



Fondo Europeo de Desarrollo Regional
"Una manera de hacer Europa"

Webinar: Casos prácticos de empresas basadas en Inteligencia Artificial

Ciclo de webinars sobre Inteligencia Artificial

Webinar 1:

Oportunidades de negocio que ofrece la Inteligencia Artificial

Online | 16 septiembre 2022 | 11:00 - 11:30 h.

(Gratis y acceso libre)

Webinar 2:

Proyectos de Inteligencia Artificial

Online | 28 octubre 2022 | 11:00 - 11:30 h.

(Gratis y acceso libre)

Webinar 3:

Casos prácticos de empresas basadas en Inteligencia Artificial

Online | 25 noviembre 2022 | 11:00 - 11:30 h.

(Gratis y acceso libre)





Objetivo:
**TRANSFORMACIÓN DIGITAL
DE TU EMPRESA**

Duración

2 años (hasta septiembre de 2023)

Objetivo

Ir de la mano de la pyme y autónomos para ayudarles en su transformación digital.

Beneficiarios

Pymes y autónomos. Multisectorial.

Líneas de actuación

de la Oficina de transformación

digital "Acelera Pyme"

Gratuito y acceso libre



JORNADAS DIVULGATIVAS EN TRANSFORMACIÓN DIGITAL

SERVICIO DE ASESORAMIENTO Y SOPORTE DIGITAL

SESIONES DE EMPRENDIMIENTO DIGITAL

VISITAS A EMPRESAS Y HABILITADORES TECNOLÓGICOS

VÍDEO PÍLDORAS TECNOLÓGICAS

FORO DE TRANSFORMACIÓN DIGITAL



Puedes participar en todas las acciones a través de la web WWW.OTDASTURIAS.ES

Dudas, preguntas => chat



Miguel Ángel Román

- Ingeniero de Telecomunicaciones, Ingeniero de Informática y Doctor en Inteligencia Artificial.
- Co-Fundador del Instituto de Inteligencia Artificial.
- Ha dirigido centros de I+D para grandes empresas.



Casos prácticos de empresas basadas en Inteligencia Artificial

Programa:

- Conocer la aplicación real de modelos de Inteligencia Artificial.
- Análisis de casos prácticos.
- Mejores prácticas.





Sede del COIIAS (Oviedo)



Página web

www.otdasturias.es



RRSS

LinkedIn/Twitter/Fb/Instagram @coiias



Correo electrónico

otd@coiias.es

Suscribirse al boletín



Oficina de Transformación Digital “Acelera Pyme”



INGENIEROS
INDUSTRIALES
PRINCIPADO DE ASTURIAS



red.es



UNIÓN EUROPEA

Fondo Europeo de Desarrollo Regional

“Una manera de hacer Europa”



INGENIEROS
INDUSTRIALES
COLEGIO OFICIAL PRINCIPADO DE ASTURIAS

Fondo Europeo de Desarrollo Regional
"Una manera de hacer Europa"

¡Gracias por Vuestra
Atención!



GOBIERNO
DE ESPAÑA

VICEPRESIDENCIA
PRIMERA DEL GOBIERNO
MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL

red.es



UNIÓN EUROPEA

OFICINA
Acelera
pyme

Oficina de
Transformación Digital
"Acelera Pyme" del
COIIAS

OFICINA
Acelera



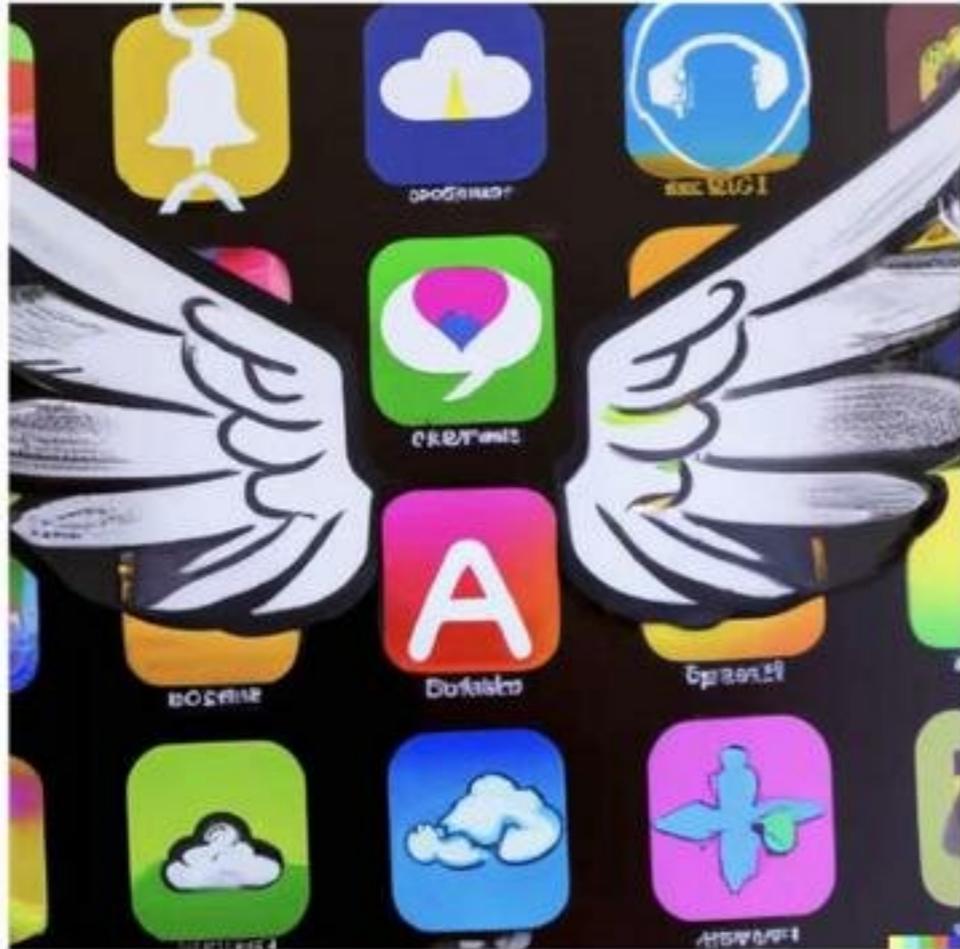
INGENIEROS
INDUSTRIALES

Casos Prácticos de Inteligencia Artificial

Miguel A. Román
Co-fundador IIA

25 de noviembre de 2022





“La Inteligencia Artificial es el Red Bull del Software”

La IA te da alas.

