueden incluir:

- compras;
- recepción;
- laboratorio;
- formulación;
- dosificación;
- fabricación;
- expedición;
- asistencia técnica;
- seguimiento de granja.

La IA no debería aplicarse a un proceso que nadie puede describir de forma consistente.

16.7. Mapa de decisiones

El mapa de procesos debe complementarse con un mapa de decisiones.

Para cada decisión:

Tabla 31. Síntesis de elemento y pregunta.

Elemento	Pregunta
Frecuencia	¿Cuántas veces se toma?
Valor	¿Qué impacto tiene?
Variabilidad	¿Existen resultados inconsistentes?
Datos	¿Qué información utiliza?
Tiempo	¿Cuándo debe tomarse?
Riesgo	¿Qué ocurre si falla?
Reversibilidad	¿Puede corregirse?
Responsable	¿Quién responde?

La inteligencia artificial aporta mayor valor en decisiones:

- frecuentes;
- basadas en datos;
- con patrones;
- económicamente relevantes;
- susceptibles de actuación.

16.8. Inventario de problemas

Los problemas deben describirse mediante evidencia.

Ejemplo deficiente:

La formulación podría ser más inteligente.

Ejemplo adecuado:

El coste medio de la fórmula supera en 6,8 €/t el coste teórico mínimo debido a la actualización mensual de matrices y a la variabilidad no incorporada de cuatro materias primas principales.

La segunda formulación permite:

- medir;
- diseñar;
- validar;
- calcular retorno.

16.9. Diagnóstico de datos

Debe analizarse:

- disponibilidad;
- calidad;
- frecuencia;
- accesibilidad;
- trazabilidad;
- propiedad;
- formato.

Puede calcularse una puntuación:

$$Q_D = w_c C + w_a A + w_t T + w_r R + w_i I$$

donde:

- (C): completitud;
- (A): exactitud;
- (T): actualidad;
- (R): representatividad;
- (I): integridad.

La puntuación no sustituye la revisión cualitativa.

Un conjunto puede ser completo y no contener la variable causal relevante.

16.10. Catálogo de fuentes

Las fuentes habituales incluyen:

- ERP;
- LIMS;
- MES;
- SCADA;
- NIRS;
- sensores;
- registros manuales;
- bases externas;
- datos de clientes;

- proveedores.

Cada fuente debe tener:

- propietario;
- descripción;
- unidad;
- frecuencia;
- calidad;
- acceso;
- retención.

16.11. Flujo real de datos

Debe distinguirse entre el flujo diseñado y el flujo real.

En muchas organizaciones existen:

- hojas de cálculo;
- correos;
- transcripciones;
- correcciones manuales;
- bases paralelas.

Estos elementos pueden contener conocimiento operativo crítico, pero también errores.

El diagnóstico debe observarlos sin asumir que el sistema oficial refleja toda la operación.

16.12. Deuda de datos

La deuda puede clasificarse en:

Estructural

Sistemas no conectados.

Semántica

Variables con significados distintos.

Histórica

Datos incompletos o inconsistentes.

Organizativa

Ausencia de propietarios.

Regulatoria

Falta de base o control de uso.

La hoja de ruta debe incluir proyectos para reducir deuda, no solo aplicaciones finales.

16.13. Diagnóstico de infraestructura

Debe evaluar:

- conectividad;
- capacidad;
- integración;
- latencia;
- almacenamiento;
- disponibilidad;
- seguridad.

No todo caso necesita infraestructura avanzada.

Pero una aplicación de control en tiempo real exige condiciones muy diferentes de un sistema de análisis mensual.

16.14. Diagnóstico de ciberseguridad

Debe analizarse:

- identidad;
- permisos;
- segmentación;
- actualización;
- copias;
- recuperación;
- proveedores.

La conexión de equipos industriales con plataformas analíticas puede abrir nuevas rutas de ataque.

La seguridad debe diseñarse antes de la integración.

16.15. Diagnóstico de capacidades humanas

Debe identificarse:

- conocimiento de dominio;
- competencia de datos;
- experiencia en validación;
- gestión de proyectos;
- capacidad de mantenimiento.

Puede representarse:

$$G_C = C_{\text{requerida}} C_{\text{disponible}}$$

La brecha puede cubrirse mediante:

- formación;
- contratación;
- colaboración;
- proveedor.

16.16. Diagnóstico de gobernanza

Debe comprobarse si existen:

- inventario;
- política;
- clasificación;
- responsables;
- validación;
- registro;
- incidentes;
- cambios.

Una organización sin gobernanza puede comenzar con aplicaciones de bajo riesgo, pero no debería automatizar decisiones críticas.

16.17. Evaluación de madurez

Puede utilizarse una escala de seis niveles.

Tabla 32. Síntesis de nivel y característica.

Nivel	Característica
0	Datos y procesos no estructurados
1	Digitalización básica
2	Analítica descriptiva
3	Predicción supervisada
4	Optimización integrada
5	Autonomía controlada

La madurez puede variar por proceso.

Una empresa puede tener producción avanzada y compras gestionadas mediante hojas de cálculo.

16.18. Perfil de madurez desigual

No debe calcularse únicamente una media corporativa.

Puede utilizarse un vector:

$$M = (M_{\text{compras}}, M_{\text{calidad}}, M_{\text{formulación}}, M_{\text{producción}}, M_{\text{granja}})$$

Esto permite seleccionar casos compatibles con la madurez de cada área.

16.19. Identificación de casos de uso

Los casos pueden obtenerse mediante:

- entrevistas;
- talleres;
- análisis de datos;
- auditorías;
- incidencias;
- benchmarking.

Cada caso debe describirse en una ficha homogénea.

16.20. Ficha de caso de uso

La ficha debería incluir:

1. problema;
2. decisión;
3. usuario;
4. datos;
5. salida;
6. acción;
7. beneficio;
8. riesgo;
9. integración;
10. dependencia;
11. validación;
12. propietario.

Esta ficha evita propuestas vagas.

16.21. Taxonomía de casos

Descriptivos

Explican qué ha ocurrido.

Diagnósticos

Identifican causas probables.

Predictivos

Estiman qué ocurrirá.

Prescriptivos

Recomiendan acciones.

Autónomos

Ejecutan acciones.

El riesgo y la exigencia aumentan con la capacidad de intervención.

16.22. Casos de uso fundacionales

Incluyen:

- limpieza de datos;
- catálogo;
- identificación;
- integración;
- cuadros de mando.

No siempre utilizan IA avanzada, pero habilitan proyectos posteriores.

Deben valorarse por su efecto transversal.

16.23. Casos de uso de bajo riesgo

Pueden incluir:

- clasificación documental;
- previsión no crítica;
- detección de anomalías informativa;
- búsqueda técnica;
- soporte interno.

Son adecuados para desarrollar capacidades y confianza.

16.24. Casos de uso de valor operativo

Pueden incluir:

- mantenimiento predictivo;
- control energético;
- predicción de calidad;
- optimización de inventario;
- planificación.

Suelen disponer de métricas económicas claras.

16.25. Casos de uso críticos

Incluyen:

- formulación automática;
- dosificación;
- liberación;
- control sanitario;
- recomendación clínica.

Requieren:

- validación rigurosa;
- límites;
- supervisión;
- contingencia;
- expediente completo.

16.26. Priorización multicriterio

Puede calcularse:

$$S_i = w_V V_i + w_F F_i + w_A A_i + w_E E_i w_R R_i w_C C_i$$

donde:

- (V_i): valor;
- (F_i): factibilidad;
- (A_i): alineación;
- (E_i): efecto habilitador;
- (R_i): riesgo;
- (C_i): complejidad.

Los pesos deben ser explícitos.

16.27. Valor

El valor puede incluir:

- ahorro;
- ingreso;
- riesgo evitado;
- calidad;
- velocidad;
- sostenibilidad.

Debe diferenciarse entre:

- valor potencial;
- valor capturable;
- valor atribuible.

16.28. Factibilidad

La factibilidad depende de:

- datos;
- tecnología;
- integración;
- usuario;
- proveedor;

- validación.

Un caso de alto valor puede posponerse si no existe infraestructura.

16.29. Efecto habilitador

Algunos proyectos crean capacidades para otros.

Ejemplo:

- identificación por lote;
- arquitectura de datos;
- integración LIMS-ERP.

Su retorno directo puede ser limitado, pero su valor estratégico elevado.

16.30. Riesgo

Debe considerar:

- salud;
- producto;
- operación;
- ciberseguridad;
- regulación;
- reputación.

Un proyecto de alto valor y alto riesgo puede ser prioritario para investigación, pero no para despliegue inmediato.

16.31. Matriz valor-factibilidad

Tabla 33. Síntesis de factibilidad alta y factibilidad baja.

	Factibilidad alta	Factibilidad baja
Valor alto	Prioridad inmediata	Preparar fundamentos
Valor bajo	Automatización selectiva	No priorizar

La matriz debe complementarse con riesgo y dependencia.

16.32. Portafolio equilibrado

Un portafolio puede distribuir recursos entre:

- 40 % casos de retorno próximo;
- 30 % fundamentos;
- 20 % estratégicos;
- 10 % investigación.

La proporción dependerá de la empresa.

Lo importante es evitar concentrar todo en proyectos visibles o, por el contrario, en infraestructura sin resultados.

16.33. Secuenciación por dependencias

Puede construirse un grafo:

$$G = (V, E)$$

donde una arista indica que un proyecto necesita otro.

Ejemplo:

formulación dinámica ← matrices por lote ← NIRS integrado ← identificación fiable

La hoja de ruta debe respetar estas dependencias.

16.34. Selección del primer caso

El primer caso debería:

- resolver un problema relevante;
- tener datos suficientes;
- ser comprensible;
- presentar riesgo manejable;
- producir aprendizaje reutilizable.

No debe ser demasiado trivial ni excesivamente ambicioso.

16.35. Definición de hipótesis

Todo proyecto debe comenzar con una hipótesis.

Ejemplo:

La incorporación de predicciones NIRS por lote reducirá la desviación entre proteína formulada y proteína real al menos un 25 %, sin aumentar el coste medio más de 1 €/t.

La hipótesis debe incluir:

- intervención;
- población;
- comparación;
- resultado;
- umbral.

16.36. Métricas primarias

Debe existir una métrica principal.

Ejemplos:

- coste por tonelada;
- error de predicción;
- tasa de fallo;
- tiempo de parada;
- conversión;
- nitrógeno excretado.

La multiplicidad de métricas puede permitir seleccionar después la más favorable.

16.37. Métricas de protección

Debe garantizarse que la mejora no perjudica:

- seguridad;
- salud;
- calidad;
- bienestar;
- sostenibilidad.

Ejemplo:

$$\min C_{\text{fórmula}}$$

sujeto a:

$$P(\text{deficiencia}) < \alpha$$

16.38. Datos mínimos

Antes del piloto debe evaluarse:

- volumen;
- variabilidad;
- prevalencia;
- calidad;
- periodo.

No existe un número universal de registros.

Un evento raro puede requerir años de datos. Un proceso estable puede modelarse con menos observaciones.

16.39. Preparación de datos

Las tareas incluyen:

- limpieza;
- normalización;
- etiquetado;
- unión;
- exclusión;

- partición.

Cada transformación debe documentarse.

La limpieza no debe eliminar precisamente los casos difíciles que el sistema tendrá que gestionar.

16.40. Separación temporal

En series temporales no debe mezclarse aleatoriamente pasado y futuro.

La validación debe simular el uso real:

entrenamiento < validación < prueba

Esto evita fuga de información.

16.41. Fuga de datos

La fuga ocurre cuando el modelo utiliza información que no estará disponible en el momento de decidir.

Ejemplos:

- resultado posterior;
- variable calculada después;
- etiqueta incorporada indirectamente.

Puede producir resultados extraordinarios e irreales.

16.42. Selección del enfoque técnico

Debe compararse:

- regla;
- estadística;
- optimización;
- aprendizaje automático;
- aprendizaje profundo.

La elección debe basarse en:

- estructura;
- volumen;
- interpretabilidad;
- mantenimiento;
- rendimiento.

No debería utilizarse aprendizaje profundo cuando una regresión robusta produce valor equivalente.

16.43. Modelo de referencia

Antes de construir un modelo complejo debe establecerse un baseline:

- media;
- regla;
- modelo lineal;
- práctica actual.

La IA debe superarlo en una métrica relevante.

$$\Delta = M_{IA} M_{baseline}$$

Si la mejora es mínima, la complejidad puede no justificarse.

16.44. Desarrollo interno, externo o híbrido

La decisión debe considerar:

- capacidad;
- rapidez;
- control;
- mantenimiento;
- propiedad.

Un proveedor puede desarrollar el sistema, pero la empresa debe conservar conocimiento suficiente para evaluarlo.

16.45. Selección de proveedor

Debe evaluarse:

- experiencia sectorial;
- referencias;
- transparencia;
- validación;
- seguridad;
- integración;
- soporte;
- salida.

Una demostración con datos preparados no sustituye una prueba real.

16.46. Prueba técnica

La prueba debe utilizar:

- datos propios;
- casos representativos;
- condiciones difíciles;
- criterios definidos.

Debe evitarse proporcionar al proveedor únicamente los registros más limpios.

16.47. Diseño del piloto

El piloto debe especificar:

- alcance;
- duración;
- población;
- comparación;
- usuarios;
- riesgo;
- decisión;
- métricas.

Debe probar el sistema completo, no únicamente el modelo.

16.48. Duración del piloto

Debe cubrir la variabilidad relevante:

- campañas;
- lotes;
- estaciones;
- fases;
- equipos.

Un piloto demasiado corto puede no observar:

- deriva;
- adaptación;
- fallos raros;
- carga operativa.

16.49. Modo sombra

El modo sombra permite comparar sin actuar.

Debe registrar:

- predicción;
- decisión humana;
- discrepancia;
- resultado.

Su objetivo es evaluar seguridad y utilidad antes de la intervención.

16.50. Intervención controlada

Cuando la evidencia lo permite, puede pasarse a recomendaciones supervisadas.

El usuario debe:

- aceptar;
- modificar;
- rechazar;
- justificar.

Esto permite analizar interacción y valor.

16.51. Grupo de comparación

Siempre que sea viable, debe existir:

- línea;
- explotación;
- lote;
- periodo;

no expuesto a la intervención.

Sin comparación, los cambios externos pueden confundirse con efecto del sistema.

16.52. Diseño escalonado

Cuando no es posible aplicar simultáneamente, puede utilizarse un despliegue escalonado.

Diferentes unidades adoptan el sistema en momentos distintos.

Esto facilita comparación y reduce riesgo.

16.53. Evaluación estadística

Debe incluir:

- efecto;
- intervalo;
- significación;
- relevancia práctica.

Un resultado puede ser estadísticamente significativo y económicamente irrelevante.

16.54. Evaluación económica

Debe calcular:

- coste real;
- ahorro real;
- tiempo;
- mantenimiento;
- retorno.

Los costes de personal dedicados al piloto deben registrarse.

16.55. Evaluación humana

Debe analizar:

- comprensión;
- confianza;
- carga;
- uso;
- override;
- errores.

Una herramienta rentable en teoría puede fracasar si aumenta excesivamente el trabajo.

16.56. Evaluación de riesgo

Debe comprobar:

- incidentes;
- situaciones límite;
- abstención;
- contingencia;
- seguridad.

El piloto debe intentar descubrir debilidades, no confirmar expectativas.

16.57. Red teaming

Puede constituirse un equipo encargado de buscar:

- entradas adversas;
- datos anómalos;
- fallos;
- usos indebidos;
- vulnerabilidades.

Esto es especialmente relevante en aplicaciones críticas y generativas.

16.58. Criterios de aceptación

Los criterios deben fijarse antes.

Ejemplo:

Tabla 34. Síntesis de dimensión y criterio.

Dimensión	Criterio
Técnica	Error < 5 %
Operativa	Disponibilidad > 99 %
Económica	ROI esperado > 20 %
Humana	Adopción efectiva > 75 %

Dimensión	Criterio
Riesgo	Ningún incidente crítico
Datos	Compleitud > 95 %

Los valores deben adaptarse al caso.

16.59. Criterios de abandono

También deben definirse:

- rendimiento insuficiente;
- datos no sostenibles;
- coste excesivo;
- riesgo no mitigable;
- baja adopción;
- dependencia inaceptable.

Abandonar un proyecto que no cumple criterios protege recursos.

16.60. Revisión de puertas

Puede establecerse:

Gate 0

Problema validado.

Gate 1

Datos y factibilidad.

Gate 2

Prototipo.

Gate 3

Piloto.

Gate 4

Producción limitada.

Gate 5

Escalado.

Cada puerta requiere evidencia específica.

16.61. Paso a producción

El despliegue necesita más que un modelo validado.

Debe incluir:

- infraestructura;
- soporte;
- usuarios;
- procedimientos;
- seguridad;
- contingencia;
- documentación;
- monitorización.

El sistema debe estar preparado para condiciones menos controladas que el piloto.

16.62. Integración operacional

La salida debe incorporarse al flujo de trabajo.

Puede integrarse en:

- ERP;
- MES;
- SCADA;
- LIMS;
- aplicación móvil.

Obligar al usuario a consultar una plataforma separada puede reducir adopción.

16.63. Diseño de la interfaz

La interfaz debe mostrar:

- recomendación;
- confianza;
- explicación;
- acción;
- límite;
- fuente.

Debe permitir registrar:

- aprobación;
- rechazo;
- comentario;
- resultado.

16.64. Procedimientos normalizados

Deben actualizarse:

- uso;
- verificación;
- override;
- error;
- contingencia;
- escalado.

El sistema no debe operar al margen del sistema de calidad.

16.65. Formación previa al despliegue

La formación debe incluir:

- finalidad;
- límites;
- casos;
- errores;
- actuación;
- responsabilidad.

Debe evaluarse la competencia antes de autorizar uso.

16.66. Estrategia de despliegue

Big bang

Implantación simultánea.

Riesgo elevado.

Gradual

Por planta, línea o producto.

Mayor control.

Canary

Se aplica a una fracción limitada y se amplía según desempeño.

Adecuado para sistemas digitales escalables.

16.67. Paralelo temporal

Durante un periodo pueden coexistir:

- sistema anterior;

- sistema nuevo.

Esto permite comparar y asegurar continuidad.

Pero mantener indefinidamente dos sistemas aumenta coste y confusión.

16.68. Plan de contingencia

Debe responder:

- cómo detectar fallo;
- quién decide;
- cómo operar;
- cómo recuperar;
- cómo comunicar.

La contingencia debe probarse.

Un procedimiento no ensayado puede ser inútil durante una incidencia.

16.69. Monitorización de producción

Debe incluir:

- desempeño;
- calidad de datos;
- deriva;
- uso;
- latencia;
- disponibilidad;
- incidentes.

Puede construirse:

$$M_t = f(E_t, D_t, A_t, R_t)$$

donde:

- (E_t): error;
- (D_t): deriva;
- (A_t): adopción;
- (R_t): riesgo.

16.70. Límites operativos

Deben definirse umbrales para:

- alerta;
- revisión;
- suspensión.

Ejemplo:

$$E_t > E_{\max} \Rightarrow \text{suspender automatización}$$

No debe esperarse a un incidente grave.

16.71. Gestión de deriva

Cuando se detecta deriva debe investigarse:

- sensor;
- proceso;
- mercado;
- materia;
- población;
- modelo.

La respuesta puede ser:

- corregir datos;
- recalibrar;
- reentrenar;
- limitar alcance;
- retirar.

16.72. Reentrenamiento

Debe existir un procedimiento que defina:

- frecuencia;
- datos;
- aprobación;
- prueba;
- versión.

El reentrenamiento automático no controlado puede convertir el sistema en una entidad cambiante difícil de validar.

16.73. Gestión de versiones

Debe registrarse:

- modelo;
- datos;
- código;
- configuración;
- interfaz.

Toda decisión debe vincularse a una combinación concreta.

16.74. Gestión de cambios

Los cambios pueden ser:

- menores;
- significativos;
- sustanciales.

Cada categoría debe tener requisitos diferentes.

Cambiar un texto no equivale a introducir una nueva variable o ampliar el sistema a otra especie.

16.75. Incidentes

Debe existir un canal único para comunicar:

- error;
- recomendación insegura;
- fallo;
- uso indebido;
- problema de datos.

El incidente debe conectarse con el sistema corporativo de calidad.

16.76. CAPA algorítmica

Las acciones pueden afectar a:

- modelo;
- dato;
- proceso;
- usuario;
- interfaz;
- proveedor.

Debe verificarse su eficacia.

16.77. Revisión de valor

El desempeño técnico no basta.

Debe comprobarse periódicamente:

- ahorro;
- beneficio;
- riesgo evitado;
- adopción;
- coste.

Un sistema que ha dejado de producir valor debe modificarse o retirarse.

16.78. Escalado

El escalado puede realizarse por:

- volumen;
- geografía;
- planta;
- especie;
- autonomía;
- funcionalidad.

No deben ampliarse simultáneamente todas las dimensiones.

16.79. Plantilla corporativa

Para escalar, deben estandarizarse:

- arquitectura;
- conectores;
- validación;
- documentación;
- formación;
- monitorización.

La plantilla reduce tiempo y variabilidad.

16.80. Adaptación local

Cada unidad puede necesitar ajustes por:

- proceso;
- equipo;
- datos;
- usuario;
- legislación.

La estandarización no debe eliminar la validación local.

