



Cómo Elegir el Algoritmo Correcto

La Guía Definitiva: Una cartografía para la toma de decisiones tecnológicas




Elaborado por: Dr. Juan I. Barrios A.
Barcelona 2026 – Ingeniería Biomédica -UB

El punto de partida: Define el mundo, no la técnica




Mensaje Claro: La pregunta que más tiempo ahorra no es '¿qué algoritmo está de moda?' sino '¿qué forma tiene la salida que necesito?'.

La Gran División: Mundo Cerrado vs. Mundo Abierto



Predictiva. Respuestas finitas.
Verificable automáticamente (ej. Número, Clase).



Generativa. Secuencias infinitas.
Exige rúbrica o juicio humano (ej. Texto, Imagen).

Mensaje Claro: Si puedes verificar la respuesta contra una fórmula o etiqueta histórica, estás en el mundo cerrado. Si la respuesta es algo nuevo, estás en el mundo abierto.

Taxonomía del aprendizaje automático (Machine Learning)

APRENDIZAJE AUTOMÁTICO CLÁSICO

Criterio: Datos simples, estructurados y categorías bien definidas

1. Aprendizaje Supervisado



2. Aprendizaje No Supervisado



APRENDIZAJE AUTOMÁTICO MODERNO

1. Redes Neuronales, Deep Learning e IA Generativa

Datos complejos con las categorías mal definidas




2. Aprendizaje por Refuerzo

No hay datos suficientes, pero tenemos un ambiente para interactuar



3. Métodos Ensamble / De Conjunto

Cuando la calidad de los datos es un problema



4. IA Agéntica y Agentes Inteligentes

Autonomía, razonamiento, planificación y ejecución de herramientas




5. Series Temporales

Análisis de secuencias y dependencias temporales




6. Modelos de Frontera e Híbridos

Modelos físicos (PINNs), neuro-simbólicos y fronteras emergentes



Taxonomía del aprendizaje automático clásico

Un árbol de decisión basado en la naturaleza y clasificación de los datos.



Taxonomía del aprendizaje automático moderno

El aprendizaje automático moderno se fundamenta en tres grandes familias conceptuales: Redes Neuronales y Aprendizaje Profundo, Aprendizaje por Refuerzo y Métodos de Ensamble. Cada una aborda la resolución de problemas mediante arquitecturas específicas adaptadas al tipo de datos e interacción requerida.



Métodos estadísticos que compiten con el Aprendizaje automático

Método de Kaplan-Meier

Análisis de Supervivencia Paso a Paso



Modelo de Riesgos Proporcionales de Cox

Evaluación de Factores de Riesgo y Cociente de Riesgo

El **modelo de Cox** evalúa el impacto de múltiples variables (edad, tratamiento, comorbilidades) sobre el riesgo de que ocurra un evento. El **Hazard Ratio (HR)** compara el riesgo entre grupos.

- $HR = 1$: Sin diferencia de riesgo.
- $HR > 1$: Mayor riesgo en el grupo de estudio.
- $HR < 1$: Menor riesgo (efecto protector).




Algoritmos y métodos estadísticos para el análisis de serie de tiempo

1. Familias Clásicas y Estadísticas



ARIMA



ETS



Prophet


Modelos: ARIMA, ETS, Prophet.

Casos: Tendencias claras, estacionalidad, datos históricos limitados.


Ventajas: Interpretables, rápidos, menos datos.

Limitaciones: Menos precisos en relaciones complejas o no lineales.


2. Redes Neuronales (Deep Learning)



RNN



LSTM



Transformers


Modelos: RNN, LSTM, Transformers.

Casos: Secuencias largas, dependencias complejas a largo plazo, grandes volúmenes de datos.


Ventajas: Capturan patrones no lineales profundos.

Limitaciones: Requieren muchos datos y cómputo, cómputo, "caja negra".

3. Modelos de Ensamble



XGBoost




LightGBM

Modelos: XGBoost, LightGBM (Regressor).

Casos: Series tabulares, alta precisión, no linealidades, ingeniería de características potente.

Ventajas: Alta precisión, robustos a ruido.

Limitaciones: Riesgo de sobreajuste, requieren buen preprocesamiento.



Cuidados y Limitaciones

Validación Crítica: Rolling-origin (ventana rodante) es esencial para evitar fugas de datos futuras.

Precauciones: Estacionariedad de los datos, tratamiento de valores faltantes, evitar "data leakage".

Cada familia tiene sus propias asunciones a verificar.


Mensaje Claro: Selecciona la arquitectura según la complejidad de la serie y la cantidad de datos, y siempre valida con técnicas robustas como *rolling-origin*.