Ingredientes de la IA



TALENTO



DATOS



CAPACIDAD DE CÓMPUTO



INFRAESTRUCTURA

Ciclo de Vida - Software 2.0



¿Cuándo usar ML?



¿Cuándo usar ML?

- ▶ Cuando el problema consiste en encontrar patrones complejos a partir de datos
- ▶ Cuando esos patrones no se pueden modelar mediante simples fórmulas o reglas conocidas
- ▶ Cuando tenemos suficientes datos que representan esos patrones
- ▶ Cuando a partir de los datos de entrenamiento se puede generalizar a otros datos nunca vistos
- ▶ Cuando se puede tolerar cierto error en los resultados



¿Qué aplicaciones de ML “funcionan” hoy?

APPROVED

¿Qué aplicaciones de ML “funcionan” hoy?

- ▶ Aprendizaje supervisado (datos etiquetados):
 - ▶ Predecir datos tabulares y series temporales
 - ▶ Clasificar datos tabulares, imágenes, audio, texto, etc.
 - ▶ Detectar objetos y pose en imágenes
 - ▶ Pasar de audio a texto y de texto a audio
 - ▶ Traducir texto entre idiomas*
 - ▶ Crear un chatbot en un entorno acotado
- ▶ Aprendizaje no supervisado (no hay que etiquetar datos):
 - ▶ Detectar anomalías, hacer clustering y reducir la dimensionalidad de datos
 - ▶ Generar recomendaciones “buenas” en general
 - ▶ Reconocer caras, imágenes similares o palabras cercanas según un corpus
 - ▶ Generar imágenes (deepfakes, transferencia de estilo, colorización, superresolución, ...) y texto (GPT-3)
- ▶ Aprendizaje por refuerzo (con simulador de escenario):
 - ▶ Juegos y asimilados

APPROVED

Machine Learning en Producción

Machine Learning en Producción

Esperado:

1. Adquirir datos
2. Entrenar modelo
3. Desplegar modelo



Fuente: cs329s.stanford.edu | Chip Huyen

Machine Learning en Producción

Esperado:

1. Adquirir datos
2. Entrenar modelo
3. Desplegar modelo



Fuente: cs329s.stanford.edu | Chip Huyen

Realidad:

1. Elegir métrica a optimizar
2. Adquirir datos
3. Entrenar modelo
4. Los datos tienen errores, limpiar datos
5. Reentrenar modelo
6. Los datos son insuficientes, adquirir más datos
7. Reentrenar modelo
8. Desplegar modelo
9. El modelo falla en producción con datos nuevos
10. Adquirir más datos
11. Reentrenar modelo
12. Desplegar modelo
13. El modelo funciona, las métricas de negocio empeoran
14. Volver al punto 1

Machine Learning en Producción

- ¿Por qué es tan difícil pasar del artículo científico (paper) a la realidad?

	Investigación	Producción
Objetivo	Métricas de evaluación	Métricas de negocio
Datos	Fijos, públicos	Cambiantes, privados
Prioridad	Entrenamiento	Inferencia
Sesgos	Opcional	Crítico
Interpretabilidad	Opcional	Importante
MLOps	Accesorio	Fundamental