16.81. Validación de transferencia

Antes de trasladar un modelo debe comprobarse:

$$P_{\text{origen}}(X) \approx P_{\text{destino}}(X)$$

y también:

$$P_{\text{origen}}(Y | X) \approx P_{\text{destino}}(Y | X)$$

Si las distribuciones difieren, puede ser necesaria adaptación.

16.82. Centro de excelencia

Puede proporcionar:

- estándares;
- plataforma;
- validación;
- soporte;
- formación.

Debe trabajar con responsables locales.

El centro no debería convertirse en propietario de todas las decisiones sectoriales.

16.83. Comunidad de usuarios

Los usuarios pueden compartir:

- errores;
- mejoras;
- patrones;
- casos.

La comunidad aumenta aprendizaje y reduce duplicidad.

16.84. Reutilización responsable

Pueden reutilizarse:

- infraestructura;
- procesos;
- herramientas;
- datos.

Los modelos solo deben reutilizarse cuando existe compatibilidad y validación.

16.85. Cuadro de mando corporativo

Puede incluir:

Tabla 35. Síntesis de dimensión y indicador.

Dimensión	Indicador
Portafolio	Casos activos
Valor	Beneficio acumulado
Riesgo	Incidentes
Datos	Calidad
Adopción	Uso efectivo
Modelos	Validación vigente

Dimensión	Indicador
Personas	Competencia
Proveedores	Dependencia
Escalado	Unidades implantadas
Sostenibilidad	Impacto evitado

16.86. Revisión trimestral del portafolio

Debe decidir:

- continuar;
- acelerar;
- fusionar;
- corregir;
- cerrar.

Los proyectos no deben permanecer activos por inercia.

16.87. Presupuesto dinámico

Los recursos pueden reasignarse según:

- evidencia;
- valor;
- dependencia;
- prioridad.

Esto evita comprometer presupuestos plurianuales con proyectos que ya no son viables.

16.88. Gobierno financiero

Las finanzas deben revisar:

- línea basal;
- atribución;
- costes;
- retorno.

El área técnica no debería validar por sí sola el beneficio económico.

16.89. Gobierno técnico

Debe aprobar:

- arquitectura;
- modelo;
- integración;
- seguridad;
- operación.

16.90. Gobierno sectorial

Nutrición, veterinaria, calidad y producción deben validar:

- coherencia;
- seguridad;
- utilidad;
- límites.

16.91. Gobierno de riesgos

Debe evaluar:

- severidad;
- probabilidad;
- controles;
- riesgo residual.

La aceptación debe corresponder al nivel directivo adecuado.

16.92. Arquitectura mínima viable

Una organización no necesita construir desde el inicio una plataforma total.

Puede comenzar con:

- repositorio controlado;
- catálogo;
- integración básica;
- monitorización;
- inventario de modelos.

La arquitectura debe permitir crecer sin obligar a rehacer todo.

16.93. Principio de modularidad

Los componentes deberían separarse:

- datos;
- modelo;
- reglas;
- interfaz;
- acción.

Esto facilita cambiar un componente sin alterar todo el sistema.

16.94. Separación entre predicción y control

La predicción puede provenir de IA.

Los límites críticos deben permanecer en una capa independiente.

$$u_t = \text{clip}(\pi(x_t), u_{\min}, u_{\max})$$

Esto evita que una salida extrema se ejecute directamente.

16.95. Arquitectura de referencia

Capa de captura

- sensores;
- laboratorio;
- registros.

Capa de integración

- APIs;
- mensajería;
- ETL.

Capa de datos

- almacenamiento;
- catálogo;
- calidad.

Capa analítica

- modelos;
- simulación;
- optimización.

Capa de decisión

- reglas;
- límites;
- supervisión.

Capa operativa

- ERP;
- MES;
- equipos.

Capa de aseguramiento

- logs;
- monitorización;
- auditoría.

16.96. Seguridad desde el diseño

La seguridad debe incluir:

- mínimo privilegio;
- autenticación;
- segmentación;
- cifrado;
- registro;
- recuperación.

Debe evitarse añadir seguridad después del despliegue.

16.97. Calidad desde el diseño

Los controles de calidad deben integrarse en:

- captura;
- procesamiento;
- predicción;
- actuación.

No debe dependerse únicamente de una revisión final.

16.98. Explicabilidad desde el diseño

La explicación debe definirse según:

- usuario;
- decisión;
- riesgo.

No es sencillo añadir interpretabilidad al final si la arquitectura no la contempla.

16.99. Privacidad desde el diseño

Cuando existan datos personales o confidenciales, debe aplicarse:

- minimización;
- separación;
- control;
- retención.

16.100. Sostenibilidad desde el diseño

Debe evaluarse:

- consumo computacional;
- hardware;
- vida útil;
- efecto real.

Una solución ambiental no debería generar una infraestructura desproporcionada.

16.101. Documentación mínima

Todo sistema debería disponer de:

- ficha;
- finalidad;
- propietario;
- datos;
- validación;
- riesgos;
- controles;
- versiones;
- procedimiento;
- monitorización.

La profundidad aumenta con la criticidad.

16.102. Expediente de implantación

Puede dividirse en:

1. caso de negocio;
2. evaluación de riesgo;
3. diseño;
4. validación;
5. formación;
6. despliegue;
7. seguimiento;
8. incidentes;
9. cambios;
10. retirada.

16.103. Auditoría de preparación

Antes de producción debe comprobarse:

- documentación;
- datos;
- integración;
- seguridad;
- usuarios;
- contingencia;
- responsabilidad.

Puede utilizarse una lista de bloqueo.

Si falta un elemento crítico, no debe desplegarse.

16.104. Primeros cien días

Una estrategia inicial puede estructurarse así.

Días 1-30

- patrocinio;
- equipo;
- diagnóstico;
- inventario;
- principios.

Días 31-60

- mapa de casos;
- priorización;
- selección;
- datos;
- proveedor.

Días 61-100

- diseño de piloto;
- baseline;
- métricas;
- riesgo;
- formación inicial.

El objetivo no es implantar autonomía en cien días, sino crear una base ejecutable.

16.105. Primer año**Trimestre 1**

Diagnóstico y selección.

Trimestre 2

Pilotos fundacionales y de bajo riesgo.

Trimestre 3

Validación y primeros despliegues.

Trimestre 4

Escalado selectivo y revisión estratégica.

La velocidad debe ajustarse a la capacidad de la organización.

16.106. Horizonte de tres años**Año 1**

Fundamentos y casos iniciales.

Año 2

Integración y optimización.

Año 3

Escalado, personalización y autonomía limitada.

No debería avanzarse a autonomía si no existe monitorización madura.

16.107. Señales de avance saludable

- Los usuarios participan.
- Los datos mejoran.
- Los proyectos tienen métricas.
- Se abandonan iniciativas.
- Los beneficios se verifican.
- Los incidentes se documentan.
- La responsabilidad es clara.
- La organización conserva capacidad manual.

16.108. Señales de fracaso

- Muchos pilotos y pocos sistemas.
- Proveedores controlan todo el conocimiento.
- No existe baseline.
- Los beneficios son narrativos.
- Los usuarios mantienen hojas paralelas.
- Nadie sabe qué versión opera.
- La dirección exige automatización sin validar.
- Los errores se atribuyen genéricamente a personas.

16.109. Antipatrones**Tecnología en busca de problema**

Se adquiere la herramienta antes de definir uso.

Piloto eterno

No existe decisión de producción o cierre.

Datos perfectos futuros

Se pospone todo esperando una calidad ideal.

Big bang

Se automatiza demasiado de una vez.

Proveedor como propietario del proceso

La empresa pierde conocimiento y control.

Métrica vanidosa

Se comunica precisión sin impacto.

Human in the loop simbólico

La persona acepta sin capacidad real de revisión.

Automatización del caos

Se digitaliza un proceso no estabilizado.

16.110. Estrategia para pequeñas y medianas empresas

Las pymes pueden evitar grandes inversiones mediante:

- casos concretos;
- servicios en nube;
- proveedores especializados;
- consorcios;
- plataformas compartidas.

Deben proteger especialmente:

- datos;
- salida;
- dependencia;
- costes recurrentes.

La falta de escala no impide utilizar IA, pero exige mayor disciplina en selección.

16.111. Estrategia para grandes grupos

Los grandes grupos pueden construir:

- plataformas comunes;
- centros de excelencia;
- modelos federados;
- estándares.

Su principal riesgo es la fragmentación entre plantas y países.

La escala solo produce ventaja si existe interoperabilidad.

16.112. Estrategia para fabricantes de ingredientes

Pueden utilizar IA para:

- descubrimiento;

- formulación;
- soporte;
- predicción de respuesta;
- documentación;
- segmentación.

El riesgo es generar recomendaciones demasiado amplias con datos limitados.

16.113. Estrategia para fabricantes de piensos

Los casos prioritarios pueden concentrarse en:

- materias;
- formulación;
- proceso;
- calidad;
- logística;
- cliente.

Deben integrar la IA con APPCC y sistemas de fabricación.

16.114. Estrategia para integradores y cooperativas

Pueden agregar datos de múltiples explotaciones.

Esto permite:

- benchmarking;
- alertas;
- personalización;
- compra conjunta.

La gobernanza debe definir retorno y control de datos para los productores.

16.115. Estrategia para explotaciones

Debe priorizarse:

- facilidad;
- mantenimiento;
- valor visible;
- conectividad;
- soporte.

Un sistema complejo que depende de atención continua puede no ser viable.

16.116. Estrategia para acuicultura

La sensorización y el control permiten aplicaciones avanzadas.

La hoja de ruta puede comenzar con:

- biomasa;
- comportamiento;
- oxígeno;
- consumo.

Después avanzar hacia control cerrado.

16.117. Estrategia para petfood

Puede combinar:

- formulación;
- palatabilidad;
- personalización;
- marketing;
- seguimiento.

Debe existir separación clara entre recomendación comercial y nutrición clínica.

16.118. Estrategia para investigación

Los proyectos deben diseñarse para producir:

- evidencia;
- datos reutilizables;
- modelos transferibles;
- documentación.

La colaboración industrial debe preservar rigor y reproducibilidad.

16.119. Gobernanza del ecosistema

La implantación puede involucrar:

- proveedores;
- clientes;
- universidades;
- laboratorios;
- administraciones.

Deben definirse:

- estándares;
- datos;
- responsabilidad;
- propiedad;
- interoperabilidad.

16.120. Contratos de datos

Deben regular:

- finalidad;
- acceso;
- calidad;
- uso;
- entrenamiento;
- conservación;
- salida.

El valor futuro de los datos justifica una negociación cuidadosa.

16.121. Contratos de desempeño

Cuando el proveedor promete resultados, deben definirse:

- baseline;
- métrica;
- periodo;
- exclusiones;
- auditoría.

16.122. Seguro y transferencia de riesgo

La empresa puede evaluar coberturas para:

- ciberincidentes;
- fallos tecnológicos;
- responsabilidad.

El seguro no sustituye controles.

16.123. Comunicación interna

Debe explicar:

- problema;
- beneficio;
- límites;
- impacto en puestos;
- responsabilidad.

La comunicación exagerada genera desconfianza.

16.124. Comunicación a clientes

Cuando la IA afecta al servicio o producto, debe comunicarse de manera proporcional.

No debe presentarse como garantía de:

- ausencia de riesgo;
- resultado individual;
- sostenibilidad perfecta.

16.125. Transparencia frente a secretos empresariales

La empresa puede proteger:

- código;
- fórmula;
- estrategia.

Pero debe proporcionar información suficiente sobre:

- finalidad;
- validación;
- límites;
- responsabilidad.

16.126. Revisión ética

Los casos de mayor impacto deberían valorar:

- bienestar;
- trabajo;
- equidad;
- sostenibilidad;
- dependencia.

La revisión ética no sustituye la legal, pero amplía el análisis.

16.127. Indicadores de éxito de la hoja de ruta

Tabla 36. Síntesis de dimensión y indicador.

Dimensión	Indicador
Estrategia	Casos alineados
Datos	Mejora de calidad
Valor	Beneficio verificado
Riesgo	Incidentes controlados
Personas	Competencia y adopción
Tecnología	Disponibilidad
Escalado	Replicación exitosa
Gobernanza	Sistemas inventariados
Aprendizaje	Proyectos cerrados con lecciones
Resiliencia	Contingencias probadas

16.128. Cuadro de decisión final

Antes de aprobar un sistema debe responderse:

1. ¿El problema está cuantificado?
2. ¿La IA supera una alternativa más simple?
3. ¿Los datos son sostenibles?
4. ¿El resultado modifica una decisión?
5. ¿El beneficio está demostrado?
6. ¿El riesgo residual es aceptable?
7. ¿Existe supervisión efectiva?
8. ¿Puede operarse sin el sistema?
9. ¿Puede cambiarse de proveedor?
10. ¿Puede reconstruirse cada decisión?

Una respuesta negativa no siempre obliga a abandonar, pero exige una acción previa.

16.129. Principios de ejecución disciplinada

1. Empezar por decisiones, no por algoritmos.
2. Priorizar valor verificable y riesgo controlable.
3. Construir fundamentos mientras se generan resultados.
4. Validar en condiciones reales.
5. Definir criterios de abandono.
6. Integrar la IA en el sistema de calidad.
7. Escalar por etapas.
8. Monitorizar valor y riesgo.
9. Conservar conocimiento y contingencia.
10. Retirar los sistemas que dejan de ser útiles.

16.130. Conclusión: implantar inteligencia artificial es construir una capacidad organizativa de decisión

La implantación de inteligencia artificial en nutrición animal no puede reducirse a una sucesión de proyectos tecnológicos. Debe concebirse como la construcción progresiva de una capacidad empresarial para convertir datos en decisiones mejores, más rápidas, más consistentes y más responsables.

Esa capacidad depende de una arquitectura compuesta por:

- procesos definidos;
- datos gobernados;
- modelos validados;
- profesionales competentes;
- controles independientes;
- trazabilidad;
- aprendizaje.

La hoja de ruta no debe comenzar con la pregunta sobre qué sistema adquirir, sino con la identificación de decisiones cuyo desempeño actual puede medirse y cuya mejora generaría valor real.

La disciplina de implantación exige aceptar que no todos los proyectos deben avanzar. Algunos demostrarán que los datos son insuficientes. Otros revelarán que una solución convencional es preferible. Otros producirán valor durante un periodo y deberán retirarse después.

El abandono de una iniciativa sin retorno no representa fracaso. El verdadero fracaso consiste en mantenerla por razones reputacionales, presupuestarias o políticas cuando la evidencia ya no la justifica.

La organización debe resistir la tentación de confundir actividad con transformación. El número de pilotos, modelos o licencias no indica madurez. La madurez se demuestra cuando la empresa puede explicar:

- qué problema resolvió;
- cuánto mejoró;
- cuánto costó;
- qué riesgo introdujo;
- quién responde;
- cómo se mantiene.

La implantación progresiva no significa lentitud. Significa aumentar velocidad sin superar la capacidad de control.

Los primeros casos deben producir aprendizaje técnico y organizativo. Los proyectos fundacionales deben mejorar datos e interoperabilidad. Los despliegues críticos deben estar conectados con calidad, seguridad y responsabilidad. El escalado debe reproducir una capacidad completa, no solo copiar software.

La inteligencia artificial aporta valor cuando se integra en el punto exacto donde una decisión produce consecuencias. Esto requiere conectar predicción y acción, pero también conservar límites, supervisión y capacidad de reversión.

La empresa que siga esta hoja de ruta no alcanzará necesariamente la mayor cantidad de automatización. Alcanzará algo más relevante: una estructura capaz de incorporar innovación sin perder control.

En un sector en el que las decisiones afectan a materias primas, procesos industriales, salud animal, seguridad alimentaria, sostenibilidad y economía, esa capacidad de control constituye el criterio central.

La implantación responsable no termina cuando el sistema entra en producción. Comienza entonces una nueva obligación: verificar de forma continua que sigue siendo válido, seguro, útil y comprensible.

Solo las organizaciones que asuman esa obligación estarán en condiciones de convertir la inteligencia artificial en una ventaja industrial sostenible, y no en una dependencia tecnológica difícil de gobernar.

17. Casos de uso sectoriales y arquitecturas de aplicación: de la formulación inteligente a la explotación conectada

La utilidad de la inteligencia artificial en nutrición animal no puede valorarse únicamente desde una perspectiva abstracta. Su desempeño depende de la especie, el sistema productivo, la escala, la disponibilidad de datos, la velocidad de decisión y la capacidad operativa para transformar una predicción en una intervención.

Una misma tecnología puede presentar un elevado valor en un contexto y resultar innecesaria, inviable o incluso contraproducente en otro.

La visión artificial, por ejemplo, puede ofrecer una estimación continua de biomasa en acuicultura intensiva, donde la cámara observa una población confinada y la alimentación puede modificarse de inmediato. La misma técnica resulta más difícil de aplicar en pastoreo extensivo, donde la visibilidad, la identificación y la conectividad son limitadas.

Del mismo modo, una formulación individualizada puede ser económicamente justificable en vacas lecheras de alta producción, reproductores selectos o animales de compañía con patologías específicas, pero no necesariamente en especies o explotaciones donde el coste de separación y dosificación supera el valor de la personalización.

La selección de casos de uso debe basarse, por tanto, en la combinación de cuatro dimensiones:

$$CU = f(V, D, A, R)$$

donde:

- (V): valor potencial;
- (D): disponibilidad y calidad de datos;
- (A): capacidad de actuación;
- (R): riesgo.

Una predicción de elevada precisión tiene escasa utilidad si no existe una acción factible. Una acción potencialmente valiosa no debe automatizarse si el riesgo no puede controlarse. Un proceso abundantemente sensorizado no justifica por sí mismo la construcción de modelos si la decisión actual ya es estable y eficiente.

Este capítulo presenta arquitecturas de aplicación para distintos ámbitos de la nutrición animal. No pretende establecer soluciones universales, sino mostrar cómo deben conectarse:

- problema;
- datos;
- modelo;
- decisión;
- acción;
- métrica;
- control.

17.1. Arquitectura general de un caso de uso

Todo caso de uso puede representarse mediante:

$$X_t \xrightarrow{M} \hat{Y}_{t+h} \xrightarrow{\pi} A_t \rightarrow Y_{t+h}$$

donde:

- (X_t): información disponible;
- (M): modelo;
- ($\hat{Y}_{t+h}$): predicción;
- (π): política de decisión;
- (A_t): acción;
- (Y_{t+h}): resultado observado.

La evaluación completa debe analizar cada transición.

Un modelo puede producir una buena predicción y fracasar porque:

- llega tarde;
- no es comprensible;
- no existe inventario;
- la acción es demasiado costosa;
- el usuario no confía;
- el resultado no se registra.

17.2. Plantilla de evaluación sectorial

Para cada aplicación deben responderse, al menos, las siguientes preguntas:

Tabla 37. Síntesis de elemento y contenido.

Elemento	Contenido
Problema	Pérdida, riesgo o variabilidad
Unidad	Animal, lote, fórmula, equipo o explotación
Datos	Fuentes necesarias
Horizonte	Tiempo hasta la decisión
Salida	Predicción o recomendación
Acción	Intervención disponible
Restricciones	Seguridad, legalidad y proceso
Métrica	Resultado principal
Riesgo	Consecuencia del error
Supervisión	Responsable humano
Validación	Evidencia necesaria
Escalabilidad	Condiciones para replicar

17.3. Caso de uso 1: valoración nutricional dinámica de materias primas

Problema

Las matrices nutricionales estáticas no reflejan completamente la variabilidad entre:

- proveedores;
- campañas;
- regiones;
- lotes;
- condiciones de almacenamiento.

Esta variabilidad puede provocar:

- sobreformulación;
- deficiencia;
- aumento de coste;
- inconsistencia productiva.

Datos mínimos

- espectros NIRS;
- análisis de referencia;
- proveedor;
- origen;
- fecha;
- humedad;
- condiciones de almacenamiento.

Modelo

Puede utilizarse:

- PLS;
- regresión regularizada;
- Random Forest;
- redes neuronales;
- modelos de transferencia.

Salida

Predicción de:

- humedad;
- proteína;
- grasa;
- fibra;
- aminoácidos;
- energía;
- digestibilidad.

Acción

Actualizar el valor del lote en el sistema de formulación.

Métrica primaria

$$E_{\text{nutriente}} |y - \hat{y}|$$

Valor

- menor margen de seguridad;
- menor coste;
- mayor consistencia;
- detección de anomalías.

Riesgo

Una predicción incorrecta puede propagarse a todas las fórmulas que utilizan el lote.

Control

- intervalos de confianza;
- confirmación analítica;
- detección fuera de dominio;
- límites de cambio.

17.4. Caso de uso 2: detección de adulteración y fraude

Problema

Algunas materias pueden presentar:

- sustitución;
- dilución;
- falsificación documental;
- origen incorrecto;
- composición anómala.

Datos

- espectros;
- imágenes;
- cromatografía;
- certificados;
- historial de proveedor;
- precios;
- rutas logísticas.

Modelo

- clasificación;

- detección de anomalías;
- análisis multimodal;
- grafos.

Salida

Puntuación de riesgo:

$$R_f = P(\text{fraude} | X)$$

Acción

- inmovilizar;
- muestrear;
- auditar;
- rechazar.

Métrica

- sensibilidad;
- tasa de falsas alarmas;
- coste de detección;
- incidentes evitados.

Riesgo

Una puntuación de riesgo no constituye prueba definitiva.