Las redes neuronales y deep learning: puente con la inteligencia artificial generativa


El **Deep Learning** actúa como la **infraestructura** y el **puente fundamental** desde el **aprendizaje automático** hacia la **Inteligencia Artificial Generativa**. Sus distintas familias de arquitecturas están optimizadas según la estructura específica del dato de entrada (tabulares, imágenes, secuencias o espacios latentes).

Arquitecturas Base, Procesamiento Espacial y Compresión

Perceptrón Multicapa (MLP) - Redes Densas




Diseñado para datos tabulares estructurados y relaciones lineales básicas.




Ejemplo: Tablas de datos estructurados (e.g., bases de datos de clientes, hojas de cálculo financiero).

Redes Convolucionales (CNN)




Especializadas en matrices 2D e imágenes (e.g., radiografías clínicas y control de calidad industrial).




Ejemplo: Análisis de imágenes médicas, detección de objetos en visión artificial.

Autoencoders




Orientados a la compresión de datos y detección de anomalías en espacio latente.



Ejemplo: Reducción de ruido, aprendizaje de representaciones eficientes para detección de anomalías.

Arquitecturas de Secuencia y Modelos Generativos

Transformers (Redes de Atención)



Estándar para secuencias complejas (texto, ADN, código) y motor central de los LLMs en IA Generativa.




Ejemplo: Modelos de lenguaje grande (LLMs), generación de código y traducción automática.

Redes Adversas Generativas (GAN)



Generador **Discriminador**

Basadas en Generador y Discriminador para sintetizar datos realistas ante la falta de muestras de entrenamiento.



Real **Generado**


Ejemplo: Creación de arte digital, síntesis de rostros realistas, mejora de imágenes.

Entornos Dinámicos: Aprendizaje por Refuerzo y Evolutivo



Requiere un entorno interactivo (real o simulado), no solo datos estáticos históricos.
Ej: Robótica, Trading.


Transferencia Sim2Real: Entrenamiento seguro en simulación antes del mundo físico. (Ej. Robótica quirúrgica).



Computación Evolutiva: Algoritmos genéticos para optimización combinatoria gigante.


Mensaje Claro: Si solo tienes datos históricos estáticos sin posibilidad de interactuar y recibir feedback, usa aprendizaje supervisado, no refuerzo.

Familia III - IA Generativa y La Escalera de Intervención



Inteligencia Agéntica: 6 Arquitecturas Topológicas


Agente Único (ReAct)



Explicación: Agente que razona y actúa de forma iterativa. Genera pensamientos, selecciona herramientas, y luego observa los resultados para informar la siguiente acción.

Ejemplos: Asistente personal que reserva vuelos, busca información y la resume, resuelve problemas matemáticos paso a paso.


Multiagente



Explicación: Múltiples agentes especializados colaboran para resolver tareas complejas. Cada agente tiene un rol definido y se comunican entre sí.

Ejemplos: Equipo de desarrollo de software (codificador, tester, revisor), simulación de mercado con compradores y vendedores, debate entre expertos.

RAG Agéntico



Explicación: Agente que utiliza Recuperación Aumentada por Generación. Busca información relevante en una base de conocimientos externa antes de generar una respuesta.

Ejemplos: Chatbot de soporte técnico que consulta manuales, analista financiero que busca en informes de la empresa, asistente legal que revisa jurisprudencia.


Plan-Act-Reflect



Explicación: Ciclo de mejora continua. El agente crea un plan, lo ejecuta, y luego reflexiona sobre el resultado para aprender y ajustar planes futuros.

Ejemplos: Robot de navegación que aprende de sus errores, sistema de tutoría que adapta su estrategia de enseñanza, agente de diseño que itera sobre prototipos.


Orquestación



Explicación: Un agente "orquestador" central coordina a otros agentes o herramientas especializadas, delegando tareas según la necesidad.

Ejemplos: Sistema de domótica que controla dispositivos, plataforma de servicios que enruta peticiones a la API correcta, gerente de proyecto de IA.

Memoria a Largo Plazo




Explicación: Agente con capacidad de almacenar y recuperar información de interacciones pasadas, permitiendo un contexto persistente y aprendizaje continuo.

Ejemplos: Compañero de IA que recuerda preferencias, sistema de recomendación que evoluciona con el historial, NPC en un juego con memoria.

Algoritmos de frontera o emergentes y modelos híbridos

IA Neuro-Simbólica

Arquitectura



Características Principales

Combina el aprendizaje profundo (reconocimiento de patrones) con sistemas basados en reglas (razonamiento lógico). Explica sus decisiones.

Ejemplos


Diagnóstico médico con justificación, sistemas legales, sistemas de QA complejos.

Limitaciones

Costo computacional alto, difícil integración de los dos paradigmas.