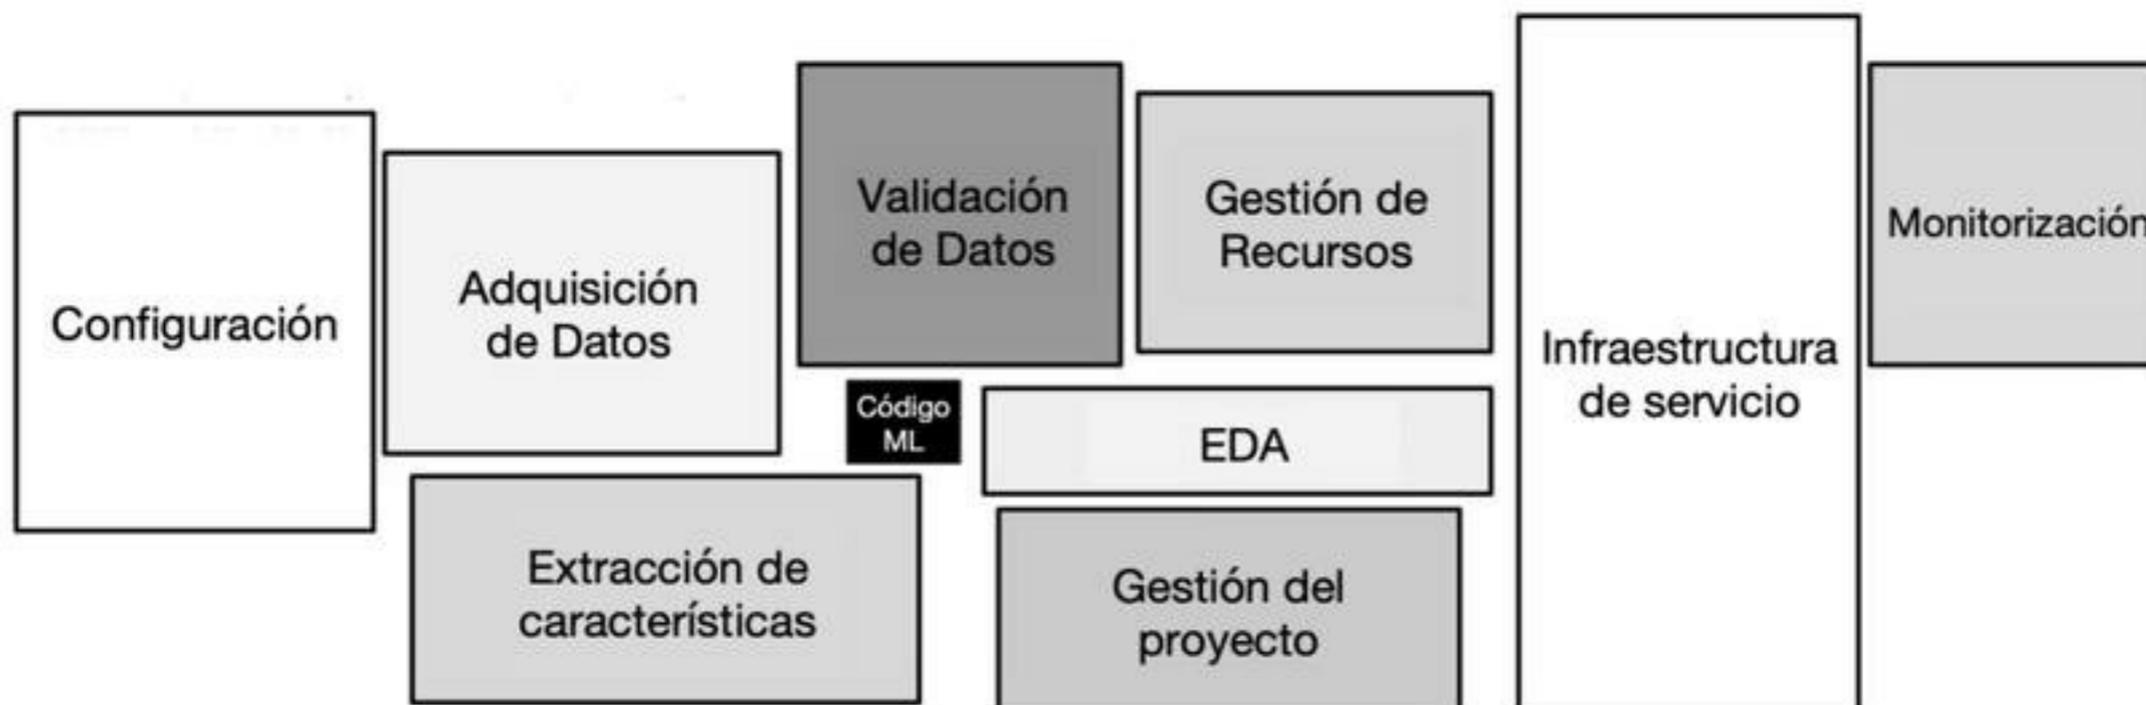
Gestión de los Datos

- ▶ 80% del esfuerzo total: adquisición, preparación y visualización (EDA)
- ▶ Adquirir más datos siempre ayuda, aumentar datos como segunda opción, y generar datos sintéticos como tercera opción
- ▶ El versionado de datos es igual de importante que el versionado de código para reproducir experimentos:
 - ▶ Nivel 1: cada experimento tiene una copia de los datos utilizados
 - ▶ Nivel 2: cada experimento tiene un fichero de metadatos que apunta a los ficheros de datos utilizados
 - ▶ Nivel 3: herramienta específica de versionado de conjuntos de datos
- ▶ Si tenemos pocas etiquetas → aprendizaje semi-supervisado
- ▶ Si tenemos problemas de privacidad → aprendizaje federado



Deuda Técnica

- Definición: esfuerzo de desarrollo que se deja para más adelante con el fin de llegar antes al mercado
- Se encuentra principalmente en datos e infraestructura (no en el código de los modelos) → MLOps



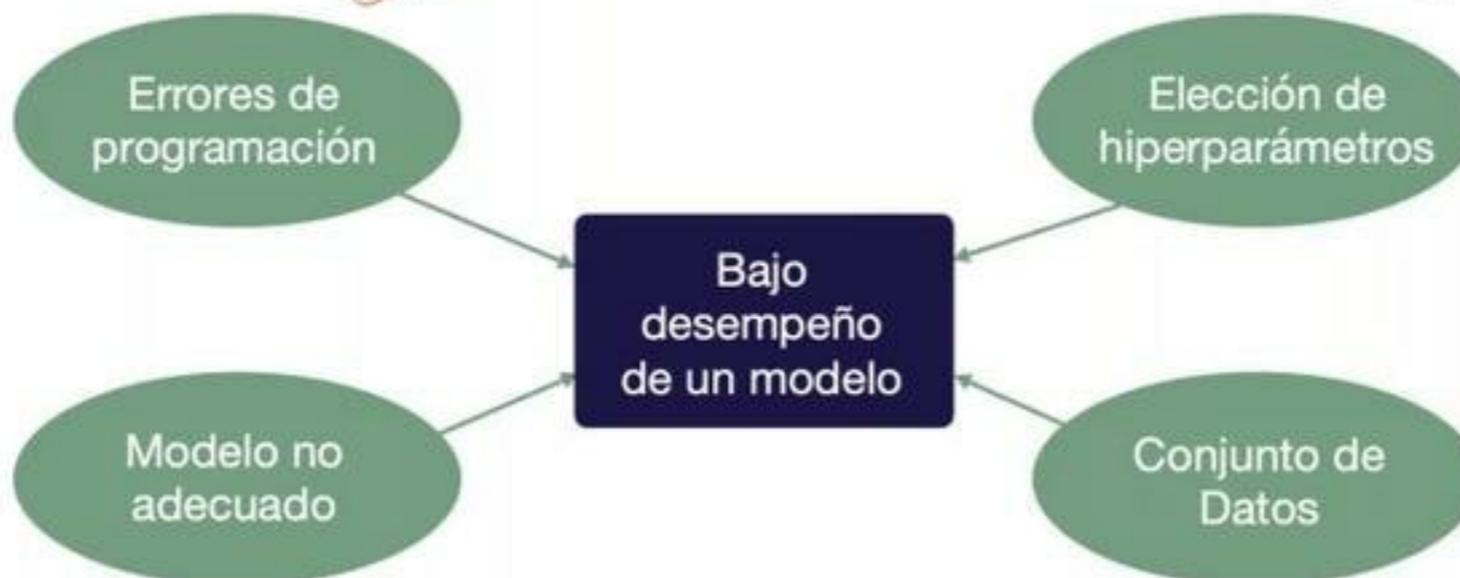
Fuente: <https://research.google/pubs/pub43146/>