Debe utilizarse como instrumento de selección y no como condena automática del proveedor.

17.5. Caso de uso 3: predicción de micotoxinas

Problema

Las micotoxinas presentan distribución heterogénea y dependen de:

- clima;
- cultivo;
- almacenamiento;
- origen;
- especie fúngica.

Datos

- meteorología;
- humedad;
- temperatura;
- cultivo;
- origen;
- análisis históricos;
- almacenamiento.

Salida

Probabilidad de superar un nivel interno o regulatorio:

$$P(C_{\text{micotoxina}} > L \mid X)$$

Acción

- intensificar muestreo;
- segregar;
- seleccionar proveedor;
- reformular;
- aplicar medidas autorizadas.

Métrica

- detección precoz;
- reducción de lotes no conformes;
- coste de muestreo optimizado.

Riesgo

El modelo no sustituye el análisis cuando este sea necesario para aceptar, rechazar o liberar el producto.

17.6. Caso de uso 4: optimización de muestreo

Problema

El muestreo uniforme puede dedicar recursos excesivos a lotes estables y resultar insuficiente en lotes de riesgo elevado.

Modelo de asignación

$$n_i = f(R_i, V_i, H_i)$$

donde:

- (R_i): riesgo del lote;
- (V_i): volumen;
- (H_i): historial.

Acción

Aumentar o reducir:

- número de incrementos;
- frecuencia;
- tipo de análisis.

Valor

- mejor utilización del laboratorio;
- reducción de tiempo;
- mayor sensibilidad en puntos críticos.

Control

Deben mantenerse los mínimos legales y metodológicos aplicables.

La optimización no puede reducir el muestreo por debajo de un nivel técnicamente defendible.

17.7. Caso de uso 5: formulación dinámica de mínimo coste

Problema

La formulación convencional utiliza:

- precios medios;
- matrices estáticas;
- escenarios limitados.

Modelo

$$\min_x c^T x$$

sujeito a:

$$Ax \geq b$$

La IA puede añadir:

- predicción de respuesta;
- incertidumbre;
- restricciones no lineales;
- palatabilidad;
- huella ambiental.

Salida

Fórmula y escenarios alternativos.

Métricas

- coste por tonelada;
- desviación nutricional;
- estabilidad;
- rendimiento productivo.

Riesgo

La reducción aparente de coste puede aumentar:

- variabilidad;
- riesgo digestivo;
- dificultad tecnológica;
- reclamaciones.

Control

Las restricciones críticas deben permanecer independientes del modelo predictivo.

17.8. Caso de uso 6: formulación robusta bajo incertidumbre

La formulación robusta no utiliza únicamente valores medios.

Puede plantearse:

$$\min_x \max_{\theta \in \Theta} C(x, \theta)$$

donde (θ) representa variabilidad de:

- composición;
- precio;
- digestibilidad;
- respuesta.

El objetivo no es obtener la solución más barata en el escenario central, sino una solución estable frente a desviaciones plausibles.

Valor

- menor riesgo de incumplimiento;
- menor sensibilidad a lotes;
- mayor consistencia.

Limitación

Una solución excesivamente conservadora puede aumentar coste innecesariamente.

17.9. Caso de uso 7: reformulación automática por disponibilidad

Problema

Una materia puede quedar:

- agotada;
- retenida;
- fuera de especificación;
- retrasada.

Sistema

El modelo consulta:

- inventario;
- recetas;
- restricciones;
- pedidos;
- capacidad.

Propone alternativas minimizando:

$$J = C_{\text{fórmula}} + C_{\text{cambio}} + C_{\text{riesgo}}$$

Acción

Generar una fórmula alternativa para aprobación.

Riesgo

La sustitución puede afectar:

- proceso;
- color;
- palatabilidad;
- etiquetado;
- claims;
- consistencia.

La revisión debe ser multidisciplinar.

17.10. Caso de uso 8: optimización de premezclas y microingredientes

Problema

Los microingredientes presentan:

- dosis bajas;
- alto impacto;
- riesgo de error;
- incompatibilidades;
- carryover.

Aplicaciones

- secuenciación;
- verificación de identidad;
- predicción de error;
- mantenimiento de dosificadores;
- control de inventario.

Métrica

$$E_d = \frac{|d_{\text{real}} - d_{\text{objetivo}}|}{d_{\text{objetivo}}}$$

Riesgo

Un error pequeño en masa puede tener gran consecuencia biológica o regulatoria.

Control

- identificación positiva;
- límites duros;
- doble verificación;
- reconciliación de masas.

17.11. Caso de uso 9: optimización de molienda**Problema**

El tamaño de partícula afecta:

- digestibilidad;
- consumo energético;
- salud digestiva;
- estabilidad del pellet.

Datos

- tipo de materia;
- humedad;
- criba;
- velocidad;
- consumo;
- distribución granulométrica.

Modelo

Predice:

- tamaño medio;
- dispersión;
- energía;
- capacidad.

Optimización

$$\min[w_1E + w_2D_{50} + w_3\sigma_D]$$

sujeto a límites nutricionales y tecnológicos.

17.12. Caso de uso 10: control inteligente de mezclado**Problema**

La homogeneidad depende de:

- carga;
- tiempo;
- secuencia;
- densidad;
- granulometría;
- equipo.

Modelo

Puede estimar el coeficiente de variación final:

$$\widehat{CV}f(t, L, \rho, S, M)$$

Acción

Ajustar tiempo de mezclado dentro de límites validados.

Valor

- menor tiempo;
- mayor capacidad;
- homogeneidad consistente.

Riesgo

Reducir el tiempo sobre la base de una predicción incorrecta puede producir mezclas no uniformes.

17.13. Caso de uso 11: optimización de peletización

Problema

La peletización exige equilibrar:

- capacidad;
- energía;
- durabilidad;
- temperatura;
- humedad;
- calidad nutricional.

Objetivo multiobjetivo

$$\min J = w_1 E w_2 Q + w_3 F + w_4 D$$

donde:

- (E): energía;
- (Q): capacidad;
- (F): finos;
- (D): degradación.

Variables

- vapor;
- humedad;
- temperatura;
- velocidad;
- matriz;
- formulación.

Control

Los límites térmicos y sanitarios no deben relajarse por optimización económica.

17.14. Caso de uso 12: extrusión inteligente

La extrusión presenta interacciones no lineales entre:

- humedad;
- temperatura;
- presión;
- velocidad;
- expansión;
- gelatinización.

Aplicaciones

- predicción de densidad;
- estabilidad acuática;
- cocción;
- consumo;
- calidad física.

Modelo

Puede utilizarse un gemelo híbrido para estimar el estado interno del proceso.

Riesgo

Los cambios pueden producir efectos rápidos y difíciles de revertir.

La autonomía debe aumentar gradualmente.

17.15. Caso de uso 13: control de contaminación cruzada

Problema

El carryover depende de:

- secuencia;
- equipo;
- limpieza;

- adherencia;
- concentración.

Modelo

$$C_{j,t}\alpha_j C_{j,t-1} + \beta_j D_t$$

donde:

- (α_j): persistencia;
- (D_t): dosis anterior.

Acción

Optimizar:

- orden;
- flushing;
- limpieza;
- tiempos.

Métrica

- concentración residual;
- producto de limpieza;
- tiempo perdido.

Control

Las reglas de incompatibilidad deben actuar como restricciones absolutas.

17.16. Caso de uso 14: mantenimiento predictivo

Problema

Los fallos de:

- molino;
- prensa;
- reductor;
- motor;
- rodamiento;
- transportador;

pueden detener producción o afectar calidad.

Datos

- vibración;
- temperatura;
- corriente;

- presión;
- sonido;
- historial.

Salida

- anomalía;
- probabilidad de fallo;
- vida útil restante.

$$RUL = f(X_{1:t})$$

Acción

Planificar intervención.

Métrica

- horas de parada;
- coste;
- disponibilidad;
- falsas alarmas.

Riesgo

El mantenimiento no debe posponerse únicamente porque el modelo estime baja probabilidad de fallo.

17.17. Caso de uso 15: predicción de demanda de pienso

Problema

La demanda depende de:

- censos;
- edad;
- estacionalidad;
- contratos;
- sanidad;
- precios;
- clima.

Modelo

$$\hat{D}_{t+h}f(D_{1:t}, Z_t)$$

Acción

Ajustar:

- producción;
- compras;

- turnos;
- transporte.

Métrica

- error;
- rotura;
- inventario;
- expediciones urgentes.

Riesgo

El error puede producir tanto exceso como desabastecimiento.

La incertidumbre debe trasladarse a políticas de inventario.

17.18. Caso de uso 16: planificación de inventario

La política puede calcular:

$$SS = z\sigma_L T$$

donde:

- (SS): stock de seguridad;
- (σ_L): variabilidad de demanda durante el plazo;
- (T): plazo.

La IA puede estimar dinámicamente:

- demanda;
- retraso;
- riesgo de proveedor;
- caducidad.

Valor

- menor capital inmovilizado;
- menos roturas;
- menor obsolescencia.

Control

Los ingredientes críticos deben tener políticas de resiliencia que no dependan únicamente del mínimo económico.

17.19. Caso de uso 17: scoring dinámico de proveedores

Variables

- calidad;

- puntualidad;
- desviaciones;
- precio;
- trazabilidad;
- sostenibilidad;
- riesgo geográfico.

Modelo

$$S_p = \sum_k w_k z_{pk}$$

o modelos no lineales.

Acción

- asignar volumen;
- aumentar controles;
- auditar;
- desarrollar alternativas.

Riesgo

El sistema puede penalizar a proveedores pequeños por menor densidad de datos.

La puntuación debe permitir revisión y explicación.

17.20. Caso de uso 18: optimización de transporte

Problema

La distribución debe equilibrar:

- coste;
- tiempo;
- ventanas;
- capacidad;
- bioseguridad.

Modelo

Problema de rutas:

$$\min \sum_{i,j} c_{ij} x_{ij}$$

sujeto a restricciones de:

- carga;
- tiempo;
- compatibilidad;

- limpieza.

Valor

- menos kilómetros;
- mejor puntualidad;
- menor huella.

Riesgo

La ruta más corta puede no ser la más segura desde la perspectiva sanitaria.

17.21. Caso de uso 19: alimentación de precisión en porcino

Problema

Los animales presentan variabilidad en:

- peso;
- crecimiento;
- consumo;
- requerimientos.

La alimentación por fases puede sobrealimentar a parte del grupo.

Sistema

Combina:

- peso;
- consumo;
- edad;
- curva;
- ambiente.

Acción

Mezclar dos o más dietas en proporción variable:

$$F_t = \lambda_t F_A + (1 - \lambda_t) F_B$$

Objetivo

- cubrir requerimiento;
- reducir nitrógeno;
- mantener crecimiento.

Métricas

- ganancia media;
- conversión;

- coste;
- nitrógeno excretado;
- uniformidad.

Riesgo

Una estimación incorrecta del requerimiento puede afectar crecimiento o salud.

17.22. Caso de uso 20: detección precoz de alteraciones en porcino

Datos

- consumo;
- agua;
- sonido;
- temperatura;
- actividad;
- imagen.

Salida

Puntuación de anomalía por corral.

Acción

- inspección;
- revisión del pienso;
- evaluación veterinaria.

Riesgo

La alerta es inespecífica.

Puede indicar:

- enfermedad;
- estrés térmico;
- avería;
- cambio de dieta;
- calidad de agua.

La IA debe orientar la inspección, no sustituirla.

17.23. Caso de uso 21: ajuste nutricional en avicultura

Datos

- peso;
- uniformidad;
- consumo;
- ambiente;

- mortalidad;
- calidad de cama.

Salida

Predicción de desviación respecto a curva.

Acción

- revisar densidad nutricional;
- manejo;
- temperatura;
- iluminación;
- agua.

Métrica

- peso;
- conversión;
- uniformidad;
- mortalidad;
- pododermatitis.

Riesgo

Una caída de crecimiento no debe atribuirse automáticamente a nutrición.

17.24. Caso de uso 22: visión artificial en pollos

La visión puede estimar:

- distribución;
- actividad;
- agrupamiento;
- peso;
- locomoción.

Aplicación nutricional

El patrón de distribución puede relacionarse con:

- acceso al alimento;
- confort;
- consumo;
- estrés.

Limitación

La densidad, iluminación, polvo y oclusión reducen la precisión.

17.25. Caso de uso 23: alimentación de precisión en ponedoras

Objetivos

- masa de huevo;
- calidad de cáscara;
- persistencia;
- eficiencia.

Datos

- edad;
- producción;
- peso de huevo;
- consumo;
- temperatura;
- calidad.

Acción

Ajustar:

- calcio;
- fósforo;
- aminoácidos;
- energía.

Riesgo

Los efectos sobre calidad de cáscara pueden aparecer con retraso.

El sistema debe evitar cambios excesivamente frecuentes.

17.26. Caso de uso 24: nutrición de precisión en vacuno lechero

Datos

- producción;
- composición de leche;
- consumo;
- rumia;
- actividad;
- condición;
- salud;
- clima.

Salida

Estimación de:

- balance energético;

- riesgo metabólico;
- requerimiento;
- respuesta marginal.

Acción

- ajustar ración;
- agrupar;
- suplementar;
- revisar manejo.

Objetivo

$$\max[V_{\text{leche}} C_{\text{ración}} C_{\text{riesgo}}]$$

Riesgo

La respuesta individual puede confundirse con:

- enfermedad;
- competencia;
- confort;
- error de medición.

17.27. Caso de uso 25: predicción de cetosis y balance energético

Datos

- leche;
- grasa/proteína;
- rumia;
- actividad;
- condición;
- partos;
- metabolitos.

Salida

Probabilidad de riesgo:

$$P(\text{cetosis} \mid X_t)$$

Acción

- evaluación;
- análisis;
- ajuste;
- seguimiento.

Control

La predicción no debe sustituir la confirmación clínica o analítica cuando esta sea necesaria.

17.28. Caso de uso 26: optimización del uso de forrajes

Problema

La composición del forraje cambia por:

- parcela;
- corte;
- conservación;
- frente de silo.

Datos

- NIRS;
- imagen;
- temperatura;
- estabilidad;
- producción.

Acción

Actualizar la ración y la estrategia de extracción.

Valor

- menor variabilidad;
- mejor utilización;
- reducción de desperdicio.

17.29. Caso de uso 27: predicción de consumo en rumiantes

El consumo de materia seca es una variable central y difícil de medir.

Puede estimarse:

$$\widehat{DMI}f(BW, MY, DIM, T, R, A)$$

donde:

- (BW): peso;
- (MY): producción;
- (DIM): días en leche;
- (T): temperatura;
- (R): rumia;
- (A): actividad.

La incertidumbre debe incorporarse en la formulación.

17.30. Caso de uso 28: mitigación de metano

Datos

- dieta;
- producción;
- consumo;
- genética;
- ambiente;
- mediciones.

Salida

Predicción de emisiones y respuesta a intervenciones.

Optimización

$$\min CH_4$$

sujeto a:

- producción;
- salud ruminal;
- coste;
- persistencia.

Riesgo

La reducción estimada debe validarse en condiciones reales y durante periodos suficientes.

17.31. Caso de uso 29: pastoreo de precisión

Datos

- satélite;
- dron;
- GPS;
- clima;
- vegetación;
- movimiento.

Salida

- biomasa;
- calidad;
- disponibilidad;
- consumo probable.

Acción

- rotación;

- suplementación;
- carga.

Limitaciones

- nubosidad;
- heterogeneidad;
- conectividad;
- coste.

17.32. Caso de uso 30: alimentación inteligente en acuicultura

Problema

La sobrealimentación incrementa:

- coste;
- residuos;
- deterioro del agua.

La subalimentación reduce crecimiento y uniformidad.

Datos

- visión;
- hidroacústica;
- oxígeno;
- temperatura;
- corriente;
- comportamiento.

Acción

Ajustar:

- dosis;
- frecuencia;
- velocidad;
- localización.

Política

$$u_t = \pi(B_t, A_t, O_t, T_t)$$

donde:

- (B_t): biomasa;
- (A_t): actividad;
- (O_t): oxígeno;
- (T_t): temperatura.

17.33. Caso de uso 31: estimación de biomasa en acuicultura

Técnicas

- visión estereoscópica;
- acústica;
- modelos de crecimiento;
- identificación.

Métrica

$$MAPE = \frac{100}{n} \sum_i \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Riesgo

La biomasa errónea afecta:

- dosis;
- tratamientos;
- planificación;
- densidad.

Debe existir calibración periódica.

17.34. Caso de uso 32: calidad del agua y alimentación

La relación entre alimentación y agua puede modelarse mediante:

- oxígeno;
- amonio;
- turbidez;
- temperatura;
- corriente.

La acción nutricional debe coordinarse con aireación, recambio y biomasa.

Un modelo aislado de alimentación puede optimizar consumo y empeorar el ambiente.

17.35. Caso de uso 33: nutrición en especies acuícolas de crecimiento desigual

La distribución de tamaños puede generar:

- competencia;
- canibalismo;
- alimentación desigual.

La visión puede estimar la distribución, no solo la media.

El objetivo puede ser:

$$\text{minVar}(W)$$

manteniendo crecimiento y eficiencia.

17.36. Caso de uso 34: nutrición personalizada en animales de compañía

Datos

- edad;
- raza;
- peso;
- actividad;
- condición;
- preferencias;
- historia.

Salida

Recomendación de:

- energía;
- ración;
- formato;
- seguimiento.

Riesgo

La personalización puede generar una falsa apariencia clínica.

Las recomendaciones para patologías deben mantenerse bajo supervisión veterinaria.

17.37. Caso de uso 35: prevención de obesidad en mascotas

Sistema

Integra:

- peso;
- actividad;
- consumo;
- premios;
- tendencia.

Salida

Predicción de evolución y recomendación calórica.

$$E_{t+1}E_t + I_t - G_t$$

Métrica

- condición corporal;
- adherencia;
- mantenimiento de masa magra.

Riesgo

La estimación de actividad mediante dispositivos puede ser incompleta o dependiente de raza.

17.38. Caso de uso 36: nutrición clínica veterinaria

Aplicaciones

- renal;
- urinaria;
- gastrointestinal;
- alergias;
- diabetes;
- recuperación.

Datos

- diagnóstico;
- analítica;
- peso;
- medicación;
- consumo.

Salida

Apoyo a la selección y ajuste dietético.

Control

El sistema debe operar como soporte clínico, con documentación y responsabilidad veterinaria.

17.39. Caso de uso 37: predicción de palatabilidad

Datos

- composición;
- aroma;
- textura;
- proceso;
- ensayos de preferencia.

Modelo

Predice:

- primera elección;
- consumo;

- rechazo;
- persistencia.

Limitación

La palatabilidad varía por:

- especie;
- edad;
- experiencia;
- ambiente;
- estado sanitario.

La predicción no sustituye pruebas de consumo.

17.40. Caso de uso 38: desarrollo inteligente de nuevos productos

Flujo

1. identificar necesidad;
2. analizar evidencia;
3. seleccionar ingredientes;
4. generar formulaciones;
5. simular;
6. priorizar;
7. ensayar.

Función objetivo

$$J = w_1 E_{\text{nutricional}} + w_2 C + w_3 R + w_4 H$$

donde:

- (C): coste;
- (R): riesgo;
- (H): huella.

Valor

Reduce el espacio experimental, pero no elimina la prueba física.

17.41. Caso de uso 39: cribado de ingredientes funcionales

La IA puede analizar:

- literatura;
- patentes;
- ensayos;
- mecanismos;
- seguridad.

Puede construir un grafo de evidencia y priorizar candidatos.

Riesgo

La cantidad de publicaciones no equivale a calidad ni reproducibilidad.

La evaluación debe ponderar:

- diseño;
- especie;
- dosis;
- consistencia;
- independencia.

17.42. Caso de uso 40: predicción de respuesta a aditivos

Problema

La respuesta puede variar por:

- dieta basal;
- microbiota;
- edad;
- ambiente;
- estado sanitario.

Modelo

$$\hat{\tau}_i \hat{Y}_i(1) \hat{Y}_i(0)$$

estima el efecto individual o por subgrupo.

Acción

Seleccionar animales o condiciones con mayor probabilidad de respuesta.

Riesgo

La heterogeneidad estimada puede ser inestable si existen pocos datos.

17.43. Caso de uso 41: recomendador técnico-comercial

Un sistema puede sugerir soluciones a partir de:

- especie;
- problema;
- fórmula;
- proceso;
- regulación;
- historial.

Valor

- rapidez;
- consistencia;
- soporte a ventas.

Riesgo

Debe evitar:

- claims no autorizados;
- dosis incorrectas;
- recomendaciones fuera de uso;
- sustitución del juicio técnico.

La salida debe vincularse a documentación vigente.

17.44. Caso de uso 42: vigilancia de reclamaciones

Datos

- texto;
- lote;
- cliente;
- producto;
- causa;
- análisis.

Modelo

- clasificación;
- agrupamiento;
- detección de tendencia.

Salida

- categoría;
- severidad;
- patrón emergente.

Valor

Detectar antes problemas de:

- calidad;
- transporte;
- formulación;
- proceso.

Riesgo

La clasificación automática no debe cerrar reclamaciones ni determinar responsabilidad sin revisión.

17.45. Caso de uso 43: farmacovigilancia y nutrivigilancia

Los sistemas pueden identificar señales en:

- incidencias;
- literatura;
- consultas;
- mortalidad;
- resultados.