IA Híbrida

Arquitectura



Características Principales

Orquesta múltiples paradigmas para abordar problemas complejos. Es modular, flexible y se adapta al problema.

Ejemplos


Robótica autónoma, planificación logística, sistemas de recomendación avanzados.

Limitaciones

Complejidad de diseño e integración, requiere expertise en múltiples áreas.

IA Cognitiva

Arquitectura



Características Principales

Imita el funcionamiento del cerebro humano. Se enfoca en la comprensión, el aprendizaje y la toma de decisiones adaptativa.

Ejemplos


Agentes conversacionales avanzados, sistemas de soporte a la decisión en tiempo real.

Limitaciones

Aún en desarrollo, requiere grandes cantidades de datos de contexto, difícil de escalar.

IA Cuántica

Arquitectura



Características Principales

Utiliza principios de mecánica cuántica (superposición, entrelazamiento) para realizar cálculos masivos. Ofrece velocidad exponencial potencial.

Ejemplos


Optimización de carteras, descubrimiento de fármacos, criptografía, ciencia de materiales.

Limitaciones


Hardware inestable, decoherencia, requiere algoritmos especializados.

Mensaje Claro: Estas arquitecturas representan la vanguardia de la IA, cada una aborda desafíos específicos donde los métodos tradicionales fallan. Su adopción requiere una comprensión profunda de sus fortalezas y limitaciones.

La Síntesis: El Árbol Decisorio Operativo



Para concluir



Gracias por su atención. Quedo a su disposición para preguntas y análisis de casos.

Te atreves a resolver estas 10 incógnitas ?

Predicción de Ventas Trimestrales

Escenario: ¿Cuánto venderemos el próximo trimestre?



Algoritmo Ideal: **Regresión Lineal** (interpretabilidad) o **Gradient Boosting** (precisión)

Alternativas: Ridge/Lasso para variables correlacionadas.

Clasificación de Abandono de Clientes

Escenario: ¿Qué clientes se darán de baja?



Algoritmo Ideal: **Regresión Logística** (explicabilidad)

Alternativas: XGBoost o Random Forest para relaciones complejas.

Segmentación de Mercado

Escenario: Agrupar clientes sin etiquetas previas



Algoritmo Ideal: **K-Means** (si se sabe el número de grupos)

Alternativas: DBSCAN para ruido o Clustering Jerárquico para genealogía.

Detección de Fraude en Transacciones

Escenario: Identificar operaciones sospechosas nunca vistas




Algoritmo Ideal: **Isolation Forest** (Detección de Anomalías)

Alternativas: Reglas de umbral simple como baseline.

Priorización de Tickets de Soporte

Escenario: Ordenar la cola de atención con recursos limitados




Algoritmo Ideal: **Modelo de Ranking** (Gradient Boosting + Optimizador)

Alternativas: Orden de llegada como baseline.

Mantenimiento Predictivo de Maquinaria

Escenario: ¿Cuándo fallará esta pieza?



Resumen de Métricas y Baselines

Métrica	Baseline
MAE/RMSE	Promedio Móvil
Precisión/Recall	Modelo de Reglas
Silüeta/DBSCAN	Aleatorio
F1-Score	Umbral Simple
NDCG	Aleatorio
MSE	Regresión Lineal
Recompensa Acumulada	Aleatorio
Accuracy	Clasificador Simple
BLEU	Modelo de Base
Distancia Total	Ruta Directa

Personalización de Ofertas en Tiempo Real

Escenario: Un sistema que aprende de la interacción del usuario




Algoritmo Ideal: **Aprendizaje por Refuerzo**

Alternativas: Clasificación estática si solo hay datos históricos.

Control de Calidad por Imagen

Escenario: Detectar defectos visuales en una línea de montaje



Algoritmo Ideal: **Red Convolutiva (CNN)**

Alternativas: Autoencoders para detectar anomalías.

Asistente de Documentación Técnica

Escenario: Responder dudas sobre manuales internos de la empresa




Arquitectura Ideal: **RAG (Generación Aumentada por Recuperación)**

Alternativas: Prompt directo para info pública.

Optimización de Rutas Logísticas

Escenario: Encontrar el camino más eficiente entre mil puntos



Algoritmo Ideal: **Algoritmos Genéticos** (Computación Evolutiva)

Alternativas: Métodos de gradiente para espacio continuo.


Algoritmos del Aprendizaje Automático Clásico

El catálogo de herramientas estadísticas fundamentales.



Algoritmos del Aprendizaje Automático Moderno

La frontera de la complejidad: Conjuntos, Refuerzo y Aprendizaje Profundo.



¡Muchas gracias!



Website: www.juanbarrios.com



Email: juan@juanbarrios.com



LinkedIn: <https://www.linkedin.com/in/bcnbigdata/>