Entrenamiento y Evaluación

Utilizar librerías probadas
Vigilar inestabilidad numérica
Sobreajustar el mismo lote

*¡Fallos
Silenciosos!*

Empezar con valores por defecto
Comparar con artículos científicos
para problemas similares



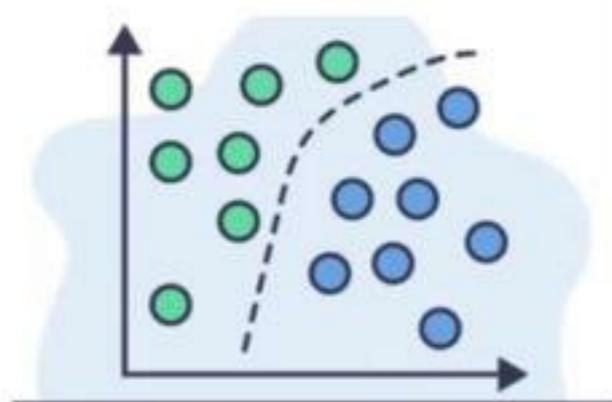
Empezar con el modelo más simple posible
Utilizar modelos predefinidos

Entrenar con un subconjunto
pequeño y medir convergencia
Realizar un EDA riguroso

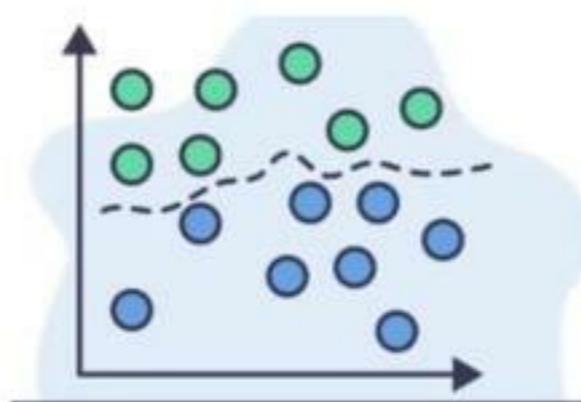
Fuente: <https://fullstackdeeplearning.com/spring2021/lecture-7/>

Monitorización

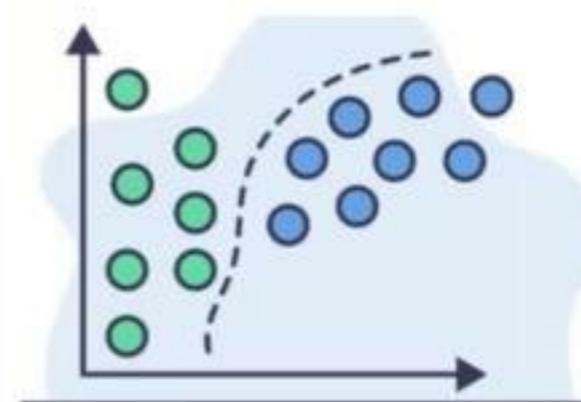
- ▶ La distribución de los datos en producción no es la esperada (o.o.d. y ejemplos *'long tail'*)
- ▶ Deriva de concepto: los resultados esperados cambian con el tiempo
 - ▶ Ejemplo: un predictor de ventas falla porque el poder adquisitivo de los clientes baja
- ▶ Deriva de datos: los datos de entrada cambian con el tiempo
 - ▶ Ejemplo: un detector de spam falla porque los textos son más sofisticados