Objetivo

Detectar patrones raros asociados a:

- aditivos;
- ingredientes;
- combinaciones;
- dosis.

Limitación

Una señal no prueba causalidad.

Debe iniciar investigación.

17.46. Caso de uso 44: gestión de antibióticos

La IA puede apoyar:

- detección precoz;
- estratificación;
- evaluación de respuesta;
- análisis de consumo.

La nutrición puede integrarse como medida de soporte.

Riesgo

El objetivo de reducir antibióticos no debe retrasar un tratamiento clínicamente necesario.

17.47. Caso de uso 45: optimización de proteína y nitrógeno

Objetivo

Reducir proteína bruta manteniendo aminoácidos digestibles y rendimiento.

$$\min N_{\text{excretado}}$$

sujeto a:

$$AA_j \geq R_j$$

Datos

- composición;
- digestibilidad;
- respuesta;
- consumo;
- excreción.

Valor

- coste;
- emisiones;
- salud intestinal.

Riesgo

Una reducción excesiva puede aumentar sensibilidad a error y variabilidad.

17.48. Caso de uso 46: optimización de fósforo

El sistema puede integrar:

- fósforo total;
- digestibilidad;
- fitasa;
- calcio;
- especie;
- fase.

Objetivo

$$\min P_{\text{excretado}}$$

manteniendo disponibilidad y salud ósea.

Riesgo

La matriz de enzimas debe validarse para condiciones reales de proceso y dieta.

17.49. Caso de uso 47: formulación ambiental multicriterio

Función

$$\min_x [C(x), GHG(x), N(x), P(x), L(x)]$$

donde:

- (GHG): gases;
- (N): nitrógeno;

- (P): fósforo;
- (L): uso de suelo.

Salida

Frente de Pareto.

Acción

Seleccionar una solución según prioridades y restricciones.

Riesgo

Un único índice puede ocultar desplazamiento de impactos.

17.50. Caso de uso 48: cálculo dinámico de huella por lote

Datos

- origen;
- transporte;
- producción;
- energía;
- formulación.

Salida

Huella estimada del lote.

Valor

- comparación;
- compra;
- reporting;
- formulación.

Control

Debe conservarse:

- metodología;
- factores;
- incertidumbre;
- fecha.

La precisión numérica no debe exceder la calidad de los datos.

17.51. Caso de uso 49: predicción de vida útil de piensos

Variables

- humedad;
- actividad de agua;
- grasa;
- antioxidantes;
- temperatura;
- envase;
- tiempo.

Salida

Probabilidad de:

- rancidez;
- crecimiento;
- pérdida vitamínica;
- rechazo.

Acción

- ajustar fecha;
- almacenamiento;
- formulación;
- distribución.

Riesgo

La vida útil debe validarse mediante estudios reales y no únicamente por predicción.

17.52. Caso de uso 50: optimización de antioxidantes

Objetivo

Determinar la mínima estrategia eficaz según:

- grasa;
- metales;
- proceso;
- almacenamiento;
- envase.

Modelo

$$D^* \arg\min_D C(D)$$

sujeto a:

$$P(Ox(T) > L) < \alpha$$

Riesgo

La respuesta puede variar por matriz y condiciones.

17.53. Caso de uso 51: control de estabilidad vitamínica

La IA puede estimar pérdidas por:

- temperatura;
- humedad;
- almacenamiento;
- interacción;
- tiempo.

Acción

Ajustar sobredosificación.

Valor

- menor coste;
- mejor cumplimiento.

Riesgo

Reducir márgenes sobre la base de modelos insuficientemente validados puede producir deficiencias.

17.54. Caso de uso 52: prevención de apelmazamiento

Datos

- humedad;
- granulometría;
- temperatura;
- tiempo;
- presión;
- composición.

Salida

Riesgo de:

- caking;
- puente;
- mala descarga.

Acción

Ajustar:

- anticomcompactante;
- almacenamiento;
- secuencia;
- humedad.

17.55. Caso de uso 53: optimización de aglutinantes y calidad física

La IA puede relacionar:

- fórmula;
- proceso;
- aglutinante;
- PDI;
- finos;
- dureza.

Objetivo

Obtener la calidad física necesaria con mínimo coste y consumo energético.

17.56. Caso de uso 54: diagnóstico integrado de baja productividad

Problema

Una caída productiva puede tener múltiples causas.

Datos

- alimento;
- animal;
- agua;
- ambiente;
- salud;
- manejo.

Modelo

Puede generar una lista priorizada de hipótesis.

Salida

No debe ser:

La causa es nutricional.

Debe expresar:

- hipótesis;
- evidencia;
- contradicciones;
- datos faltantes;
- pruebas sugeridas.

17.57. Caso de uso 55: soporte a auditorías

La IA puede:

- seleccionar registros;
- detectar inconsistencias;
- reconstruir decisiones;
- comparar procedimientos.

Valor

- rapidez;
- cobertura;
- preparación.

Riesgo

La auditoría debe conservar criterio, independencia y materialidad.

17.58. Caso de uso 56: trazabilidad decisional

Objetivo

Reconstruir:

- dato;
- modelo;
- versión;
- recomendación;
- aprobación;
- acción.

Aplicación

- retirada;
- reclamación;
- litigio;
- auditoría;
- mejora.

La trazabilidad decisional debe integrarse desde el diseño.

17.59. Caso de uso 57: predicción de retiradas y crisis

El sistema puede combinar:

- reclamaciones;
- laboratorio;
- proveedores;
- logística;
- anomalías.

Salida

Puntuación de escalado.

Riesgo

No debe generar comunicación pública o retirada automática sin una estructura de decisión definida.

17.60. Caso de uso 58: simulación de retiradas

Un gemelo de trazabilidad puede simular:

- lotes afectados;
- clientes;
- tiempo;
- volumen;
- coste.

Métricas

- tiempo de identificación;
- precisión;
- sobrealcance;
- unidades localizadas.

17.61. Caso de uso 59: optimización energética de fábrica

Datos

- consumo;
- producción;
- equipo;
- tarifa;
- temperatura;
- receta.

Acción

- secuenciar;
- ajustar carga;
- evitar picos;
- detectar ineficiencias.

Métrica

$$E_s = \frac{\text{kWh}}{t}$$

Debe vigilarse simultáneamente la calidad.

17.62. Caso de uso 60: mantenimiento de calidad durante ahorro energético

La optimización energética debe estar sujeta a:

$$Q_j \geq Q_{j,\min}$$

para:

- cocción;
- homogeneidad;
- PDI;
- seguridad.

La energía no puede reducirse a costa de controles esenciales.

17.63. Caso de uso 61: predicción de riesgo de proveedor por clima y geopolítica

Datos

- meteorología;
- producción;
- rutas;
- conflictos;
- precios;
- dependencia.

Salida

Probabilidad de interrupción:

$$P(TTS < TTR)$$

Acción

- diversificar;
- comprar;
- reformular;
- aumentar stock.

Riesgo

Las señales geopolíticas contienen alta incertidumbre.

El sistema debe ofrecer escenarios, no certezas.

17.64. Caso de uso 62: análisis de precios de materias primas

Los modelos pueden estimar tendencias de:

- cereales;
- proteínas;
- grasas;
- aminoácidos;
- energía.

Acción

- cobertura;
- compra;
- formulación.

Limitación

Los mercados sufren eventos estructurales no presentes en históricos.

La predicción debe acompañarse de escenarios y límites de exposición.

17.65. Caso de uso 63: formulación condicionada por contratos

Una empresa puede integrar:

- inventario;
- coberturas;
- mínimos de compra;
- restricciones nutricionales.

Objetivo

$$\min C_{\text{total}} C_{\text{ingrediente}} + C_{\text{contrato}} + C_{\text{inventario}} + C_{\text{riesgo}}$$

Esto conecta formulación y compras.

17.66. Caso de uso 64: personalización de servicios a explotaciones

El fabricante puede proporcionar:

- benchmarking;
- alertas;
- recomendaciones;
- predicción de consumo.

Modelo de negocio

- suscripción;
- servicio incluido;
- pago por resultado;
- plataforma.

Riesgo

Debe definirse quién responde por la decisión final y qué datos puede reutilizar el proveedor.

17.67. Caso de uso 65: contratos por rendimiento

La remuneración puede vincularse a:

- conversión;
- crecimiento;

- mortalidad;
- ahorro.

Dificultad

El resultado depende también de:

- manejo;
- genética;
- salud;
- ambiente.

La atribución debe modelarse contractualmente.

17.68. Caso de uso 66: benchmarking entre explotaciones

Objetivo

Comparar rendimientos ajustando por:

- especie;
- genética;
- fase;
- clima;
- sistema.

Riesgo

Un ranking bruto puede ser injusto y conducir a conclusiones erróneas.

Debe utilizarse ajuste de riesgo.

17.69. Caso de uso 67: detección de granjas atípicas

La detección de anomalías puede identificar:

- mejora excepcional;
- deterioro;
- problema de datos;
- riesgo sanitario.

Acción

- investigar;
- compartir prácticas;
- intervenir.

La anomalía no debe interpretarse automáticamente como incumplimiento.

17.70. Caso de uso 68: segmentación de clientes por necesidad técnica

La segmentación puede basarse en:

- especie;
- problema;
- madurez;
- consumo;
- historial.

Valor

- soporte dirigido;
- desarrollo comercial;
- priorización.

Riesgo

La segmentación comercial no debe producir discriminación injustificada ni uso opaco de datos.

17.71. Caso de uso 69: asistente de formulación para pymes

Una plataforma compartida puede ofrecer:

- cálculo;
- restricciones;
- alertas;
- documentación.

Valor

Democratiza capacidades.

Riesgo

Las empresas pequeñas pueden confiar excesivamente en una herramienta que no conoce su proceso real.

Debe ofrecer límites claros y soporte experto.

17.72. Caso de uso 70: laboratorio inteligente

Aplicaciones

- priorización de muestras;
- detección de anomalías;
- mantenimiento;
- revisión de resultados;
- estimación de incertidumbre.

Control

Los resultados analíticos deben conservar trazabilidad metrológica y validación del método.

17.73. Caso de uso 71: selección automática de método analítico

El sistema puede recomendar un método según:

- matriz;
- analito;
- límite;
- urgencia;
- coste.

Riesgo

La selección debe respetar métodos oficiales, acreditados o validados según finalidad.

17.74. Caso de uso 72: revisión de certificados analíticos

Los modelos de lenguaje pueden extraer:

- lote;
- parámetro;
- resultado;
- unidad;
- método;
- conformidad.

Valor

- rapidez;
- reducción de transcripción.

Control

Debe verificarse:

- identidad;
- decimal;
- unidad;
- límite;
- firma.

17.75. Caso de uso 73: generación de etiquetado y documentación

La IA puede generar borradores de:

- etiquetas;
- especificaciones;
- fichas;
- certificados.

Riesgo

Debe comprobarse:

- composición;
- mercado;
- especie;
- claims;
- versión normativa.

La generación automática no debe publicar directamente contenido sin revisión.

17.76. Caso de uso 74: vigilancia regulatoria

El sistema puede monitorizar:

- nuevas normas;
- autorizaciones;
- límites;
- guías.

Acción

Identificar:

- productos afectados;
- fórmulas;
- mercados;
- acciones.

Control

La interpretación jurídica final debe ser validada por personal competente.

17.77. Caso de uso 75: predicción de riesgo de no conformidad

Datos

- proveedor;
- lote;
- proceso;
- operario;
- equipo;
- historial.

Salida

$$P(NC = 1 | X)$$

Acción

- muestreo;
- inspección;
- revisión;
- bloqueo preventivo.

Riesgo

El modelo no debe utilizar variables que actúen como proxies injustificados de determinadas personas o proveedores.

17.78. Caso de uso 76: copiloto de investigación y desarrollo

Puede apoyar:

- búsqueda;
- síntesis;
- diseño experimental;
- cálculos;
- documentación.

Riesgo

- referencias falsas;
- omisión de estudios;
- simplificación;
- filtración.

La revisión científica sigue siendo imprescindible.

17.79. Caso de uso 77: diseño de experimentos

La IA puede seleccionar combinaciones de:

- dosis;
- ingredientes;
- proceso.

Puede utilizar optimización bayesiana:

$$x_{t+1} \operatorname{argmax}_x a(x \mid D_t)$$

Valor

Reduce el número de ensayos.

Riesgo

La función de adquisición debe respetar límites éticos y de seguridad.

17.80. Caso de uso 78: análisis causal de ensayos

Los modelos pueden estimar:

- efecto medio;
- heterogeneidad;
- mediadores;
- interacciones.

Requisito

El diseño experimental debe seguir siendo adecuado.

Un algoritmo complejo no corrige aleatorización deficiente ni ausencia de control.

17.81. Caso de uso 79: metaanálisis asistido

La IA puede:

- identificar estudios;
- extraer datos;
- clasificar evidencia;
- detectar heterogeneidad.

Riesgo

La selección y evaluación de calidad requieren revisión humana.

La automatización puede reproducir sesgos de publicación y bases de datos.

17.82. Caso de uso 80: generador de hipótesis

Los grafos de conocimiento pueden sugerir relaciones entre:

- ingrediente;
- vía;
- metabolito;
- efecto.

La salida debe considerarse:

- hipótesis;
- no evidencia;
- no claim;
- no recomendación inmediata.

17.83. Evaluación comparada de casos de uso

Tabla 38. Síntesis de caso, valor, datos, actuación, riesgo y madurez.

Caso	Valor	Datos	Actuación	Riesgo	Madurez
NIRS por lote	Alto	Alto	Alta	Medio	Alta
Mantenimiento predictivo	Alto	Medio	Alta	Medio	Alta
Formulación robusta	Alto	Alto	Alta	Alto	Media-alta
Alimentación acuícola	Alto	Alto	Muy alta	Alto	Media-alta
Microbiota personalizada	Potencial alto	Bajo-medio	Media	Alto	Baja
Modelos generativos	Medio	Variable	Media	Medio-alto	Media
Gemelo de explotación	Alto	Alto	Alta	Alto	Media
Descubrimiento de aditivos	Alto	Alto	Baja inmediata	Medio	Media
Trazabilidad decisional	Alto	Medio	Indirecta	Medio	Alta
Nutrición clínica digital	Alto	Alto	Alta	Muy alto	Media

17.84. Selección por horizonte de decisión

Tiempo real

- dosificación;
- alimentación;
- control de proceso;
- seguridad de equipo.

Diario

- ajuste de dieta;
- salud;
- inventario;
- producción.

Semanal

- formulación;
- compras;
- planificación;
- seguimiento.

Estratégico

- proveedores;
- capacidad;
- sostenibilidad;
- nuevos productos.

La arquitectura debe corresponder al horizonte.

17.85. Selección por unidad de intervención

Ingrediente

- valoración;
- riesgo;
- compra.

Fórmula

- optimización;
- robustez;
- sostenibilidad.

Lote

- proceso;
- calidad;
- liberación.

Animal

- nutrición;
- salud;
- comportamiento.

Explotación

- manejo;
- recursos;
- economía.

Cadena

- trazabilidad;
- logística;
- resiliencia.

17.86. Selección por nivel de autonomía

Informativo

Muestra datos.

Predictivo

Anticipa.

Prescriptivo

Recomienda.

Ejecutivo supervisado

Actúa tras aprobación.

Autónomo limitado

Actúa dentro de límites.

La mayoría de las organizaciones debería progresar de forma escalonada.

17.87. Combinación de casos

El valor aumenta cuando varios casos se conectan.

Ejemplo:

NIRS → matriz dinámica → formulación → producción → respuesta

Pero la integración aumenta el riesgo de propagación.

Debe existir monitorización en cada interfaz.

17.88. Caso integrado de fábrica inteligente

Una arquitectura completa puede incluir:

1. predicción de materias;
2. formulación robusta;
3. secuenciación;
4. control de molienda;
5. mezclado adaptativo;
6. peletización;
7. liberación;
8. logística.

El objetivo global puede expresarse:

$$\min J = C + E + Q_d + R$$

donde:

- (C): coste;
- (E): energía;
- (Q_d): desviación de calidad;
- (R): riesgo.

17.89. Caso integrado de explotación inteligente

Puede conectar:

- consumo;

- ambiente;
- comportamiento;
- salud;
- producción;
- dieta.

La decisión debe distinguir entre causas nutricionales y no nutricionales.

Un sistema integrado no debe transformar toda desviación en una modificación de alimento.

17.90. Caso integrado de cadena sostenible

Puede combinar:

- origen;
- huella;
- precio;
- riesgo;
- formulación;
- emisiones.

La decisión debe mostrar el frente de compromisos.

No debería producir una puntuación única opaca.

17.91. Arquitectura mínima para casos de bajo riesgo

Puede incluir:

- datos controlados;
- modelo;
- revisión;
- registro;
- responsable.

No requiere necesariamente integración en tiempo real.

17.92. Arquitectura para casos críticos

Debe incluir:

- validación independiente;
- calidad de datos en línea;
- detector fuera de dominio;
- límites duros;
- supervisión;
- logging;
- contingencia;
- revisión de incidentes.

17.93. Prueba de aptitud del caso

Antes de implantar debe verificarse:

$$Aptitud = Problema \times Datos \times Acción \times Control$$

Si uno de los factores es prácticamente cero, la aptitud global también lo será.

17.94. Antipatrones sectoriales

Formular sin datos de consumo

Se optimiza una dieta sin conocer exposición real.

Diagnosticar con una sola señal

Se atribuye causalidad a un patrón inespecífico.

Automatizar antes de estabilizar

Se aplica IA a equipos o procesos con variabilidad no controlada.

Optimizar una métrica aislada

Se mejora conversión deteriorando salud, calidad o bienestar.

Personalizar sin capacidad logística

Se generan recomendaciones que no pueden fabricarse o distribuirse.

Sustituir análisis por predicción

Se utiliza el modelo fuera de su función de cribado o apoyo.

17.95. Métricas transversales

Todo caso debería considerar:

Técnica

- error;
- calibración;
- robustez.

Operativa

- tiempo;
- disponibilidad;
- actuación.

Económica

- ahorro;
- coste;
- retorno.

Sanitaria

- incidentes;
- salud;
- seguridad.

Humana

- adopción;
- carga;
- override.

Ambiental

- recursos;
- emisiones;
- residuos.

17.96. Condiciones para escalar un caso sectorial

1. Desempeño estable.
2. Datos sostenibles.
3. Acción integrada.
4. Usuarios competentes.
5. Riesgo residual aceptado.
6. Beneficio verificado.
7. Transferencia validada.
8. Soporte disponible.
9. Contingencia probada.
10. Documentación completa.

17.97. Caso no escalable

Un caso puede producir beneficio local y no ser escalable por:

- dependencia de experto;
- sensores específicos;
- proceso único;
- datos no estandarizados;
- coste marginal alto.

Esto no invalida su valor local.

La estrategia debe diferenciar entre soluciones corporativas y soluciones especializadas.

17.98. Criterio de simplicidad sectorial

La solución debe compararse con:

- regla;
- checklist;
- sensor;
- procedimiento;
- formación.

La IA se justifica cuando añade capacidad relevante.

No cuando sustituye una regla simple con un sistema más difícil de mantener.

17.99. Principios para seleccionar casos de uso

1. Elegir problemas cuantificados.
2. Priorizar decisiones con actuación posible.
3. Exigir una línea basal.
4. Validar por especie, proceso y contexto.
5. Mantener límites independientes.
6. Medir efectos no deseados.
7. No confundir predicción con diagnóstico.
8. Escalar solamente tras demostrar transferencia.
9. Preservar la capacidad profesional.
10. Retirar los casos que dejen de generar valor.

17.100. Conclusión: el valor sectorial surge de conectar la predicción con una intervención técnicamente defendible

La inteligencia artificial puede aplicarse prácticamente a todos los eslabones de la nutrición animal: materias primas, formulación, fábrica, explotación, salud, logística, sostenibilidad, investigación y servicio técnico. Esta amplitud no significa que todas las aplicaciones tengan el mismo valor ni que deban implantarse simultáneamente.

El caso de uso correcto no es necesariamente el más innovador. Es aquel en el que existe una correspondencia clara entre:

- un problema relevante;
- datos suficientes;
- una predicción útil;
- una acción viable;
- un resultado medible;
- un riesgo controlable.

La existencia de datos abundantes no garantiza valor. Tampoco lo garantiza una elevada precisión. El elemento decisivo es la capacidad para transformar la salida del modelo en una intervención adecuada.

En producción animal, esta transformación exige prudencia porque las variables están profundamente interconectadas. Una caída de consumo puede ser nutricional, sanitaria, ambiental, tecnológica o conductual.

Una mejora de conversión puede ocultar efectos sobre bienestar, uniformidad o calidad. Una reducción de coste puede aumentar exposición a variabilidad.

Los sistemas sectoriales más robustos serán aquellos que mantengan abiertas varias hipótesis, expresen incertidumbre y eviten reducir fenómenos biológicos complejos a una única señal.

La inteligencia artificial debe utilizarse de forma diferente según el horizonte de decisión. En control industrial puede actuar en segundos. En nutrición adaptativa debe respetar retardos biológicos. En investigación puede generar hipótesis, pero necesita ensayos. En regulación puede localizar cambios, pero no sustituir la interpretación jurídica.

Los casos con mayor grado de autonomía requieren una arquitectura de control proporcionalmente más fuerte. La alimentación automática, la dosificación, la reformulación y la liberación de producto no deben depender de un único modelo sin barreras, trazabilidad y capacidad de intervención humana.

La integración de casos puede generar un valor superior al de cada aplicación aislada. Una materia prima caracterizada por lote puede alimentar una formulación robusta, que a su vez ajuste el proceso y permita relacionar la dieta real con la respuesta animal. Esta integración constituye uno de los principales horizontes del sector.

Sin embargo, también crea cadenas de dependencia. Un error inicial puede propagarse por toda la arquitectura. Por ello, cada interfaz debe conservar controles y expresar incertidumbre.

La selección disciplinada de casos de uso permite evitar dos errores frecuentes: implantar tecnologías complejas donde una regla sencilla sería suficiente y utilizar sistemas insuficientemente validados en decisiones de alta consecuencia.

La ventaja competitiva no procederá de afirmar que toda la cadena utiliza inteligencia artificial. Procederá de identificar los puntos exactos en los que una mejor decisión produce un efecto material y construir, alrededor de esos puntos, una arquitectura que combine ciencia, datos, proceso y responsabilidad.

En definitiva, la aplicación sectorial madura no busca automatizar todo aquello que pueda automatizarse. Busca intervenir únicamente allí donde la inteligencia artificial aporte una mejora verificable frente a las alternativas disponibles, sin debilitar la seguridad, el bienestar, la calidad ni la capacidad humana para comprender y gobernar el sistema.

18. Validación científica de los sistemas de inteligencia artificial en nutrición animal: evidencia, reproducibilidad y demostración de valor

18.1. Introducción

El éxito de un sistema de inteligencia artificial no puede medirse únicamente por su precisión matemática. Un algoritmo capaz de alcanzar una exactitud del 99 % en un conjunto de datos históricos puede fracasar completamente cuando se incorpora a un proceso industrial real si no demuestra robustez, reproducibilidad, estabilidad temporal y utilidad operativa.

En nutrición animal, esta exigencia resulta especialmente intensa porque las decisiones derivadas de un sistema inteligente pueden afectar simultáneamente a la salud y bienestar de los animales, al rendimiento zootécnico, a la seguridad de los alimentos destinados al consumo humano, al cumplimiento normativo y a la rentabilidad económica de la explotación o de la industria fabricante de piensos.

Por ello, la validación debe entenderse como un proceso científico continuo y no como un único ensayo realizado antes de la puesta en producción.

La pregunta relevante deja de ser:

«¿Funciona el algoritmo?»

para transformarse en otra mucho más exigente:

«¿Existe evidencia suficiente para confiar en este sistema dentro del contexto concreto en el que va a utilizarse?»

Esta diferencia es fundamental.

Un algoritmo nunca es válido en términos absolutos.

Es válido únicamente para:

- una población determinada;
- unas materias primas concretas;
- un rango de funcionamiento definido;
- unas condiciones ambientales específicas;
- una arquitectura de datos conocida;
- unas decisiones previamente delimitadas.

Fuera de ese dominio, toda extrapolación debe considerarse una hipótesis pendiente de validación.

18.2. Concepto de evidencia científica aplicada a la inteligencia artificial

La evidencia científica de un sistema inteligente puede definirse como el grado de confianza objetivamente demostrable de que dicho sistema produce decisiones mejores que las alternativas disponibles bajo unas condiciones previamente especificadas.

Esta definición incorpora varios elementos esenciales.

La comparación siempre debe realizarse frente a una referencia.

Dicha referencia puede consistir en:

- la práctica habitual;
- un procedimiento estadístico clásico;
- un experto humano;
- otro algoritmo;
- un sistema híbrido.

Del mismo modo, la mejora debe demostrarse mediante indicadores previamente establecidos y no mediante observaciones retrospectivas seleccionadas después del análisis.

18.3. Niveles de validación

La validación puede estructurarse en diferentes niveles.

Nivel I. Validación técnica

Comprueba que el algoritmo funciona desde el punto de vista matemático.

Incluye:

- precisión;
- sensibilidad;
- especificidad;
- error medio;
- estabilidad.

Todavía no demuestra utilidad industrial.

Nivel II. Validación operacional

Evalúa si el algoritmo continúa funcionando cuando se integra en el proceso productivo.

Se analizan:

- tiempos;
- latencia;
- disponibilidad;
- interoperabilidad;
- robustez.

Nivel III. Validación biológica

Determina si la intervención derivada del algoritmo mejora realmente la respuesta animal.

Debe medirse mediante variables objetivas como:

- índice de conversión;
- ganancia media diaria;
- producción;
- digestibilidad;
- mortalidad;
- bienestar.

Nivel IV. Validación económica

Calcula el beneficio económico atribuible al sistema.

Debe incorporar:

- inversión;
- mantenimiento;
- costes ocultos;
- ahorro;
- productividad;
- reducción del riesgo.

Nivel V. Validación regulatoria

Comprueba que el sistema cumple las obligaciones legales y documentales aplicables.

18.4. Reproducibilidad

Un resultado aislado carece de suficiente valor científico.

La reproducibilidad exige obtener conclusiones similares cuando el estudio se repite en condiciones comparables.

Debe distinguirse entre:

- repetibilidad;
- reproducibilidad;
- transferibilidad.

La repetibilidad implica repetir exactamente el mismo procedimiento.

La reproducibilidad incorpora variaciones razonables de operadores, instalaciones o momentos temporales.

La transferibilidad evalúa si el modelo continúa siendo útil cuando cambia parcialmente el contexto de utilización.

18.5. Robustez

Un sistema robusto mantiene un comportamiento aceptable frente a perturbaciones previsibles.

Estas perturbaciones incluyen:

- ruido experimental;
- cambios moderados en las materias primas;
- pequeñas desviaciones analíticas;
- errores instrumentales;
- modificaciones ambientales.

La robustez puede expresarse como:

$$R = \frac{P_{\text{perturbado}}}{P_{\text{óptimo}}}$$

donde (P) representa el rendimiento del modelo.

Cuanto más próximo sea (R) a uno, mayor robustez presenta el sistema.

18.6. Generalización

Uno de los errores más frecuentes consiste en confundir aprendizaje con memorización.

Un modelo correctamente entrenado debe generalizar.

Es decir, debe responder adecuadamente frente a datos nunca observados durante el entrenamiento.

La generalización constituye probablemente el verdadero objetivo de cualquier sistema de inteligencia artificial industrial.

18.7. Diseño experimental para validar IA

Los ensayos deben incorporar, siempre que resulte posible:

- grupo control;
- grupo intervención;
- asignación objetiva;
- criterios de inclusión;
- criterios de exclusión;
- variables primarias;
- variables secundarias;
- análisis estadístico predefinido.

La inteligencia artificial no elimina la necesidad de un diseño experimental riguroso.

Por el contrario, aumenta su importancia.

18.8. Variables de resultado

En nutrición animal, las principales variables pueden agruparse en cinco categorías:

Productivas

- crecimiento;
- conversión;
- producción;
- uniformidad.

Sanitarias

- incidencia de enfermedad;
- mortalidad;
- morbilidad;
- parámetros clínicos.

Nutricionales

- digestibilidad;
- consumo;
- utilización de nutrientes.

Ambientales

- emisiones;
- excreción de nitrógeno;
- fósforo;
- eficiencia energética.

Económicas

- margen;
- coste por tonelada;
- retorno de inversión;
- reducción de pérdidas.

18.9. Estudios multicéntricos

La validación adquiere mayor solidez cuando se realiza en:

- diferentes países;
- diferentes explotaciones;
- distintos fabricantes;

- campañas sucesivas;
- diversas especies.

Los estudios multicéntricos permiten estimar la variabilidad real del comportamiento del algoritmo.

18.10. Evidencia longitudinal

Los algoritmos deben evaluarse durante periodos suficientemente largos para detectar:

- deriva;
- adaptación;
- cambios de comportamiento;
- degradación del rendimiento.

Una excelente actuación durante unas pocas semanas puede ocultar problemas importantes a medio plazo.

18.11. Indicadores de retorno

La demostración del valor empresarial debe apoyarse en indicadores verificables.

Entre ellos:

- reducción del coste de formulación;
- disminución del consumo energético;
- reducción de reclamaciones;
- incremento de productividad;
- disminución del desperdicio;
- mejora del bienestar;
- reducción de emisiones;
- incremento del margen bruto.

Cada indicador debe vincularse a un periodo de observación claramente definido.

18.12. Limitaciones de la evidencia

Toda validación posee límites.

Entre los más frecuentes destacan:

- tamaño insuficiente de muestra;
- sesgo de selección;
- sobreajuste;
- cambios de contexto;
- calidad insuficiente de los datos;
- variables de confusión;

- dependencia de un único proveedor tecnológico.

Reconocer estas limitaciones no debilita la evidencia.

La fortalece.

18.13. Cultura de validación continua

La validación no finaliza cuando el sistema entra en producción.

Debe mantenerse mediante:

- monitorización continua;
- auditorías periódicas;
- reevaluaciones;
- análisis de incidentes;
- recalibraciones;
- estudios posteriores a la implantación.

La inteligencia artificial debe considerarse un sistema vivo cuya evidencia evoluciona con el tiempo.

18.14. Conclusión

La diferencia entre una demostración tecnológica y una innovación científicamente consolidada reside en la calidad de la evidencia que la respalda.

En nutrición animal, donde convergen biología, ingeniería, economía y regulación, la validación debe extenderse mucho más allá de la precisión algorítmica. Debe demostrar que el sistema mejora decisiones reales, mantiene su comportamiento a lo largo del tiempo, resiste condiciones variables, puede auditarse y genera un beneficio verificable sin comprometer la seguridad, el bienestar animal ni el cumplimiento normativo.

La inteligencia artificial solo alcanzará una implantación industrial madura cuando la comunidad científica, los fabricantes de piensos, los nutricionistas, los veterinarios, los reguladores y las empresas tecnológicas compartan un mismo principio: toda decisión automatizada debe apoyarse en una evidencia al menos tan sólida como la que exigiríamos a cualquier otra innovación nutricional.

Desde esta perspectiva, la validación deja de ser la última etapa del desarrollo y pasa a convertirse en el mecanismo permanente que sostiene la confianza, la reproducibilidad y la legitimidad científica de la inteligencia artificial aplicada a la nutrición animal.

19. Estandarización metodológica de la inteligencia artificial en nutrición animal: criterios científicos para el diseño, evaluación y comunicación de sistemas inteligentes

19.1. Introducción

Toda disciplina científica alcanza su madurez cuando deja de depender exclusivamente de la capacidad individual de investigadores o desarrolladores y comienza a apoyarse en metodologías reproducibles, criterios homogéneos de evaluación y estándares aceptados por la comunidad científica e industrial.

La inteligencia artificial aplicada a la nutrición animal todavía se encuentra en una fase de expansión tecnológica caracterizada por una extraordinaria diversidad metodológica. Modelos entrenados con conjuntos de datos heterogéneos, métricas distintas, protocolos de validación incompatibles y descripciones incompletas dificultan la comparación objetiva entre estudios y limitan la transferencia efectiva del conocimiento hacia la industria.

Mientras que disciplinas consolidadas, como la química analítica, la microbiología o la nutrición experimental, disponen desde hace décadas de normas internacionales para el diseño de estudios, la validación de métodos o la comunicación de resultados, la inteligencia artificial carece todavía de un marco específico adaptado a las particularidades de la nutrición animal.

La ausencia de estándares genera tres consecuencias principales.

La primera consiste en la dificultad para reproducir los resultados publicados.

La segunda impide comparar de forma rigurosa modelos desarrollados por grupos diferentes.

La tercera obstaculiza la incorporación de estas herramientas a los sistemas de calidad, a los procesos regulatorios y a la práctica industrial cotidiana.

La consolidación de esta disciplina exige avanzar desde la innovación aislada hacia una ciencia metodológicamente estructurada.

19.2. La necesidad de un lenguaje común

Una parte importante de la literatura científica utiliza términos como *modelo inteligente*, *predicción avanzada*, *algoritmo optimizado* o *sistema experto* sin definir con precisión su significado operativo.

La estandarización comienza necesariamente por la terminología.

Cada publicación debería especificar, como mínimo:

- finalidad exacta del modelo;
- población objetivo;
- variables de entrada;
- variables de salida;
- horizonte temporal de predicción;
- contexto operativo;

- restricciones de utilización.

La ausencia de estas definiciones impide interpretar correctamente los resultados y favorece comparaciones inapropiadas entre sistemas diseñados para objetivos completamente distintos.

19.3. Clasificación funcional de los modelos

Desde un punto de vista metodológico resulta útil distinguir cinco grandes categorías funcionales:

1. Modelos descriptivos.
2. Modelos diagnósticos.
3. Modelos predictivos.
4. Modelos prescriptivos.
5. Modelos autónomos de decisión.

Cada categoría implica requisitos diferentes de validación, documentación y supervisión.

La comparación entre modelos pertenecientes a categorías distintas carece, por tanto, de significado científico.

19.4. Documentación mínima de un sistema inteligente

Todo trabajo científico debería describir de manera explícita:

- objetivo del sistema;
- justificación biológica;
- origen de los datos;
- periodo temporal cubierto;
- tamaño muestral;
- criterios de inclusión y exclusión;
- preprocesamiento aplicado;
- arquitectura del modelo;
- procedimiento de entrenamiento;
- estrategia de validación;
- métricas utilizadas;
- limitaciones conocidas.

La reproducibilidad comienza con una documentación suficientemente detallada.

19.5. Calidad metodológica de los datos

La calidad del modelo nunca puede superar la calidad de los datos empleados durante su desarrollo.

Por ello, los estudios deberían informar sistemáticamente sobre:

- completitud;
- exactitud;
- consistencia;
- representatividad;
- trazabilidad;
- frecuencia de actualización.

Asimismo, deberían describirse las estrategias utilizadas para gestionar:

- valores perdidos;
- valores atípicos;
- ruido experimental;
- sesgos de selección.

19.6. Diseño de conjuntos de entrenamiento y validación

La división de los datos constituye uno de los elementos metodológicos más críticos.

Debería especificarse claramente:

- procedimiento de partición;
- proporción utilizada;
- independencia temporal;
- independencia geográfica;
- independencia biológica.

La utilización inadvertida de información futura durante el entrenamiento constituye una de las fuentes más frecuentes de sobreestimación del rendimiento.

19.7. Métricas estandarizadas

La comparación objetiva entre estudios exige utilizar métricas ampliamente aceptadas.

Entre ellas:

- MAE;
- RMSE;
- MAPE;
- sensibilidad;
- especificidad;
- precisión;
- F1;
- AUC;
- calibración;
- Brier Score.

La selección debe justificarse en función del problema concreto.

No existe una métrica universalmente superior.

19.8. Validación externa

La validación interna resulta necesaria, pero insuficiente.

La verdadera robustez solo puede demostrarse mediante validaciones independientes realizadas:

- en otras explotaciones;
- con otras materias primas;

- en campañas diferentes;
- en otros países;
- por grupos investigadores distintos.

La evidencia externa constituye el principal indicador de generalización.

19.9. Evaluación del impacto

La evaluación metodológica debe extenderse más allá del rendimiento matemático.

Cada sistema debería cuantificar su impacto sobre:

- productividad;
- bienestar animal;
- seguridad alimentaria;
- sostenibilidad;
- rentabilidad económica;
- consumo de recursos.

Un algoritmo extremadamente preciso puede carecer de interés industrial si no modifica ninguna decisión relevante.

19.10. Transparencia y reproducibilidad

Las publicaciones deberían describir con suficiente detalle:

- versiones del software;
- parámetros del entrenamiento;
- arquitectura empleada;
- hardware utilizado;
- dependencias críticas;
- limitaciones.

Siempre que sea posible deberían facilitarse:

- conjuntos de datos anonimizados;
- scripts de entrenamiento;
- modelos reproducibles;
- documentación técnica.

Cuando existan restricciones comerciales o de propiedad intelectual, al menos deberían describirse los procedimientos empleados para permitir la evaluación independiente.

19.11. Control de sesgos

La metodología debe incorporar procedimientos específicos para detectar:

- sesgos de selección;
- sesgos geográficos;
- sesgos temporales;
- sesgos derivados de la especie;

- sesgos asociados al proveedor de datos.

La identificación temprana de estos fenómenos resulta esencial para garantizar la validez científica del modelo.

19.12. Interpretabilidad metodológica

La interpretabilidad no debe entenderse únicamente como una característica técnica.

Constituye un requisito metodológico.

El investigador debe ser capaz de explicar:

- qué variables condicionan la predicción;
- por qué lo hacen;
- bajo qué circunstancias dejan de hacerlo.

La ausencia de interpretabilidad limita considerablemente la utilidad científica del sistema.

19.13. Comunicación responsable de resultados

Las publicaciones deberían evitar afirmaciones excesivamente categóricas.

Expresiones como:

«la inteligencia artificial demuestra...»

deberían sustituirse por formulaciones más rigurosas:

«el modelo evaluado mostró...»

o

«en las condiciones experimentales estudiadas se observó...».

Esta precisión lingüística constituye un componente esencial del rigor científico.

19.14. Hacia un estándar internacional

Resulta razonable prever que durante los próximos años aparezcan guías específicas para la publicación y validación de modelos de inteligencia artificial aplicados a nutrición animal, de manera análoga a las directrices CONSORT, STROBE o PRISMA utilizadas en otros ámbitos biomédicos.

Dichas guías deberían integrar simultáneamente:

- criterios estadísticos;
- criterios biológicos;
- criterios tecnológicos;
- criterios regulatorios;
- criterios de transparencia.

19.15. Conclusión

La consolidación científica de la inteligencia artificial aplicada a la nutrición animal dependerá menos del desarrollo de algoritmos cada vez más complejos que de la capacidad de la comunidad investigadora para construir estándares metodológicos comunes.

La estandarización permitirá comparar resultados, reproducir estudios, acumular evidencia y acelerar la transferencia industrial de los avances científicos.

Solo cuando los sistemas inteligentes puedan diseñarse, validarse, documentarse y auditarse mediante procedimientos homogéneos será posible considerar que esta disciplina ha alcanzado una verdadera madurez científica.

En ese momento, la inteligencia artificial dejará de percibirse como una tecnología emergente para convertirse en una herramienta metodológica plenamente integrada en la investigación y en la práctica profesional de la nutrición animal.

20. Agenda de investigación para la próxima década: de los modelos predictivos aislados a los sistemas nutricionales verificables

20.1. Una agenda orientada a problemas, no a modas tecnológicas

La próxima década de investigación no debería organizarse alrededor de una sucesión de arquitecturas algorítmicas, sino de los problemas científicos e industriales que permanecen sin resolver. En nutrición animal, el valor de una innovación depende de su capacidad para mejorar una decisión concreta: caracterizar un ingrediente variable, estimar una necesidad individual, controlar un proceso, anticipar un peligro, reducir una excreción o demostrar que una intervención mantiene la salud y el bienestar. La investigación pierde utilidad cuando la elección del método precede a la definición del problema.

La agenda debe distinguir entre precisión estadística, relevancia biológica y utilidad decisoria. Un incremento marginal de exactitud puede carecer de significado si no modifica la formulación, la vigilancia, el manejo o la respuesta clínica. Inversamente, un modelo más sencillo puede generar un valor elevado cuando identifica con suficiente antelación una desviación que permite actuar. El criterio principal será, por tanto, la mejora verificable frente a la práctica de referencia y no la complejidad del algoritmo.

Esta orientación exige ensayos comparativos, líneas basales explícitas, evaluación económica y seguimiento de efectos no deseados. La investigación futura deberá responder no solo si el modelo predice, sino qué decisión cambia, quién la ejecuta, qué riesgo introduce, cuánto dura el beneficio y bajo qué condiciones deja de ser válido.

20.2. Modelos fundacionales especializados en nutrición y producción animal

Los modelos fundacionales ofrecen la posibilidad de integrar grandes volúmenes de literatura científica, tablas nutricionales, documentación técnica, registros de formulación, datos analíticos y series productivas. Su interés no reside en producir respuestas lingüísticamente plausibles, sino en construir representaciones reutilizables de ingredientes, animales, procesos y contextos. Un modelo sectorial podría apoyar la recuperación de evidencia, la comparación de especificaciones, la detección de incompatibilidades y la generación de hipótesis formulativas.

El desarrollo de estos sistemas requerirá corpus curados, metadatos de calidad y mecanismos que separen conocimiento normativo, evidencia experimental, experiencia industrial y contenido comercial. La mera agregación documental no garantiza fiabilidad. Será necesario registrar procedencia, fecha, jurisdicción, especie, fase productiva, método analítico y nivel de evidencia, de modo que la respuesta conserve el contexto que determina su validez.

La evaluación deberá incluir alucinación, omisión, estabilidad de respuesta, actualización y capacidad para abstenerse. En decisiones críticas, el modelo fundacional no debería sustituir las bases de datos autorizadas ni las reglas de formulación, sino actuar como interfaz de conocimiento sometida a verificación y a límites documentados.

20.3. Inteligencia artificial multimodal y representación integrada del sistema

La nutrición animal es inherentemente multimodal. Un mismo fenómeno puede expresarse mediante composición de ingredientes, espectros, imágenes, sonido, actividad, consumo, agua, temperatura, registros clínicos, parámetros de fabricación y resultados productivos. La investigación futura deberá superar los modelos que analizan cada fuente de manera aislada y desarrollar arquitecturas capaces de integrar señales heterogéneas sin perder su resolución temporal ni su significado biológico.