Clasificador Original

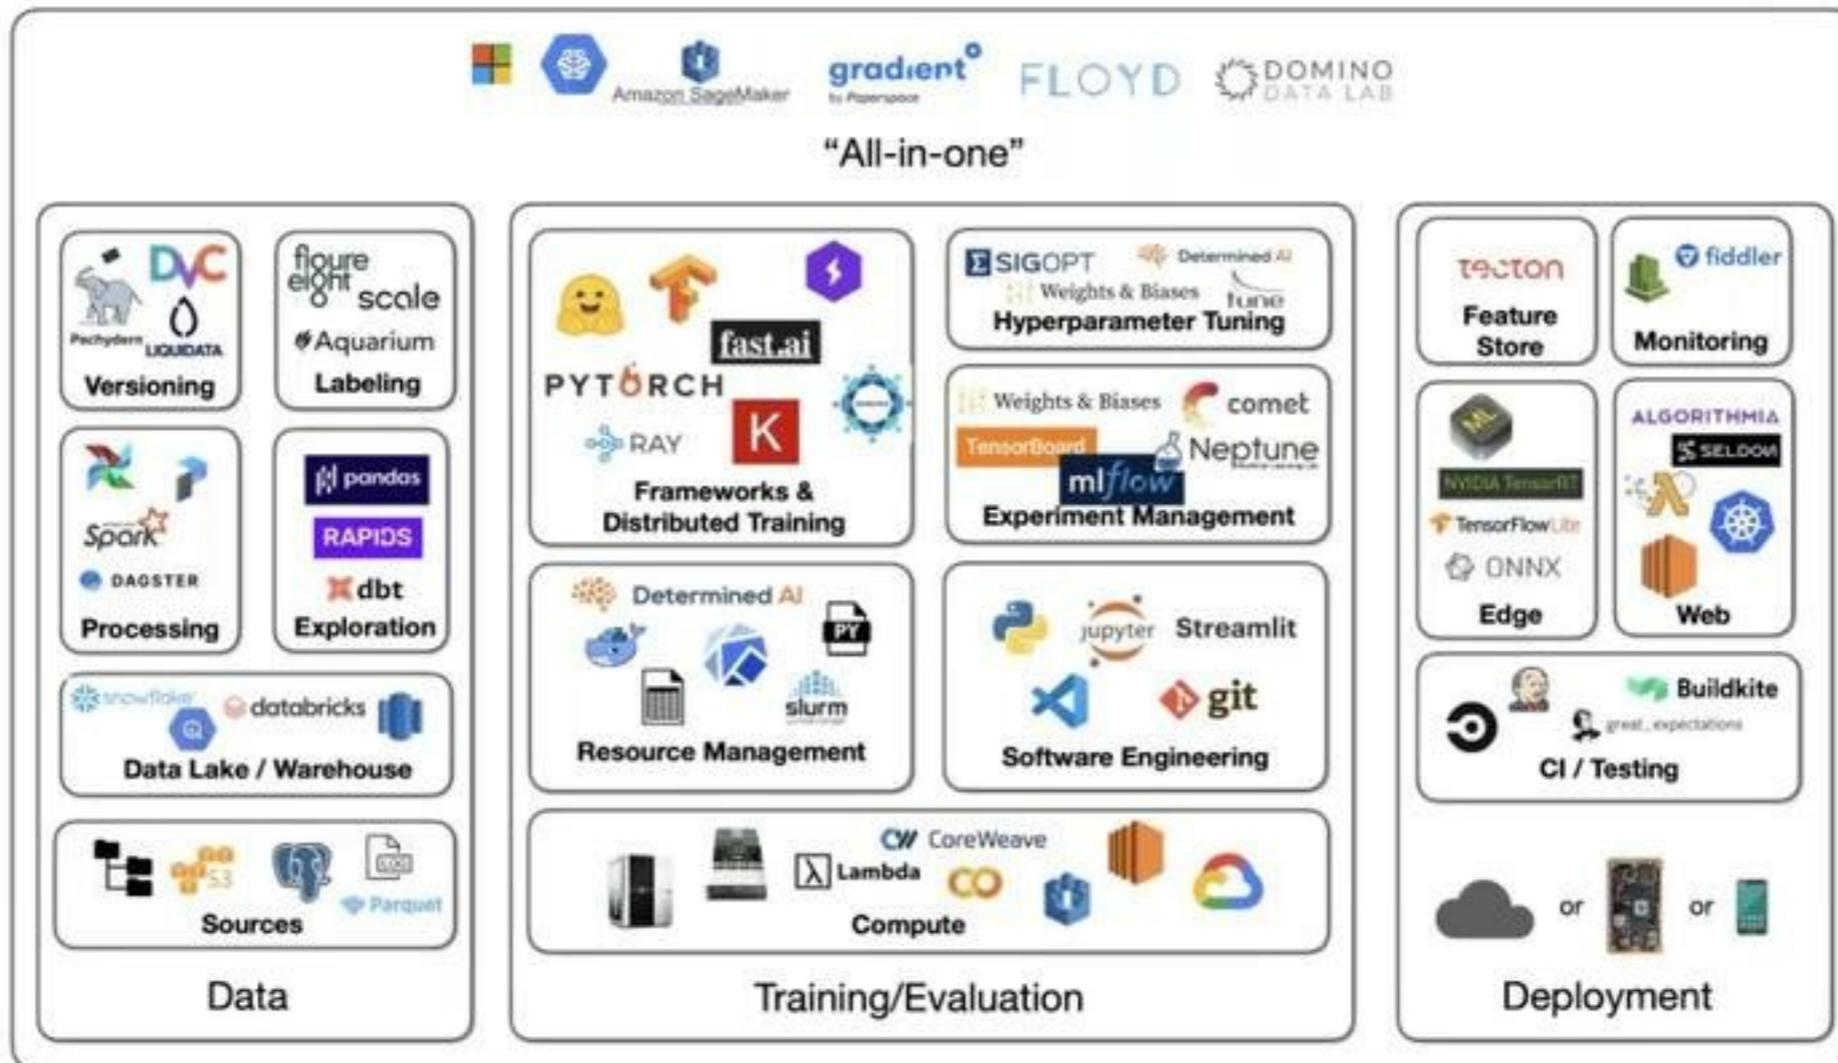


Deriva de Concepto



Deriva de Datos

Herramientas MLOps



Fuente: <https://fullstackdeeplearning.com/spring2021/lecture-6/>

Caso práctico:

Booking.com

Applied Data Science Track Paper

KDD '19, August 4-8, 2019, Anchorage, AK, USA

150 Successful Machine Learning Models: 6 Lessons Learned at Booking.com

Lucas Bernardi*
Booking.com
Amsterdam, Netherlands
lucas.bernardi@booking.com

Themis Mavridis*
Booking.com
Amsterdam, Netherlands
themistoklis.mavridis@booking.com

Pablo Estevez*
Booking.com
Amsterdam, Netherlands
pablo.estevez@booking.com

ABSTRACT

Booking.com is the world's largest online travel agent where millions of guests find their accommodation and millions of accommodation providers list their properties including hotels, apartments, bed and breakfasts, guest houses, and more. During the last years we have applied Machine Learning to improve the experience of our customers and our business. While most of the Machine Learning literature focuses on the algorithmic or mathematical aspects of the field, not much has been published about how Machine Learning can deliver meaningful impact in an industrial environment where commercial gains are paramount. We conducted an analysis on about 150 successful customer facing applications of Machine Learning, developed by dozens of teams in Booking.com, exposed to hundreds of millions of users worldwide and validated through rigorous Randomized Controlled Trials. Following the phases of a Machine Learning project we describe our approach, the many challenges we found, and the lessons we learned while scaling up such a complex technology across our organisation. Our main conclusion is that an iterative, hypothesis driven process, integrated with other disciplines was fundamental to build 150 successful products enabled by Machine Learning.