La multimodalidad puede aumentar la robustez porque permite contrastar señales. Una reducción de ingestión acompañada de menor actividad, alteración térmica y cambios de vocalización posee un significado distinto de una caída aislada registrada por un comedero. No obstante, la integración también multiplica los

puntos de fallo: desincronización, identidades incorrectas, frecuencias diferentes, datos ausentes y dependencias entre proveedores.

Los estudios deberán informar qué aporta cada modalidad, qué ocurre cuando una fuente desaparece y si el modelo mantiene su rendimiento en instalaciones con menor digitalización. La arquitectura óptima no será necesariamente la que utilice más sensores, sino la que consiga una representación suficiente con un coste, una complejidad y una mantenibilidad compatibles con el entorno productivo.

20.4. Causalidad, contrafactuales y separación entre asociación e intervención

Una parte importante de los sistemas actuales aprende asociaciones. Esta capacidad resulta útil para la predicción, pero insuficiente cuando se pretende decidir una intervención. Saber que una variable precede a una caída de rendimiento no demuestra que modificarla vaya a corregir el problema. La nutrición requiere distinguir causas, mediadores, consecuencias y simples marcadores.

La inteligencia artificial causal deberá combinar conocimiento mecanístico, diagramas causales, diseños experimentales y datos observacionales. Su objetivo será responder preguntas contrafactuales: qué habría ocurrido con otra dieta, otro nivel de inclusión, otra estrategia de transición o una actuación más temprana. Estas estimaciones deberán expresar sus supuestos y reconocer cuándo los datos no permiten identificar el efecto.

El avance más relevante consistirá en conectar modelos predictivos con ensayos adaptativos y validación experimental. La causalidad no puede inferirse únicamente por la sofisticación del método. Requiere variación informativa, control de confusores, temporalidad correcta y plausibilidad biológica.

20.5. Aprendizaje por refuerzo y control adaptativo bajo restricciones

El aprendizaje por refuerzo puede resultar útil en decisiones secuenciales, como la mezcla diaria de dietas, la regulación de procesos térmicos, la programación de producción o la adaptación progresiva a cambios ambientales. Sin embargo, el aprendizaje mediante ensayo y error plantea dificultades evidentes cuando las acciones afectan a animales, seguridad o producto liberado.

La investigación deberá centrarse en aprendizaje por refuerzo seguro, simulación previa, restricciones duras y políticas conservadoras. Las acciones admisibles deben quedar limitadas por requisitos nutricionales, máximos regulatorios, capacidad de equipos, estabilidad digestiva y criterios de bienestar. El sistema no puede explorar libremente combinaciones cuyo riesgo no haya sido caracterizado.

Los gemelos digitales y los modelos mecanísticos pueden proporcionar entornos de entrenamiento, pero la transferencia desde la simulación al sistema real deberá validarse. Una política eficaz en un modelo imperfecto puede explotar precisamente sus errores. Por ello, toda transición hacia control adaptativo exigirá pruebas escalonadas, supervisión humana y mecanismos de retorno inmediato a una estrategia segura.

20.6. Aprendizaje federado, soberanía de datos y colaboración entre empresas

La escasez de datos representativos constituye una de las principales limitaciones del sector. Ninguna fábrica, integradora o explotación dispone por sí sola de toda la variabilidad necesaria para construir modelos generalizables. El aprendizaje federado permite entrenar de manera distribuida sin concentrar necesariamente los datos brutos, abriendo la posibilidad de colaboración entre organizaciones que no pueden compartir información comercial o productiva sensible.

No obstante, la federación no elimina los problemas de gobernanza. Deben definirse variables comunes, criterios de calidad, derechos sobre el modelo, participación en los beneficios, seguridad de las actualizaciones y procedimientos para detectar contribuciones defectuosas o maliciosas. Las diferencias entre instalaciones pueden además producir modelos globales que rindan peor en participantes minoritarios.

La investigación deberá comparar estrategias globales y personalizadas, medir la equidad entre participantes y evaluar técnicas de privacidad diferencial y computación segura. La soberanía de datos debe coexistir con la trazabilidad suficiente para auditar cómo se construyó el modelo.

20.7. Gemelos digitales biológicos e industriales

El concepto de gemelo digital puede abarcar desde una representación del proceso de fabricación hasta un modelo dinámico de un animal, un lote, una explotación o una cadena de suministro. Su valor reside en permitir simulaciones, evaluación de escenarios y anticipación de consecuencias antes de modificar el sistema real.

En nutrición animal, un gemelo útil deberá integrar balances de nutrientes, consumo, crecimiento, producción, ambiente, salud y fabricación. No puede reducirse a una visualización de datos. Debe representar relaciones dinámicas, incertidumbre y límites de validez. Los modelos híbridos, que combinan ecuaciones mecanísticas con componentes aprendidos, ofrecen una vía especialmente prometedora.

La agenda de investigación debe establecer criterios para calibración, actualización, identidad entre el activo físico y su representación digital, y retirada cuando la divergencia supera un umbral. El gemelo deberá ser tratado como un instrumento científico que necesita verificación, no como una copia perfecta del sistema.

20.8. Laboratorios autónomos y experimentación adaptativa

La combinación de robótica, analítica rápida, diseño experimental e inteligencia artificial puede acelerar el desarrollo de ingredientes, aditivos y estrategias nutricionales. Un laboratorio semiautónomo puede seleccionar la siguiente condición experimental a partir de resultados previos, concentrando recursos en las regiones más informativas del espacio de formulación.

Esta capacidad resulta especialmente relevante cuando existen numerosas combinaciones de dosis, matrices, condiciones de proceso y respuestas. Sin embargo, la autonomía experimental no elimina la necesidad de hipótesis biológicas, controles, réplicas y criterios de exclusión. Un sistema puede optimizar una respuesta instrumental y alejarse del resultado fisiológicamente relevante.

Los protocolos futuros deberán registrar decisiones adaptativas, evitar sesgos por detención temprana y reservar conjuntos confirmatorios independientes. La fase de descubrimiento puede ser flexible; la demostración de eficacia y seguridad debe mantener estándares experimentales estrictos.

20.9. Integración de ómicas, microbioma y fenotipos funcionales

La metabolómica, transcriptómica, proteómica y metagenómica ofrecen una descripción de gran profundidad, pero generan espacios de variables muy superiores al número de animales disponibles. La investigación futura deberá priorizar diseños longitudinales, reducción de dimensionalidad interpretable y validación funcional de los marcadores.

El objetivo no debería ser clasificar de manera retrospectiva grupos que ya se conocen, sino identificar señales que anticipen una respuesta nutricional y permitan intervenir. Los modelos deberán separar correlaciones de composición microbiana de mecanismos mediados por metabolitos, barrera intestinal, inmunidad o competencia por sustratos.

La traducción industrial requerirá paneles reducidos, métodos reproducibles y costes compatibles. Un biomarcador complejo solo generará valor si puede medirse con suficiente frecuencia y si existe una acción nutricional asociada a su resultado.

20.10. Biología sintética, nuevos ingredientes y predicción de funcionalidad

La expansión de proteínas microbianas, fermentaciones de precisión, enzimas, biomasa de algas, insectos y coproductos modificará las matrices de formulación. La IA puede ayudar a predecir composición, digestibilidad, funcionalidad tecnológica y riesgos, pero los nuevos ingredientes suelen situarse fuera del dominio de los modelos históricos.

La agenda deberá integrar caracterización química, estructura, procesado, factores antinutricionales, microbiología, palatabilidad y respuesta animal. Las similitudes composicionales no bastan para asumir equivalencia nutricional. Los sistemas predictivos deben indicar cuándo una materia prima requiere ensayos adicionales y evitar extrapolaciones silenciosas.

En biología sintética, la optimización deberá incorporar seguridad, estabilidad genética, trazabilidad y consecuencias ambientales. La posibilidad de diseñar ingredientes no reduce la obligación de demostrar su comportamiento dentro de dietas completas y condiciones productivas reales.

20.11. Explicabilidad, incertidumbre y capacidad de abstención

La próxima generación de sistemas deberá comunicar no solo una predicción, sino también su incertidumbre, las variables determinantes, el dominio de validez y las circunstancias que justifican abstenerse. La explicación debe adaptarse al usuario: un nutricionista, un operador de fábrica, un veterinario y un auditor necesitan niveles de detalle diferentes.

La investigación no debería evaluar la explicabilidad por su apariencia visual, sino por su capacidad para mejorar decisiones y detectar errores. Una explicación puede ser estable y comprensible, pero causalmente incorrecta. Será necesario contrastarla con conocimiento experto, perturbaciones controladas y análisis de sensibilidad.

La abstención constituye una función crítica. Cuando faltan datos, aparece una materia prima nueva o la entrada se aleja del entrenamiento, el sistema debe poder reconocer que no dispone de evidencia suficiente. Forzar una salida en todos los casos convierte la automatización en una fuente de riesgo.

20.12. Datos de referencia, benchmarks y ciencia abierta

La comparación científica exige conjuntos de referencia que reflejen la variabilidad del sector. Los benchmarks futuros deberán incluir diferentes especies, genéticas, sistemas productivos, campañas, materias primas, regiones y niveles de digitalización. Un único conjunto altamente controlado no permite estimar la transferibilidad.

La apertura de datos debe respetar confidencialidad, bienestar, propiedad intelectual y protección de información comercial. Cuando los datos no puedan publicarse, pueden compartirse esquemas, diccionarios, protocolos, datos sintéticos validados y entornos de evaluación independientes. La reproducibilidad no exige necesariamente revelar secretos empresariales, pero sí ofrecer evidencia suficiente para verificar el resultado.

También se necesitan repositorios de fallos, incidentes y casos fuera de dominio. La ciencia aprende no solo de los modelos que funcionan, sino de las condiciones en las que dejan de hacerlo.

20.13. Validación prospectiva y evidencia posterior al despliegue

La mayoría de los estudios continúa evaluando retrospectivamente datos históricos. La próxima década debe priorizar validaciones prospectivas, multicéntricas y longitudinales. El modelo debe emitir la predicción antes de que se conozca el resultado y debe evaluarse dentro del flujo real de trabajo, incluyendo la respuesta de los usuarios.

La eficacia algorítmica y la eficacia organizativa pueden diferir. Una alerta correcta no genera valor si llega tarde, no se comprende, no existe capacidad de actuación o se diluye entre avisos irrelevantes. Los estudios deben medir adopción, tiempo de respuesta, modificaciones de conducta y resultados finales.

La vigilancia posterior al despliegue deberá registrar deriva, incidentes, cambios de contexto y decisiones de retirada. La validación se convertirá en un proceso continuo asociado a cada versión del modelo.

20.14. Regulación, estándares y aseguramiento independiente

La madurez del sector dependerá de la convergencia entre ciencia, sistemas de calidad y regulación. Las metodologías de validación deberán conectarse con la higiene de los piensos, el APPCC, la trazabilidad, la gestión de cambios, la ciberseguridad y el marco europeo de inteligencia artificial. El cumplimiento no puede permanecer separado de la arquitectura técnica.

Los estándares futuros deberían definir documentación mínima, clasificación por impacto, pruebas de robustez, supervisión humana, conservación de registros y criterios de reevaluación. La evaluación independiente será especialmente importante cuando el proveedor del sistema controla también los datos, las métricas y la interpretación del resultado.

La regulación debe ser proporcional. Un modelo de apoyo documental no requiere los mismos controles que un sistema que modifica automáticamente una dosificación. La clasificación funcional y el impacto real deben determinar la intensidad del aseguramiento.

20.15. Cooperación internacional y sistemas productivos con menor digitalización

La investigación no debe limitarse a explotaciones intensivas altamente instrumentadas. Una parte sustancial de la producción animal mundial opera con conectividad, capacidad analítica y recursos limitados. Los modelos desarrollados exclusivamente en entornos avanzados pueden ampliar la brecha tecnológica.

Se necesitan arquitecturas frugales, sensores robustos, funcionamiento local y procedimientos que toleren datos incompletos. La transferencia debe considerar clima, materias primas locales, razas, enfermedades, estructuras empresariales y disponibilidad de servicios veterinarios y laboratoriales.

La colaboración internacional permitirá construir evidencia más diversa, pero debe evitar relaciones extractivas en las que los datos se obtienen de una región y el valor tecnológico se concentra en otra. Los acuerdos deben definir acceso, gobernanza, propiedad y retorno para los participantes.

20.16. Prioridades 2026–2036 y conclusión

Las prioridades de la próxima década pueden resumirse en cinco exigencias: datos representativos, modelos híbridos y causales, validación prospectiva, gobernanza integrada y demostración de valor sobre resultados biológicos e industriales. La innovación será relevante cuando consiga conectar estas dimensiones sin aumentar de forma desproporcionada la complejidad operativa.

El futuro no estará definido por sistemas completamente autónomos que sustituyan al nutricionista, al veterinario o al responsable de calidad. Estará definido por sistemas aumentados capaces de medir mejor, expresar incertidumbre, proponer alternativas y conservar límites independientes. La autonomía solo será admisible allí donde el dominio esté bien caracterizado, la intervención sea reversible y existan barreras suficientes.

La agenda de investigación debe abandonar la idea de que más datos y mayor complejidad producen automáticamente mejores decisiones. La cuestión decisiva será si el sistema puede demostrar, en condiciones reales y durante el tiempo suficiente, que mejora la nutrición, la seguridad, el bienestar, la sostenibilidad y la resiliencia sin trasladar riesgos ocultos a otros eslabones de la cadena.

Tabla 39. Prioridades de investigación y criterios de demostración para el periodo 2026–2036.

Prioridad	Pregunta científica	Evidencia mínima	Riesgo principal
Datos representativos	¿El conjunto refleja el contexto de uso?	Validación externa y análisis por subgrupos	Sesgo y falsa generalización
Modelos causales e híbridos	¿La intervención produce el efecto esperado?	Ensayos prospectivos y contraste mecanístico	Confundir asociación con causalidad
Nutrición adaptativa segura	¿Puede ajustarse la dieta sin superar límites?	Pruebas escalonadas, simulación y barreras	Exploración insegura
Multimodalidad	¿La combinación de señales mejora la decisión?	Ablación de modalidades y tolerancia a fallos	Dependencia tecnológica excesiva
Gobernanza y trazabilidad	¿Puede reconstruirse cada recomendación?	Registro de versión, datos, decisión y actuación	Opacidad y responsabilidad difusa
Valor industrial	¿El modelo modifica resultados relevantes?	Comparación con línea basal y seguimiento económico	Optimizar métricas sin impacto real

Conclusiones generales: de la promesa algorítmica a la nutrición animal verificable

La inteligencia artificial aplicada a la alimentación animal no constituye una ruptura completa con la tradición cuantitativa del sector. La formulación, la producción y la evaluación zootécnica llevan décadas apoyándose en modelos, coeficientes, restricciones y decisiones optimizadas. La transformación actual procede de la capacidad para incorporar datos más frecuentes, heterogéneos e individualizados, relacionarlos con la respuesta productiva y actualizar la intervención durante el proceso. Esta continuidad histórica es importante porque impide confundir digitalización, automatización e inteligencia artificial, y permite preservar aquello que ya funcionaba: reglas nutricionales explícitas, límites de seguridad, conocimiento fisiológico y responsabilidad profesional.

La obra ha mostrado que el valor de la IA depende menos de la etiqueta tecnológica que de la arquitectura decisoria en la que se integra. Un algoritmo aislado puede predecir con precisión y, sin embargo, resultar irrelevante si la organización no puede actuar sobre su salida. También puede producir daño cuando su recomendación se ejecuta sin restricciones, cuando los datos no representan el contexto real o cuando una función objetivo económica desplaza silenciosamente objetivos de salud, bienestar o seguridad. La unidad de análisis correcta no es el modelo, sino el sistema sociotécnico completo.

La primera condición de legitimidad es la calidad de los datos. La materia prima, el proceso, el animal y el ambiente deben conservar identidades y tiempos compatibles. El muestreo, la calibración, la trazabilidad de lotes, la gestión de ausencias y la interoperabilidad semántica condicionan el resultado tanto como la arquitectura algorítmica. Una empresa que no controla estas capas no dispone de una plataforma de inteligencia artificial, sino de una acumulación de registros cuya apariencia cuantitativa puede ocultar errores sistemáticos.

La segunda condición es la integración entre predicción y restricciones. La formulación inteligente no debe sustituir los límites legales, toxicológicos, fisiológicos y tecnológicos por ponderaciones negociables. La solución robusta combina modelos que estiman composición, consumo, respuesta o riesgo con motores de optimización y barreras independientes. Esta separación permite saber qué componente falló, reconstruir la decisión y evitar que una mejora económica compense matemáticamente una condición que nunca debería sacrificarse.

La tercera condición es la validación externa y prospectiva. La precisión obtenida en datos históricos no demuestra que el sistema funcione en otra campaña, fábrica, explotación, genética o región. La evidencia debe incluir robustez, generalización, calibración, comportamiento en subgrupos, análisis de errores extremos y seguimiento después del despliegue. La incertidumbre no es una debilidad que deba ocultarse: es información esencial para decidir si la recomendación puede ejecutarse, necesita revisión o debe rechazarse.

La cuarta condición es la supervisión humana efectiva. La intervención profesional no puede reducirse a confirmar rutinariamente una salida. El nutricionista, veterinario, responsable de calidad u operador debe comprender el significado de la recomendación, disponer de información sobre sus límites y tener autoridad real para detenerla. La automatización aumenta el valor del conocimiento experto cuando libera tiempo de cálculo y vigilancia; lo degrada cuando transforma al profesional en un firmante sin capacidad de contraste.

La quinta condición es la conexión entre productividad, salud y bienestar. Una mejora en conversión, crecimiento o producción no basta para demostrar que el sistema es superior. Las métricas deben incorporar mortalidad, morbilidad, comportamiento, competencia por recursos, estabilidad digestiva, locomoción, estrés térmico y otros indicadores basados en el animal. La IA puede revelar señales tempranas y favorecer intervenciones más precisas, pero también puede consolidar una visión productivista si solo aprende de aquello que la empresa decidió medir.

La sexta condición es la gobernanza de la cadena de suministro y de la fábrica. La calidad nutricional calculada puede perderse por dosificación, mezcla, molienda, tratamiento térmico, contaminación cruzada, almacenamiento o transporte. La inteligencia artificial ofrece herramientas para vigilar estas desviaciones, optimizar secuencias y anticipar fallos, pero crea nuevas dependencias de software, sensores, conectividad y

proveedores. La resiliencia exige procedimientos de contingencia, capacidad de operación segura sin el modelo y conservación de registros comprensibles.

La séptima condición es una evaluación ambiental que no desplace impactos. Reducir proteína bruta, emisiones o huella de carbono puede ser beneficioso, pero cada optimización debe considerar efectos sobre digestibilidad, uso del suelo, biodiversidad, dependencia geográfica, salud y duración del ciclo productivo. La sostenibilidad algorítmica requiere límites de sistema transparentes, incertidumbre y análisis de sensibilidad. Una cifra más precisa no corrige una frontera de evaluación mal definida.

La octava condición es el encaje jurídico y regulatorio. La utilización de IA no desplaza las obligaciones del operador de piensos ni transforma la recomendación automatizada en una causa de exoneración. La higiene, la trazabilidad, el control de peligros, la seguridad del producto y la diligencia profesional siguen siendo exigibles. El Reglamento de Inteligencia Artificial añade una capa de gobernanza que debe integrarse con los sistemas sectoriales existentes, no gestionarse como un expediente tecnológico separado.

La novena condición es la demostración de valor. El retorno no se limita al ahorro directo. Puede expresarse en menor variabilidad, decisiones más tempranas, reducción de pérdidas, mejor capacidad de auditoría, mayor disponibilidad de equipos o menor exposición a incidentes. Sin embargo, el cálculo debe incluir integración, datos, mantenimiento, supervisión, falsas alertas, formación y riesgo de dependencia. Un proyecto piloto que no define su línea basal ni la decisión que pretende mejorar difícilmente podrá justificar su escalado.

La décima condición es el desarrollo de capital humano. La nutrición animal aumentada por IA necesita profesionales capaces de leer modelos, cuestionar datos, interpretar incertidumbre y traducir resultados a acciones biológicamente defendibles. Esta competencia no sustituye el conocimiento nutricional; lo amplía. La organización deberá proteger el saber tácito, documentar excepciones y evitar que la dependencia tecnológica erosione la capacidad para comprender el proceso.

En conjunto, la inteligencia artificial ofrece una oportunidad real para transformar la alimentación animal desde una práctica basada en promedios y revisiones tardías hacia sistemas más sensibles a la variabilidad, el tiempo y el contexto. Esa oportunidad no se materializará mediante la adopción indiscriminada de herramientas. Requiere una disciplina de diseño, validación, documentación y retirada. La madurez se reconocerá cuando las empresas sean capaces de explicar no solo qué modelo utilizan, sino por qué es apropiado, dónde funciona, cuándo se abstiene, quién responde y qué evidencia demuestra su valor.

La conclusión final puede formularse de manera deliberadamente exigente: la IA será legítima en nutrición animal cuando permita tomar mejores decisiones sin debilitar las barreras que protegen al animal, al operador, al consumidor y al sistema productivo. La automatización no constituye el fin. El fin es una nutrición más segura, precisa, sostenible y verificable. Todo sistema que no pueda demostrar esa contribución debe permanecer como hipótesis tecnológica y no convertirse todavía en autoridad decisoria.