1 INTRODUCTION

Booking.com is the world's largest online travel agent where millions of guests find their accommodation and millions of accommodation providers list their properties, including hotels, apartments, bed and breakfasts, guest houses, etc. Our platform is developed by many different interdisciplinary teams working on different products, ranging from a large new application like our recent Booking Assistant, or an important page of the website with rich business value like the search results page, to a part of it, like the destinations recommendations displayed at the bottom. Teams have their own goals, and use different business metrics to quantify the value the product delivers and to test hypotheses, the core of our learning process. Several issues make our platform a unique challenge, we briefly describe them below:

High Stakes: Recommending the wrong movie, song, book, or product has relevant impact in the consumer experience. Nevertheless, in most cases there is a way to "undo" the selection: stop listening to a song or watching a movie, even returning a unsatisfactory product. But once you arrive to an accommodation that does not meet your expectations, there is no easy undo option, generating frustration and disengagement with the platform.

- ▶ Cifras 2019:
 - ▶ 28M de alojamientos
 - ▶ >100M usuarios
 - ▶ >1M noches reservadas al día
 - ▶ \$15066 Millones al año ingresos
- ▶ Retos de la plataforma:
 - ▶ Se juega mucho en las recomendaciones (no hay vuelta atrás)
 - ▶ Poca información del usuario en cada búsqueda
 - ▶ Decisión muy compleja (destino, fechas, tipo de alojamiento, ubicación, etc...)
 - ▶ Oferta dinámica (precio, disponibilidad)
 - ▶ Siempre en arranque frío (usuarios viajan 1-2 veces al año, nuevas acomodaciones cada día)
 - ▶ Contenido muy rico (número de baños, aire acondicionado, wifi, ...)

Cuando una recomendación falla...

Cuando una recomendación falla...



Cuando una recomendación acierta...

Cuando una recomendación acierta...



Aplicaciones de ML en Booking

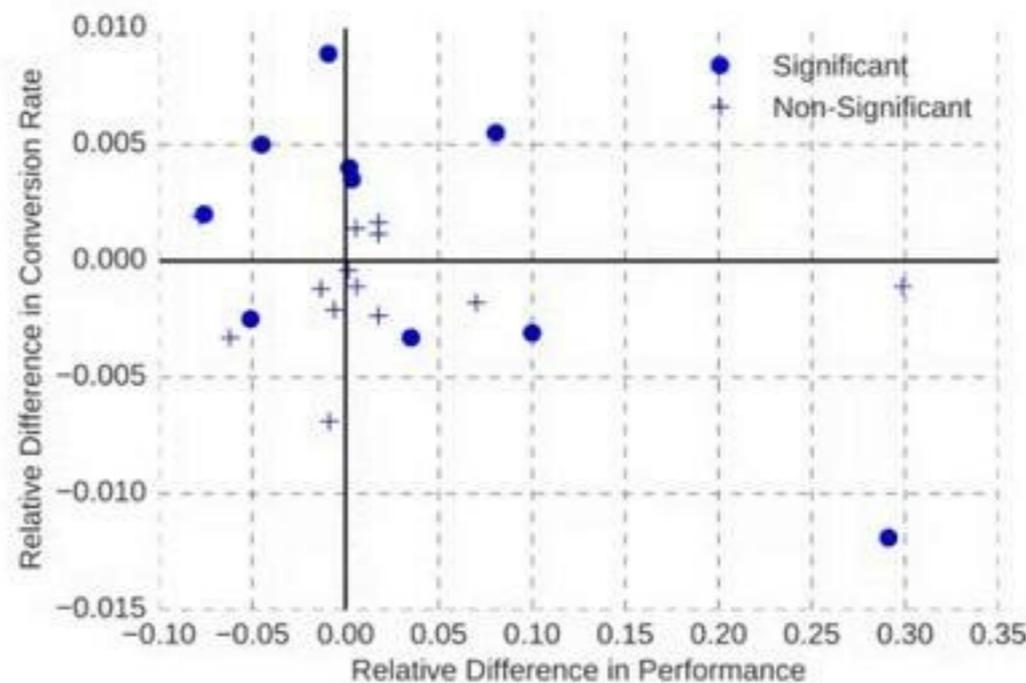
- ▶ El aprendizaje automático es la navaja suiza para el desarrollo de software
- ▶ Tipos de modelos:
 - ▶ Modelos específicos para un caso de uso (recomendación de mejores ofertas)
 - ▶ Modelos como capa semántica para nuevos casos de uso (predicción de flexibilidad de fechas de un viajero)



Lección 1: *“El impacto de los modelos basados en machine learning es positivo frente a otros basados en reglas”*

Modelo vs. Negocio

- ▶ No hay correlación entre la métrica del modelo y la métrica del negocio



Lección 2: “La métrica del modelo verifica la salud del mismo, pero no varia a la par que la métrica de negocio”

Construcción de Problema

- ▶ Proceso iterativo para elegir la mejor configuración del problema
- ▶ Criterios de selección de problemas:
 - ▶ Dificultad de aprendizaje
 - ▶ Cercanía de los datos disponibles con el concepto a predecir
 - ▶ Sesgo de selección de etiquetas