Glosario esencial

Algoritmo. Conjunto ordenado de reglas o instrucciones utilizado para transformar datos de entrada en una salida o decisión.

Aprendizaje automático. Conjunto de métodos que ajustan su comportamiento a partir de datos sin que todas las reglas hayan sido programadas de forma explícita.

Aprendizaje federado. Entrenamiento distribuido en el que varias organizaciones contribuyen a un modelo sin transferir necesariamente sus datos brutos a un repositorio central.

Aprendizaje por refuerzo. Método en el que un agente aprende una política de actuación a partir de recompensas y consecuencias acumuladas.

Calibración. Correspondencia entre la probabilidad predicha y la frecuencia real observada del resultado.

Dato fuera de dominio. Entrada que difiere de manera relevante de las observaciones utilizadas para desarrollar o validar el modelo.

Deriva conceptual. Cambio en la relación entre las variables de entrada y el resultado que reduce el rendimiento del modelo con el tiempo.

Deriva de datos. Cambio en la distribución de las variables de entrada respecto del conjunto de entrenamiento.

Explicabilidad. Capacidad para proporcionar información comprensible sobre los factores y procesos que condicionan una salida algorítmica.

Frontera de Pareto. Conjunto de soluciones multiobjetivo en las que ningún objetivo puede mejorarse sin empeorar al menos otro.

Gemelo digital. Representación dinámica de un activo, proceso o sistema físico que se actualiza con datos y permite simular estados o escenarios.

Gobernanza de IA. Estructura de responsabilidades, políticas, controles y registros utilizada para dirigir y supervisar el ciclo de vida de sistemas de IA.

IA causal. Métodos destinados a estimar relaciones causales y efectos de intervenciones, no únicamente asociaciones predictivas.

IA explicable (XAI). Técnicas y prácticas orientadas a hacer interpretables las predicciones, clasificaciones o recomendaciones de un sistema.

IA multimodal. Sistema capaz de integrar diferentes modalidades de datos, como texto, imágenes, espectros, sonido, series temporales y registros tabulares.

Interoperabilidad. Capacidad de sistemas diferentes para intercambiar datos y conservar un significado común.

Modelo fundacional. Modelo entrenado con grandes volúmenes de datos y reutilizable o adaptable para múltiples tareas posteriores.

Modelo híbrido. Arquitectura que combina conocimiento mecanístico o reglas explícitas con componentes aprendidos a partir de datos.

Nutrición de precisión. Ajuste del aporte nutricional a las necesidades reales de un individuo o subgrupo con mayor frecuencia y resolución que la alimentación convencional por fases.

Predicción. Estimación de una variable desconocida o futura a partir de información disponible.

Robustez. Capacidad del sistema para mantener un comportamiento aceptable ante ruido, perturbaciones, ausencias o variaciones razonables.

Sesgo. Error sistemático que favorece o perjudica determinados contextos, grupos o resultados.

Supervisión humana. Intervención de una persona competente con información, tiempo y autoridad suficientes para revisar, modificar o detener una recomendación.

Trazabilidad algorítmica. Capacidad para reconstruir datos, versión, parámetros, salida, revisión y actuación asociados a una decisión.

Validación externa. Evaluación del modelo con datos independientes procedentes de otra población, periodo, fábrica, explotación o contexto.

Validación prospectiva. Evaluación en la que la predicción se emite antes de conocer el resultado y dentro del flujo real de trabajo.

Variable proxy. Medida indirecta utilizada para representar un fenómeno que no se observa de forma directa.

Visión artificial. Procesamiento algorítmico de imágenes o vídeo para detectar, clasificar, medir o seguir objetos, animales y comportamientos.

Bibliografía científica, normativa y técnica

Las referencias se presentan por bloques temáticos para facilitar su consulta. La edición definitiva deberá mantener la correspondencia entre cada afirmación, cita en el texto y entrada bibliográfica, así como comprobar las actualizaciones normativas posteriores a la fecha de cierre editorial.

I. Fundamentos de inteligencia artificial, aprendizaje automático y ciencia de datos

- Aggarwal, C. C. (2018). *Neural networks and deep learning*. Springer.
- Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. MIT Press.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1-127. <https://doi.org/10.1561/22000000006>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L. (2001). Statistical modeling: The two cultures. *Statistical Science*, 16(3), 199-231. <https://doi.org/10.1214/ss/1009213726>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Chollet, F. (2021). *Deep learning with Python* (2nd ed.). Manning.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273-297. <https://doi.org/10.1007/BF00994018>
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87. <https://doi.org/10.1145/2347736.2347755>
- Domingos, P. (2015). *The master algorithm*. Basic Books.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv. <https://doi.org/10.48550/arXiv.1702.08608>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning* (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263-1284. <https://doi.org/10.1109/TKDE.2008.239>
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics* (2nd ed.). MIT Press.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence* (pp. 1137-1143). Morgan Kaufmann.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer. <https://doi.org/10.1007/978-1-4614-6849-3>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems*, 30.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Molnar, C. (2022). *Interpretable machine learning* (2nd ed.). Independently published.
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Murphy, K. P. (2022). *Probabilistic machine learning: An introduction*. MIT Press.
- Pearl, J. (2009). *Causality: Models, reasoning, and inference* (2nd ed.). Cambridge University Press.
- Pearl, J., Glymour, M., & Jewell, N. P. (2016). *Causal inference in statistics: A primer*. Wiley.
- Provost, F., & Fawcett, T. (2013). *Data science for business*. O'Reilly Media.

- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). Why should I trust you? Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135-1144). ACM. <https://doi.org/10.1145/2939672.2939778>
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge University Press.
- Shmueli, G. (2010). To explain or to predict? *Statistical Science*, 25(3), 289-310. <https://doi.org/10.1214/10-STS330>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Vapnik, V. N. (1998). *Statistical learning theory*. Wiley.
- Zhou, Z.-H. (2021). *Machine learning*. Springer.

II. Inteligencia artificial, agricultura digital y ganadería de precisión

- Banhazi, T. M., Lehr, H., Black, J. L., Crabtree, H., Schofield, P., Tschärke, M., & Berckmans, D. (2012). Precision livestock farming: An international review of scientific and commercial aspects. *International Journal of Agricultural and Biological Engineering*, 5(3), 1-9.
- Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. *Revue Scientifique et Technique*, 33(1), 189-196. <https://doi.org/10.20506/rst.33.1.2273>
- Berckmans, D. (2017). General introduction to precision livestock farming. *Animal Frontiers*, 7(1), 6-11. <https://doi.org/10.2527/af.2017.0102>
- Borchers, M. R., & Bewley, J. M. (2015). An assessment of producer precision dairy farming technology use, prepurchase considerations, and usefulness. *Journal of Dairy Science*, 98(6), 4198-4205. <https://doi.org/10.3168/jds.2014-8963>
- Cabrera, V. E., & Fadul-Pacheco, L. (2021). Future of dairy farming from the Dairy Brain perspective: Data integration, analytics, and applications. *International Dairy Journal*, 121, 105069. <https://doi.org/10.1016/j.idairyj.2021.105069>
- Caja, G., Castro-Costa, A., & Knight, C. H. (2016). Engineering to support wellbeing of dairy animals. *Journal of Dairy Research*, 83(2), 136-147. <https://doi.org/10.1017/S0022029916000261>
- Dawkins, M. S. (2021). Does smart farming improve or damage animal welfare? Technology and what animals want. *Frontiers in Animal Science*, 2, 736536. <https://doi.org/10.3389/fanim.2021.736536>
- Eastwood, C., Klerkx, L., Ayre, M., & Dela Rue, B. (2019). Managing socio-ethical challenges in the development of smart farming: From a fragmented to a comprehensive approach for responsible research and innovation. *Journal of Agricultural and Environmental Ethics*, 32, 741-768. <https://doi.org/10.1007/s10806-017-9704-5>
- Frost, A. R., Schofield, C. P., Beulah, S. A., Mottram, T. T., Lines, J. A., & Wathes, C. M. (1997). A review of livestock monitoring and the need for integrated systems. *Computers and Electronics in Agriculture*, 17(2), 139-159. [https://doi.org/10.1016/S0168-1699\(96\)01301-4](https://doi.org/10.1016/S0168-1699(96)01301-4)
- Halachmi, I., Guarino, M., Bewley, J., & Pastell, M. (2019). Smart animal agriculture: Application of real-time sensors to improve animal well-being and production. *Annual Review of Animal Biosciences*, 7, 403-425. <https://doi.org/10.1146/annurev-animal-020518-114851>
- Klerkx, L., Jakku, E., & Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0. *NJAS - Wageningen Journal of Life Sciences*, 90-91, 100315. <https://doi.org/10.1016/j.njas.2019.100315>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Lovarelli, D., Bacenetti, J., & Guarino, M. (2020). A review on dairy cattle farming: Is precision livestock farming the compromise for an environmental, economic and social sustainable production? *Journal of Cleaner Production*, 262, 121409. <https://doi.org/10.1016/j.jclepro.2020.121409>
- Neethirajan, S. (2020). The role of sensors, big data and machine learning in modern animal farming. *Sensing and Bio-Sensing Research*, 29, 100367. <https://doi.org/10.1016/j.sbsr.2020.100367>
- Neethirajan, S., Tuteja, S. K., Huang, S.-T., & Kelton, D. (2017). Recent advancement in biosensors technology for animal and livestock health management. *Biosensors and Bioelectronics*, 98, 398-407. <https://doi.org/10.1016/j.bios.2017.07.015>
- Rowe, E., Dawkins, M. S., & Gebhardt-Henrich, S. G. (2019). A systematic review of precision livestock farming in the poultry sector: Is technology focussed on improving bird welfare? *Animals*, 9(9), 614. <https://doi.org/10.3390/ani9090614>
- Rutten, C. J., Velthuis, A. G. J., Steeneveld, W., & Hogeveen, H. (2013). Invited review: Sensors to support health management on dairy farms. *Journal of Dairy Science*, 96(4), 1928-1952. <https://doi.org/10.3168/jds.2012-6107>
- Smith, M. J. (2020). Getting value from artificial intelligence in agriculture. *Animal Production Science*, 60(1), 46-54.
- Steeneveld, W., & Hogeveen, H. (2015). Characterization of Dutch dairy farms using sensor systems for cow management. *Journal of Dairy Science*, 98(1), 709-717. <https://doi.org/10.3168/jds.2014-8595>

- Tullo, E., Finzi, A., & Guarino, M. (2019). Environmental impact of livestock farming and precision livestock farming as a mitigation strategy. *Science of the Total Environment*, 650, 2751-2760. <https://doi.org/10.1016/j.scitotenv.2018.10.018>
- Wathes, C. M., Kristensen, H. H., Aerts, J.-M., & Berckmans, D. (2008). Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? *Computers and Electronics in Agriculture*, 64(1), 2-10. <https://doi.org/10.1016/j.compag.2008.05.005>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming - A review. *Agricultural Systems*, 153, 69-80. <https://doi.org/10.1016/j.agry.2017.01.023>
- Zhai, Z., Martínez, J. F., Beltran, V., & Martínez, N. L. (2020). Decision support systems for agriculture 4.0: Survey and challenges. *Computers and Electronics in Agriculture*, 170, 105256. <https://doi.org/10.1016/j.compag.2020.105256>

III. Sensores, visión artificial, comportamiento, bienestar y sanidad animal

- Borchers, M. R., Chang, Y. M., Tsai, I. C., Wadsworth, B. A., & Bewley, J. M. (2016). A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *Journal of Dairy Science*, 99(9), 7458-7466. <https://doi.org/10.3168/jds.2015-10843>
- Brown-Brandl, T. M., Jones, D. D., & Woldt, W. E. (2005). Evaluating modelling techniques for cattle heat stress prediction. *Biosystems Engineering*, 91(4), 513-524.
- Buller, H., Blokhuis, H., Lokhorst, K., Silberberg, M., & Veissier, I. (2020). Animal welfare management in a digital world. *Animals*, 10(10), 1779. <https://doi.org/10.3390/ani10101779>
- Chapa, J. M., Maschat, K., Iwersen, M., Baumgartner, J., & Drillich, M. (2020). Accelerometer systems as tools for health and welfare assessment in cattle and pigs - A review. *Behavioural Processes*, 181, 104262. <https://doi.org/10.1016/j.beproc.2020.104262>
- Dawkins, M. S., Lee, H.-J., Waitt, C. D., & Roberts, S. J. (2009). Optical flow patterns in broiler chicken flocks as automated measures of behaviour and gait. *Applied Animal Behaviour Science*, 119(3-4), 203-209. <https://doi.org/10.1016/j.applanim.2009.04.009>
- Dawkins, M. S., Roberts, S. J., Cain, R. J., Nickson, T., & Donnelly, C. A. (2017). Early warning of footpad dermatitis and hockburn in broiler chicken flocks using optical flow, bodyweight and water consumption. *Veterinary Record*, 180(20), 499. <https://doi.org/10.1136/vr.104066>
- Delgado, B., Cuevas, E., Valera, M., & Molina, A. (2021). Computer vision and machine learning for animal monitoring: A review. *Animals*, 11(11), 3163.
- Eckelkamp, E. A., Bewley, J. M., Hockin, J., & Taraba, J. L. (2016). Validation of an automated monitoring system for dairy cattle behavior. *Journal of Dairy Science*, 99(9), 7329-7344.
- Feighelstein, M., Shimshoni, I., Finka, L. R., Luna, S. P. L., Mills, D. S., & Zamansky, A. (2022). Automated recognition of pain in cats. *Scientific Reports*, 12, 9575.
- Graves, R. E. (2006). Dairy cattle behavior and management. In N. K. Jain (Ed.), *Dairy production systems*. American Society of Agricultural and Biological Engineers.
- Guarino, M., Jans, P., Costa, A., Aerts, J.-M., & Berckmans, D. (2008). Field test of algorithm for automatic cough detection in pig houses. *Computers and Electronics in Agriculture*, 62(1), 22-28. <https://doi.org/10.1016/j.compag.2007.08.016>
- Halachmi, I., Polak, P., Roberts, D. J., & Klopčic, M. (2008). Cow body shape and automation of condition scoring. *Journal of Dairy Science*, 91(11), 4444-4451. <https://doi.org/10.3168/jds.2007-0785>
- Hogeveen, H., Kamphuis, C., Steeneveld, W., & Mollenhorst, H. (2010). Sensors and clinical mastitis - The quest for the perfect alert. *Sensors*, 10(9), 7991-8009. <https://doi.org/10.3390/s100907991>
- Li, N., Ren, Z., Li, D., & Zeng, L. (2020). Review: Automated techniques for monitoring the behaviour and welfare of broilers and laying hens. *Animal*, 14(3), 617-625. <https://doi.org/10.1017/S1751731119002158>
- Matthews, S. G., Miller, A. L., Clapp, J., Plötz, T., & Kyriazakis, I. (2016). Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. *Veterinary Journal*, 217, 43-51. <https://doi.org/10.1016/j.tvjl.2016.09.005>
- Nasirahmadi, A., Edwards, S. A., & Sturm, B. (2017). Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science*, 202, 25-38. <https://doi.org/10.1016/j.livsci.2017.05.014>
- Oczak, M., Viazzi, S., Ismayilova, G., Sonoda, L. T., Roulston, N., Fels, M., Bahr, C., Hartung, J., Guarino, M., Berckmans, D., & Vranken, E. (2014). Classification of aggressive behaviour in pigs by activity index and multilayer feed forward neural network. *Biosystems Engineering*, 119, 89-97. <https://doi.org/10.1016/j.biosystemseng.2014.01.005>
- Pastorelli, G., Faustini, M., Corino, C., Rossi, R., & Zaninelli, M. (2020). Computer vision and deep learning for monitoring livestock behavior and health. *Animals*, 10, 2032.
- Poursaberi, A., Bahr, C., Pluk, A., Van Nuffel, A., & Berckmans, D. (2010). Real-time automatic lameness detection based on back posture extraction in dairy cattle. *Transactions of the ASABE*, 53(4), 1265-1273.
- Roelofs, J. B., van Eerdenburg, F. J. C. M., Soede, N. M., & Kemp, B. (2005). Various behavioral signs of estrous and their relationship with time of ovulation in dairy cattle. *Theriogenology*, 63(5), 1366-1377.
- Van Hertem, T., Maltz, E., Antler, A., Romanini, C. E. B., Viazzi, S., Bahr, C., Schlageter-Tello, A., Lokhorst, C., Berckmans, D., & Halachmi, I. (2013). Lameness detection based on multivariate continuous sensing of milk yield, rumination, and neck activity. *Journal of Dairy Science*, 96(7), 4286-4298.

Weary, D. M., Huzzey, J. M., & von Keyserlingk, M. A. G. (2009). Board-invited review: Using behavior to predict and identify ill health in animals. *Journal of Animal Science*, 87(2), 770-777. <https://doi.org/10.2527/jas.2008-1297>

IV. Nutrición animal, requerimientos y alimentación de precisión

- Agricultural Research Council. (1981). The nutrient requirements of pigs. Commonwealth Agricultural Bureaux.
- Agricultural Research Council. (1984). The nutrient requirements of ruminant livestock. Commonwealth Agricultural Bureaux.
- Baker, D. H. (2009). Advances in protein-amino acid nutrition of poultry. *Amino Acids*, 37, 29-41. <https://doi.org/10.1007/s00726-008-0198-3>
- Brossard, L., Quiniou, N., Dourmad, J.-Y., Salaün, Y., & Van Milgen, J. (2009). Dynamic model of nutrient use and individual requirements of growing pigs. *Animal*, 3(5), 673-685.
- Chalupa, W., & Sniffen, C. J. (2000). Balancing rations for amino acids in high-producing dairy cows. In *Recent advances in animal nutrition*. Nottingham University Press.
- CVB. (2021). CVB feed table 2021. Federatie Nederlandse Diervoederketen.
- de Lange, C. F. M., Birkett, S. H., & Morel, P. C. H. (2001). Protein, fat and bone tissue growth in swine. In A. J. Lewis & L. L. Southern (Eds.), *Swine nutrition* (2nd ed.). CRC Press.
- Dourmad, J.-Y., Étienne, M., Valancogne, A., Dubois, S., van Milgen, J., & Noblet, J. (2008). InraPorc: A model and decision support tool for the nutrition of sows. *Animal Feed Science and Technology*, 143(1-4), 372-386.
- Emmans, G. C., & Kyriazakis, I. (2001). Consequences of genetic change in farm animals on food intake and feeding behaviour. *Proceedings of the Nutrition Society*, 60(1), 115-125.
- FEDNA. (2019). Necesidades nutricionales para ganado porcino (2.^a ed.). Fundación Española para el Desarrollo de la Nutrición Animal.
- FEDNA. (2021). Normas FEDNA para la formulación de piensos compuestos (5.^a ed.). Fundación Española para el Desarrollo de la Nutrición Animal.
- FEDNA. (2023). Tablas FEDNA de composición y valor nutritivo de alimentos para la fabricación de piensos compuestos (5.^a ed.). Fundación Española para el Desarrollo de la Nutrición Animal.
- GfE. (2006). Recommendations for the supply of energy and nutrients to pigs. DLG-Verlag.
- GfE. (2008). Recommendations for the supply of energy and nutrients to dairy cows and heifers. DLG-Verlag.
- INRA. (2018). INRA feeding system for ruminants. Wageningen Academic Publishers.
- Leeson, S., & Summers, J. D. (2005). *Commercial poultry nutrition* (3rd ed.). University Books.
- McDonald, P., Edwards, R. A., Greenhalgh, J. F. D., Morgan, C. A., Sinclair, L. A., & Wilkinson, R. G. (2022). *Animal nutrition* (8th ed.). Pearson.
- National Academies of Sciences, Engineering, and Medicine. (2016). Nutrient requirements of beef cattle (8th rev. ed.). National Academies Press. <https://doi.org/10.17226/19014>
- National Academies of Sciences, Engineering, and Medicine. (2021). Nutrient requirements of dairy cattle (8th rev. ed.). National Academies Press. <https://doi.org/10.17226/25806>
- National Research Council. (1994). Nutrient requirements of poultry (9th rev. ed.). National Academies Press.
- National Research Council. (2001). Nutrient requirements of dairy cattle (7th rev. ed.). National Academies Press.
- National Research Council. (2011). Nutrient requirements of fish and shrimp. National Academies Press. <https://doi.org/10.17226/13039>
- National Research Council. (2012). Nutrient requirements of swine (11th rev. ed.). National Academies Press. <https://doi.org/10.17226/13298>
- Noblet, J., & van Milgen, J. (2004). Energy value of pig feeds: Effect of pig body weight and energy evaluation system. *Journal of Animal Science*, 82(E-Suppl.), E229-E238.
- Pomar, C., & Remus, A. (2019). Precision pig feeding: A breakthrough toward sustainability. *Animal Frontiers*, 9(2), 52-59. <https://doi.org/10.1093/af/vfz006>
- Pomar, C., & Schinckel, A. P. (2022). Precision feeding in pig production. In I. Kyriazakis (Ed.), *The science of animal nutrition*. CABI.
- Pomar, C., Hauschild, L., Zhang, G.-H., Pomar, J., & Lovatto, P. A. (2009). Applying precision feeding techniques in growing-finishing pig operations. *Revista Brasileira de Zootecnia*, 38, 226-237.
- Sauvant, D., Perez, J.-M., & Tran, G. (Eds.). (2004). *Tables of composition and nutritional value of feed materials*. Wageningen Academic Publishers.
- Tedeschi, L. O., Fox, D. G., Sainz, R. D., Barioni, L. G., Medeiros, S. R., & Boin, C. (2005). Mathematical models in ruminant nutrition. *Scientia Agricola*, 62(1), 76-91.
- Van Milgen, J., Valancogne, A., Dubois, S., Dourmad, J.-Y., Sève, B., & Noblet, J. (2008). InraPorc: A model and decision support tool for the nutrition of growing pigs. *Animal Feed Science and Technology*, 143(1-4), 387-405.
- Whittemore, C. T., Green, D. M., & Knap, P. W. (2001). Technical review of the energy and protein requirements of growing pigs. *Animal Science*, 73(3), 363-373.