Lección 3: *“Para generar valor en el negocio además de mejorar el modelo, también resulta muy efectivo cambiar la configuración del problema”*

El tiempo es oro

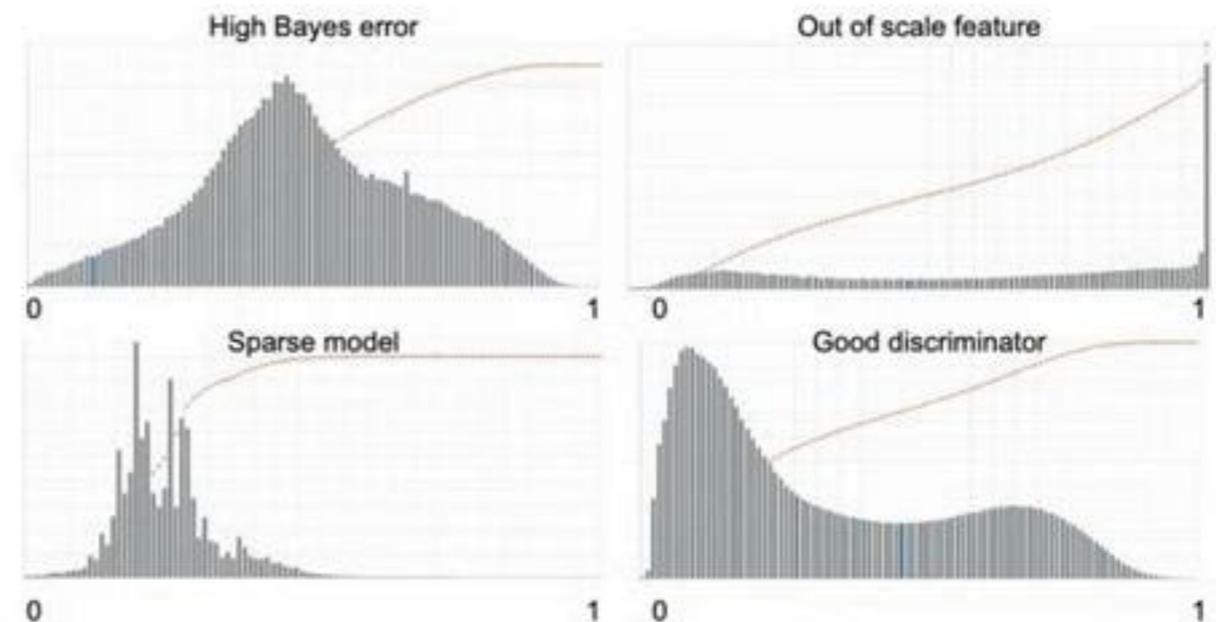
- ▶ Escalabilidad horizontal de modelos (redundancia)
- ▶ Motor de inferencia desarrollado internamente
- ▶ Estudio de ablación de parámetros
- ▶ Modelo precalculado y cacheado
- ▶ Llamada en bloque
- ▶ Minimizar preprocesado de datos



Lección 4: *“La inferencia de modelos introduce una significativa latencia que afecta directamente a la métrica de negocio más importante, el ratio de conversión”*

Monitorización de modelos

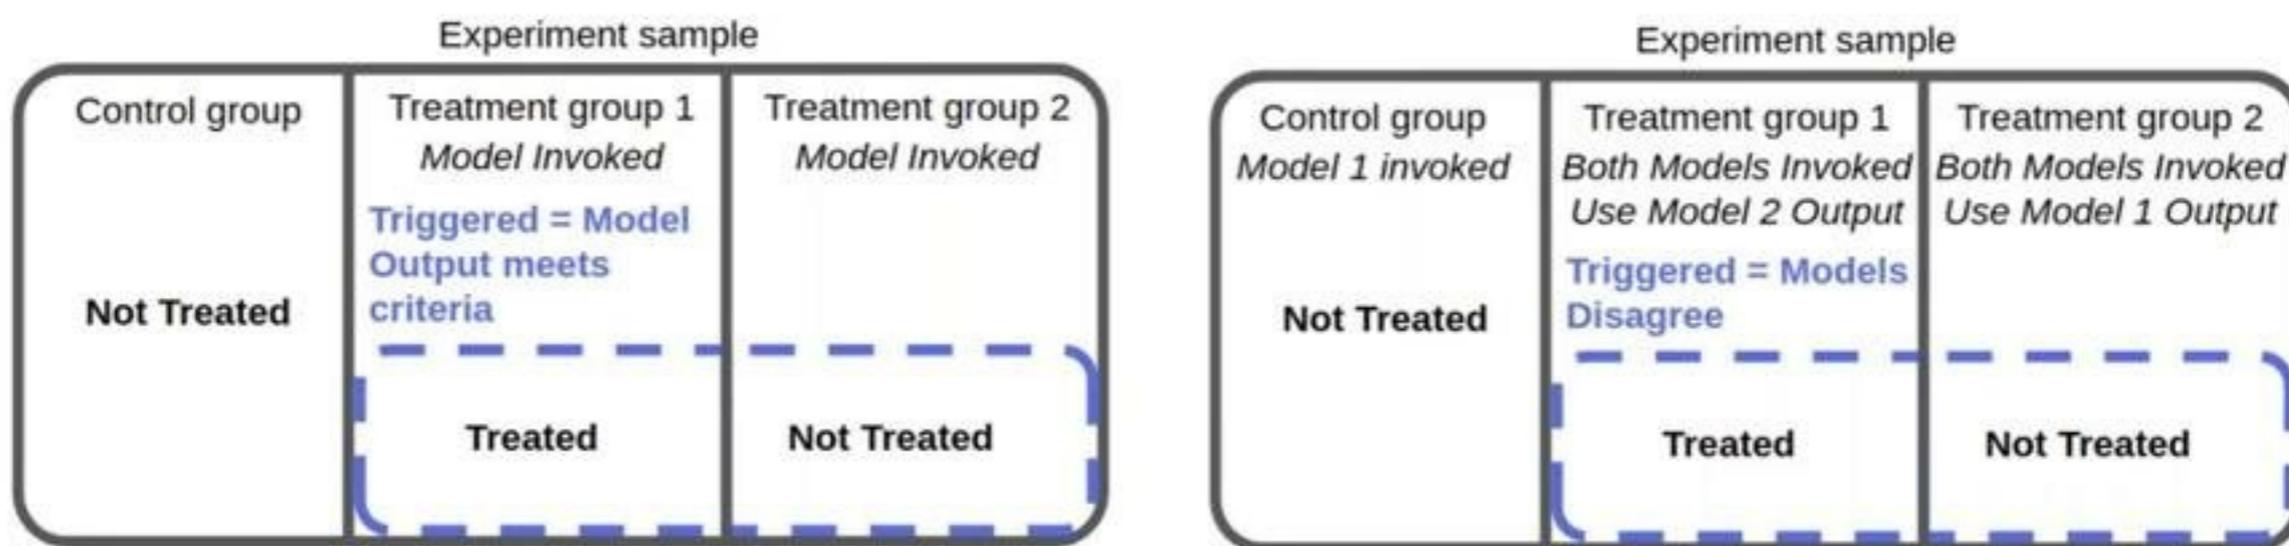
- ▶ Al utilizar un modelo en producción:
 - ▶ Etiquetas reales no siempre se conocen
 - ▶ Etiquetas reales se reciben con mucho retraso
- ▶ Las métricas predictivas tradicionales no se pueden aplicar en producción
- ▶ Alternativa mediante heurística: Análisis de Distribución de Respuestas



Lección 5: *“El Análisis de Distribución de Respuestas ha demostrado ser una herramienta muy útil que permite detectar defectos en los modelos lo antes posible”*

Evaluación de resultados

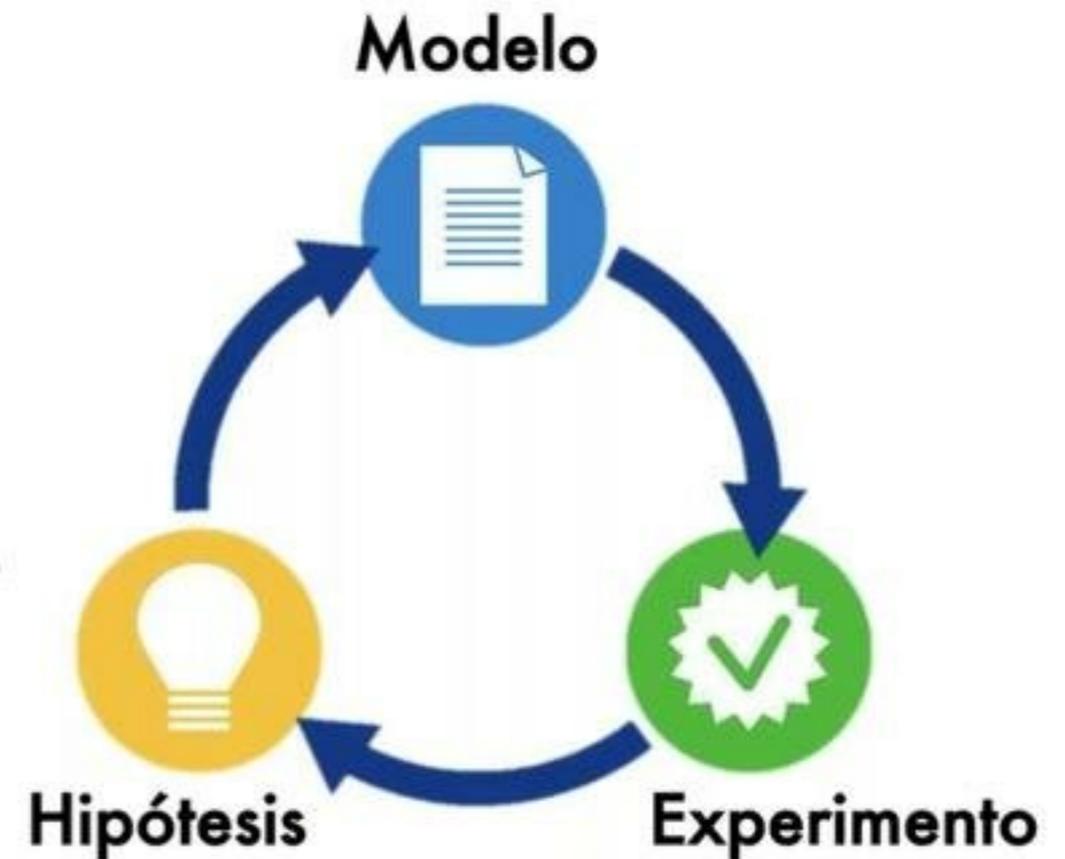
- ▶ Ensayos Controlados Aleatorizados (~A/B Testing) adaptados al modelado predictivo



Lección 6: “La sofisticación de las herramientas de experimentación en campo mejora el ciclo iterativo, ofreciendo estimaciones rápidas, fiables y precisas del efecto de nuestras decisiones y la validez de nuestras hipótesis”

Conclusión

- ▶ Estas lecciones les ayudan a mejorar el ciclo de desarrollo de modelos
- ▶ Integran ideas de varias disciplinas: programación, ingeniería de software, experiencia de usuario, inferencia causal, etc.



“Iteración basada en hipótesis e integración interdisciplinar son las claves para generar valor con machine learning”

¡Gracias!

Miguel A. Román
ma@iaa.es

¡Gracias!

Miguel A. Román
ma@iaa.es



EXPLICABLE

<https://explicable.iaa.es>