V. Ingredientes, digestibilidad, microbiota y aditivos para alimentación animal

- Bedford, M. R., & Partridge, G. G. (Eds.). (2010). *Enzymes in farm animal nutrition* (2nd ed.). CABI.
- Borda-Molina, D., Seifert, J., & Camarinha-Silva, A. (2018). Current perspectives of the chicken gastrointestinal tract and its microbiome. *Computational and Structural Biotechnology Journal*, 16, 131-139.
- Celi, P., Cowieson, A. J., Fru-Nji, F., Steinert, R. E., Kluenter, A.-M., & Verlhac, V. (2017). Gastrointestinal functionality in animal nutrition and health. *Animal Feed Science and Technology*, 234, 88-100.
<https://doi.org/10.1016/j.anifeedsci.2017.09.012>
- Choct, M. (2006). Enzymes for the feed industry: Past, present and future. *World's Poultry Science Journal*, 62(1), 5-16.
- Dibner, J. J., & Buttin, P. (2002). Use of organic acids as a model to study the impact of gut microflora on nutrition and metabolism. *Journal of Applied Poultry Research*, 11(4), 453-463.
- Gadde, U., Kim, W. H., Oh, S. T., & Lillehoj, H. S. (2017). Alternatives to antibiotics for maximizing growth performance and feed efficiency in poultry. *Animal Health Research Reviews*, 18(1), 26-45.
- Gibson, G. R., Hutkins, R., Sanders, M. E., Prescott, S. L., Reimer, R. A., Salminen, S. J., Scott, K., Stanton, C., Swanson, K. S., Cani, P. D., Verbeke, K., & Reid, G. (2017). The ISAPP consensus statement on the definition and scope of prebiotics. *Nature Reviews Gastroenterology & Hepatology*, 14, 491-502.
- Hill, C., Guarner, F., Reid, G., Gibson, G. R., Merenstein, D. J., Pot, B., Morelli, L., Canani, R. B., Flint, H. J., Salminen, S., Calder, P. C., & Sanders, M. E. (2014). Expert consensus document: The scope and appropriate use of the term probiotic. *Nature Reviews Gastroenterology & Hepatology*, 11, 506-514.
- Jha, R., & Berrocoso, J. D. (2015). Dietary fiber utilization and its effects on physiological functions and gut health of swine. *Animal*, 9(9), 1441-1452.
- Kogut, M. H., & Arsenault, R. J. (2016). Gut health: The new paradigm in food animal production. *Frontiers in Veterinary Science*, 3, 71.
- Krause, D. O., Bhandari, S. K., House, J. D., & Nyachoti, C. M. (2010). Response of gut microbial ecology to diets and antibiotics in swine. In *Sustainable swine nutrition*. Wiley-Blackwell.
- Lallès, J.-P., Bosi, P., Smidt, H., & Stokes, C. R. (2007). Nutritional management of gut health in pigs around weaning. *Proceedings of the Nutrition Society*, 66(2), 260-268.
- Makkar, H. P. S. (Ed.). (2012). *Biofuel co-products as livestock feed: Opportunities and challenges*. FAO.
- Oakley, B. B., Lillehoj, H. S., Kogut, M. H., Kim, W. K., Maurer, J. J., Pedrosa, A., Lee, M. D., Collett, S. R., Johnson, T. J., & Cox, N. A. (2014). The chicken gastrointestinal microbiome. *FEMS Microbiology Letters*, 360(2), 100-112.
- Pluske, J. R., Turpin, D. L., & Kim, J.-C. (2018). Gastrointestinal tract health and welfare in the young pig. *Animal Nutrition*, 4(2), 187-196.
- Ricke, S. C. (2003). Perspectives on the use of organic acids and short chain fatty acids as antimicrobials. *Poultry Science*, 82(4), 632-639.
- Rosen, G. D. (2007). Holo-analysis of the efficacy of Bio-Mos in broiler nutrition. *British Poultry Science*, 48(1), 21-26.
- Shurson, G. C. (2018). Yeast and yeast derivatives in feed additives and ingredients. *Animal Feed Science and Technology*, 235, 60-76.
- Stein, H. H., Sève, B., Fuller, M. F., Moughan, P. J., & de Lange, C. F. M. (2007). Invited review: Amino acid bioavailability and digestibility in pig feed ingredients. *Journal of Animal Science*, 85(1), 172-180.
- Van Immerseel, F., Russell, J. B., Flythe, M. D., Gantois, I., Timbermont, L., Pasmans, F., Haesebrouck, F., & Ducatelle, R. (2006). The use of organic acids to combat *Salmonella* in poultry. *Avian Pathology*, 35(3), 182-188.

VI. Tecnología de fabricación de piensos, NIRS, control de proceso y calidad

- AACC International. (2010). *Approved methods of analysis* (11th ed.). AACC International.
- American Feed Industry Association. (2014). *Feed manufacturing technology* (5th ed.). AFIA.
- AOAC International. (2019). *Official methods of analysis of AOAC International* (21st ed.). AOAC International.
- Baker, S., & Herrman, T. (2002). *Evaluating particle size*. Kansas State University Agricultural Experiment Station and Cooperative Extension Service.
- Cozzolino, D. (2015). The role of near-infrared sensors and spectroscopy in the feed and food industries. *Sensors*, 15(11), 28152-28162.
- Davies, A. M. C., & Williams, P. (Eds.). (1996). *Near infrared spectroscopy: The future waves*. NIR Publications.
- García-Ciudad, A., Ruano-Ramos, A., Becerro-Barco, A., & Zabalgoitia, I. (1999). NIR determination of feed quality parameters. *Journal of Near Infrared Spectroscopy*, 7, 145-154.
- Haughey, S. A., Galvin-King, P., Malechaux, A., & Elliott, C. T. (2015). The use of handheld near infrared reflectance spectroscopy for the proximate analysis of poultry feed. *Food Chemistry*, 183, 236-242.
- Jones, F. T. (2011). A review of practical *Salmonella* control measures in animal feed. *Journal of Applied Poultry Research*, 20(1), 102-113.
- Liu, K. (2009). Effects of particle size distribution, compositional and color properties of ground corn on quality of distillers dried grains with solubles. *Bioresource Technology*, 100(19), 4433-4440.

- Mertens, D. R. (2002). Gravimetric determination of amylase-treated neutral detergent fiber in feeds with refluxing in beakers or crucibles. *Journal of AOAC International*, 85(6), 1217-1240.
- Murray, I., & Cowe, I. A. (2004). Sample preparation. In C. A. Roberts, J. Workman, & J. B. Reeves (Eds.), *Near-infrared spectroscopy in agriculture*. ASA-CSSA-SSSA.
- Reeves, J. B. (2000). Use of near infrared reflectance spectroscopy. In D. Mello (Ed.), *Farm animal metabolism and nutrition*. CABI.
- Riaz, M. N. (2000). *Extruders in food applications*. CRC Press.
- Riaz, M. N. (2007). *Extruders and expanders in pet food, aquatic and livestock feeds*. Agrimedia.
- Thomas, M., van Zuilichem, D. J., & van der Poel, A. F. B. (1997). Physical quality of pelleted animal feed. 2. Contribution of processes and its conditions. *Animal Feed Science and Technology*, 64(2-4), 173-192.
- Williams, P., & Norris, K. (Eds.). (2001). *Near-infrared technology in the agricultural and food industries* (2nd ed.). American Association of Cereal Chemists.
- Workman, J., & Weyer, L. (2012). *Practical guide and spectral atlas for interpretive near-infrared spectroscopy* (2nd ed.). CRC Press.

VII. Micotoxinas, contaminantes y seguridad de los piensos

- Binder, E. M., Tan, L. M., Chin, L. J., Handl, J., & Richard, J. (2007). Worldwide occurrence of mycotoxins in commodities, feeds and feed ingredients. *Animal Feed Science and Technology*, 137(3-4), 265-282.
- Bryden, W. L. (2012). Mycotoxin contamination of the feed supply chain. *Animal Feed Science and Technology*, 173(1-2), 134-158.
- CAST. (2003). *Mycotoxins: Risks in plant, animal, and human systems*. Council for Agricultural Science and Technology.
- European Food Safety Authority. (2004-2025). *Scientific opinions and statements on contaminants, undesirable substances and mycotoxins in animal feed*. EFSA Journal.
- Grenier, B., & Applegate, T. J. (2013). Modulation of intestinal functions following mycotoxin ingestion. *Animal Feed Science and Technology*, 182(1-4), 1-15.
- Kabak, B., Dobson, A. D. W., & Var, I. (2006). Strategies to prevent mycotoxin contamination of food and animal feed. *Critical Reviews in Food Science and Nutrition*, 46(8), 593-619.
- Krska, R., Schubert-Ullrich, P., Molinelli, A., Sulyok, M., MacDonald, S., & Crews, C. (2008). Mycotoxin analysis: An update. *Food Additives & Contaminants: Part A*, 25(2), 152-163.
- Magnoli, A. P., Poloni, V. L., & Cavaglieri, L. (2019). Impact of mycotoxin contamination in the animal feed industry. *Current Opinion in Food Science*, 29, 99-108.
- Rodrigues, I., & Naehrer, K. (2012). A three-year survey on the worldwide occurrence of mycotoxins in feedstuffs and feed. *Toxins*, 4(9), 663-675.
- Streit, E., Schatzmayr, G., Tassis, P., Tzika, E., Marin, D., Taranu, I., Tabuc, C., Nicolau, A., Aprodu, I., Puel, O., & Oswald, I. P. (2012). Current situation of mycotoxin contamination and co-occurrence in animal feed. *Animal Feed Science and Technology*, 178(3-4), 213-228.
- Vila-Donat, P., Marín, S., Sanchis, V., & Ramos, A. J. (2018). A review of the mycotoxin adsorbing agents, with an emphasis on their multi-binding capacity. *Food and Chemical Toxicology*, 114, 246-259.
- World Health Organization. (2018). *Mycotoxins*. WHO Food Safety Digest.

VIII. Sostenibilidad, evaluación ambiental y eficiencia de recursos

- de Vries, M., & de Boer, I. J. M. (2010). Comparing environmental impacts for livestock products: A review of life cycle assessments. *Livestock Science*, 128(1-3), 1-11.
- FAO. (2006). *Livestock's long shadow: Environmental issues and options*. Food and Agriculture Organization of the United Nations.
- FAO. (2013). *Tackling climate change through livestock: A global assessment of emissions and mitigation opportunities*. Food and Agriculture Organization of the United Nations.
- FAO. (2018). *World livestock: Transforming the livestock sector through the Sustainable Development Goals*. Food and Agriculture Organization of the United Nations.
- FAO. (2023). *Pathways towards lower emissions: A global assessment of the greenhouse gas emissions and mitigation options from livestock agrifood systems*. Food and Agriculture Organization of the United Nations.
- Gerber, P. J., Steinfeld, H., Henderson, B., Mottet, A., Opio, C., Dijkman, J., Falcucci, A., & Tempio, G. (2013). *Tackling climate change through livestock*. FAO.
- Herrero, M., Henderson, B., Havlík, P., Thornton, P. K., Conant, R. T., Smith, P., Wierseni, S., Hristov, A. N., Gerber, P., Gill, M., Butterbach-Bahl, K., Valin, H., Garnett, T., & Stehfest, E. (2016). Greenhouse gas mitigation potentials in the livestock sector. *Nature Climate Change*, 6, 452-461.
- ISO. (2006). *ISO 14040:2006 Environmental management - Life cycle assessment - Principles and framework*. International Organization for Standardization.

- ISO. (2006). ISO 14044:2006 Environmental management - Life cycle assessment - Requirements and guidelines. International Organization for Standardization.
- LEAP Partnership. (2016). Environmental performance of animal feeds supply chains: Guidelines for assessment. FAO.
- Mottet, A., de Haan, C., Falcucci, A., Tempio, G., Opio, C., & Gerber, P. (2017). Livestock: On our plates or eating at our table? A new analysis of the feed/food debate. *Global Food Security*, 14, 1-8.
- Poore, J., & Nemecek, T. (2018). Reducing food's environmental impacts through producers and consumers. *Science*, 360(6392), 987-992. <https://doi.org/10.1126/science.aag0216>
- Rotz, C. A. (2020). Environmental sustainability of livestock production. *Meat and Muscle Biology*, 4(2), 1-18.
- Steinfeld, H., Gerber, P., Wassenaar, T., Castel, V., Rosales, M., & de Haan, C. (2006). Livestock's long shadow. FAO.
- Thornton, P. K. (2010). Livestock production: Recent trends, future prospects. *Philosophical Transactions of the Royal Society B*, 365(1554), 2853-2867.

IX. Estadística, diseño experimental, causalidad y validación

- Altman, D. G. (1991). *Practical statistics for medical research*. Chapman & Hall.
- Bland, J. M., & Altman, D. G. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, 327(8476), 307-310.
- Box, G. E. P., Hunter, J. S., & Hunter, W. G. (2005). *Statistics for experimenters* (2nd ed.). Wiley.
- Cochran, W. G. (1977). *Sampling techniques* (3rd ed.). Wiley.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Routledge.
- Harrell, F. E. (2015). *Regression modeling strategies* (2nd ed.). Springer.
- Hernán, M. A., & Robins, J. M. (2020). *Causal inference: What if*. Chapman & Hall/CRC.
- Kuhn, M., & Johnson, K. (2019). *Feature engineering and selection*. CRC Press.
- Montgomery, D. C. (2019). *Design and analysis of experiments* (10th ed.). Wiley.
- Moons, K. G. M., Altman, D. G., Reitsma, J. B., Ioannidis, J. P. A., Macaskill, P., Steyerberg, E. W., Vickers, A. J., Ransohoff, D. F., & Collins, G. S. (2015). Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis: TRIPOD statement. *Annals of Internal Medicine*, 162(1), 55-63.
- Riley, R. D., van der Windt, D., Croft, P., & Moons, K. G. M. (Eds.). (2019). *Prognosis research in healthcare*. Oxford University Press.
- Steyerberg, E. W. (2019). *Clinical prediction models* (2nd ed.). Springer.
- Vickers, A. J., & Elkin, E. B. (2006). Decision curve analysis: A novel method for evaluating prediction models. *Medical Decision Making*, 26(6), 565-574.
- Wasserstein, R. L., & Lazar, N. A. (2016). The ASA statement on p-values. *The American Statistician*, 70(2), 129-133.

X. Gobernanza de la IA, gestión de riesgos, calidad de datos y ciberseguridad

- European Commission High-Level Expert Group on Artificial Intelligence. (2019). *Ethics guidelines for trustworthy AI*. European Commission.
- European Commission High-Level Expert Group on Artificial Intelligence. (2020). *Assessment list for trustworthy artificial intelligence*. European Commission.
- ISO. (2018). ISO 19011:2018 Guidelines for auditing management systems. International Organization for Standardization.
- ISO. (2018). ISO 31000:2018 Risk management - Guidelines. International Organization for Standardization.
- ISO. (2019). ISO/IEC 27001:2022 Information security, cybersecurity and privacy protection - Information security management systems - Requirements. International Organization for Standardization.
- ISO. (2023). ISO/IEC 23894:2023 Information technology - Artificial intelligence - Guidance on risk management. International Organization for Standardization.
- ISO. (2023). ISO/IEC 42001:2023 Information technology - Artificial intelligence - Management system. International Organization for Standardization.
- ISO/IEC. (2020). ISO/IEC 22989:2022 Information technology - Artificial intelligence - Artificial intelligence concepts and terminology. International Organization for Standardization.
- ISO/IEC. (2022). ISO/IEC 23053:2022 Framework for artificial intelligence systems using machine learning. International Organization for Standardization.
- ISO/IEC. (2023). ISO/IEC 5259 series: Artificial intelligence - Data quality for analytics and machine learning. International Organization for Standardization.
- National Institute of Standards and Technology. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)*. U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>
- National Institute of Standards and Technology. (2024). *Artificial intelligence risk management framework: Generative artificial intelligence profile*. U.S. Department of Commerce.
- OECD. (2019). *Recommendation of the Council on Artificial Intelligence*. Organisation for Economic Co-operation and Development.

OECD. (2023). Advancing accountability in AI: Governing and managing risks throughout the lifecycle for trustworthy AI. OECD Publishing.

UNESCO. (2021). Recommendation on the ethics of artificial intelligence. UNESCO.

XI. Seguridad alimentaria, legislación de piensos y regulación europea

Codex Alimentarius Commission. (2004). Code of practice on good animal feeding (CXC 54-2004). FAO/WHO.

European Commission. (2006). Commission Recommendation 2006/576/EC on the presence of deoxynivalenol, zearalenone, ochratoxin A, T-2 and HT-2 and fumonisins in products intended for animal feeding.

European Commission. (2011). Commission Regulation (EU) No 575/2011 on the Catalogue of feed materials.

European Commission. (2013). Commission Regulation (EU) No 68/2013 on the Catalogue of feed materials.

European Commission. (2024). Regulation (EU) 2024/1689 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Official Journal of the European Union.

European Food Safety Authority. (2017). Guidance on the assessment of the safety of feed additives for the target species. EFSA Journal, 15(10), 5021.

European Food Safety Authority. (2017). Guidance on the identity, characterisation and conditions of use of feed additives. EFSA Journal, 15(10), 5023.

European Food Safety Authority. (2018). Guidance on the characterisation of microorganisms used as feed additives or as production organisms. EFSA Journal, 16(3), 5206.

European Food Safety Authority. (2021). Guidance on the renewal of the authorisation of feed additives. EFSA Journal, 19(10), 6340.

European Food Safety Authority. (2022). Artificial intelligence in risk assessment. EFSA Journal.

European Food Safety Authority. (2025). AI@EFSA: Artificial intelligence for evidence management and risk assessment. EFSA.

European Parliament and Council. (2002). Regulation (EC) No 178/2002 laying down the general principles and requirements of food law. Official Journal of the European Communities.

European Parliament and Council. (2003). Regulation (EC) No 1831/2003 on additives for use in animal nutrition. Official Journal of the European Union.

European Parliament and Council. (2005). Regulation (EC) No 1831/2005 laying down requirements for feed hygiene. Official Journal of the European Union.

European Parliament and Council. (2009). Regulation (EC) No 767/2009 on the placing on the market and use of feed. Official Journal of the European Union.

European Parliament and Council. (2016). Regulation (EU) 2016/429 on transmissible animal diseases. Official Journal of the European Union.

European Parliament and Council. (2016). Regulation (EU) 2016/679 on the protection of natural persons with regard to the processing of personal data. Official Journal of the European Union.

European Parliament and Council. (2017). Regulation (EU) 2017/625 on official controls and other official activities. Official Journal of the European Union.

European Parliament and Council. (2022). Regulation (EU) 2022/2065 on a Single Market for Digital Services. Official Journal of the European Union.

European Parliament and Council. (2024). Directive (EU) 2024/2853 on liability for defective products. Official Journal of the European Union.

European Union. (2002). Directive 2002/32/EC on undesirable substances in animal feed. Official Journal of the European Communities.

European Union. (2009). Regulation (EC) No 1069/2009 laying down health rules as regards animal by-products and derived products not intended for human consumption. Official Journal of the European Union.

European Union. (2011). Regulation (EU) No 142/2011 implementing Regulation (EC) No 1069/2009. Official Journal of the European Union.

FAO & IFIF. (2010). Good practices for the feed industry: Implementing the Codex Alimentarius Code of Practice on Good Animal Feeding. FAO Animal Production and Health Manual No. 9.

FAO & WHO. (2008). Animal feed impact on food safety: Report of the FAO/WHO Expert Meeting. FAO.

International Feed Industry Federation. (2020). Feed manual of good practices. IFIF.

ISO. (2015). ISO 9001:2015 Quality management systems - Requirements. International Organization for Standardization.

ISO. (2018). ISO 22000:2018 Food safety management systems - Requirements for any organization in the food chain. International Organization for Standardization.

XII. Innovación, adopción tecnológica, economía y transformación organizativa

Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. MIS Quarterly, 13(3), 319-340.

- Deloitte. (2024). State of AI in the enterprise. Deloitte Insights.
- Klerkx, L., & Rose, D. (2020). Dealing with the game-changing technologies of agriculture 4.0. *Global Food Security*, 24, 100347.
- Porter, M. E. (1985). *Competitive advantage*. Free Press.
- Porter, M. E., & Heppelmann, J. E. (2014). How smart, connected products are transforming competition. *Harvard Business Review*, 92(11), 64-88.
- Rogers, E. M. (2003). *Diffusion of innovations* (5th ed.). Free Press.
- Teece, D. J. (2007). Explicating dynamic capabilities. *Strategic Management Journal*, 28(13), 1319-1350.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478.
- Westerman, G., Bonnet, D., & McAfee, A. (2014). *Leading digital*. Harvard Business Review Press.