

**BBVA**

Creando Oportunidades



**INSTITUTO ESPAÑOL  
DE ANALISTAS** DESDE 1965

# Aplicaciones de la IA a la gestión de riesgo en entidades financieras

## Usos de la IA en modelos de Riesgo de Crédito

Rubén García Céspedes

Barcelona 27 de Febrero 2024

# Índice

- 01 Introducción
- 02 Usos en Riesgo de Crédito
- 03 Explicabilidad
- 04 Retos y conclusiones

# Introducción

La inteligencia artificial promete ser una revolución comparable a la revolución industrial en el siglo XVIII

**¿Que es la inteligencia artificial?** Según wikipedia “La inteligencia artificial (IA), en el contexto de las ciencias de la computación, es una disciplina y un conjunto de capacidades cognitivas e intelectuales expresadas por sistemas informáticos o combinaciones de algoritmos cuyo propósito es la creación de máquinas que imiten la inteligencia humana para realizar tareas, y que pueden mejorar conforme recopilen información”

**¿Que es el Aprendizaje Automático?** Según wikipedia “El aprendizaje automático (AA); también llamado automatizado, computacional o de máquinas (del inglés machine learning, ML), es el subcampo de las ciencias de la computación y una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras aprendan”

**Datos**  
Aumento de la información disponible

+

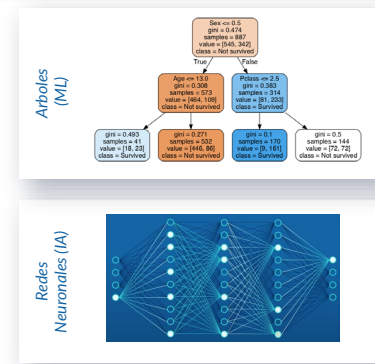
**Computación**  
Aumento de la capacidad computacional

+

**Técnicas**  
Nuevas tipologías de modelo

=

**IA / ML**



Los modelos de regresión clásicos caen dentro de la definición de IA y ML

# Introducción

## Principales tipologías de modelos de Riesgo de Crédito

Según publicaciones del Banco de España:

- “...We observe that ML delivers predictive **gains of up to 20 % in default classification** compared with traditional statistical models...”
- “...could yield **savings from 12.4% to 17% in terms of regulatory capital requirements**...”



### Admisión y Seguimiento

Modelos para **ordenar los clientes** en función de su probabilidad de impago, en la admisión o posteriormente.

Suelen ser ejes de las estimaciones de capital. Se requiere el OK del **supervisor**



### Requerimientos de Capital

Se emplean los modelos de admisión y seguimiento junto con ejes adicionales. Se requiere el OK del **supervisor**



### Cobranzas

Modelos para **ordenar los clientes** en función de su recuperabilidad o % de pérdida estimada



### Provisiones

Se emplean los modelos de admisión y seguimiento junto con ejes adicionales. Se requiere el OK del **auditor**

El uso de ML en Riesgos requiere de



Impacto en Negocio




Modificaciones en Infraestructura (IT)

El foco del ML en Riesgo de Crédito ha estado en modelos no-regulatorios i.e. cobranzas o geografías con cap. reg. Estandar (no-IRB)

# Usos en Riesgo de Crédito

El desarrollo robusto de modelos de ML comparte el 90% de las fases para desarrollar modelos clásicos

## Fases de Modelización



### Modelos de Cobranzas (KPI-Provisiones)

Modelos de preventiva/EWS:

- Prob. de **impago** en el corto plazo
- No es necesario segmentar por tipología de cliente o info

Modelos de roll-rates:

- Prob. de **avanzar** en los días de impago
- No es necesario segmentar por bucket de días

Modelos de ranking de agencias:

- Identificar la **mejor agencia** para un cliente en impago
- Incluido **grupo de control** para futuras re-estimaciones

Modelos de propensión al pago:

- Probabilidad o % de recuperación de un cliente
- Tanto en el **corto** como en el **largo** plazo

Modelos de contactabilidad:

- Mejor **canal/momento** de contacto para clientes

Aprendizaje por refuerzo:

- Definición de la **mejor acción** para recuperar dado un target de largo plazo
- Incluido grupo de **exploración**

### Modelos de Admisión y seguimiento (KPI-Vol. Admisión)

Modelos de límites/ingresos:

- Estimación de **ingresos** de clientes
- Definición de **límites** en función de los ingresos estimados

Modelos de admisión:

- Reactivos en geografías **Cap. Estandard**
- Algunas entidades cuentan con reactivos en **IRB**

Modelos comportamentales:

- En geografías **Cap. Estandard**
- **Explicabilidad** de impactos en **provisiones**

### Otros usos

Identificación de ejes adicionales de segmentación:

- **Árboles** para completar el eje de la puntuación

Generación de datos sintéticos (poco estudiado):

- En Low Default Portfolios
- En datos faltantes para MoCs de Cap. Reg.

Se han de mantener estándares igual de rigurosos que en el desarrollo de modelos clásicos junto con la necesidad de intervención humana

# Explicabilidad de los modelos de Machine Learning

Los modelos de ML son complejos y a veces son llamados “cajas negras”

Regresión IA-1.0

+ Complejidad  
+ Precisión

Árbol de decisión IA-2.0

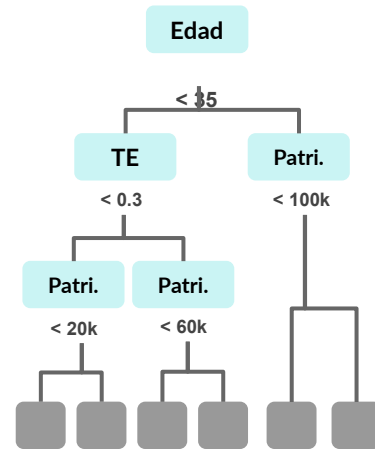
+ Complejidad  
+ Precisión

Machine Learning IA-3.0 (\*)

$$P_{Default} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

- **Opción 1:** Valor de los coeficientes para entender el efecto
- **Opción 2:** Coeficientes y valores. Cuanto afecta a la variabilidad final
- **Opción 3:** Correlación entre variables
- Si uso el coef entonces el **efecto de una variable** es igual para todas las observaciones

■ Se capturan **efectos medios** en la población



■ No tenemos **coeficientes**

■ El **efecto de una variable** es diferente en las observaciones

$$P = \beta_1 \text{[Rede Neuronal]} + \beta_2 \text{[Rede Neuronal]} + \beta_3 \text{[Rede Neuronal]} + \dots$$

■ Cuando hacemos **Machine Learning** el problema se vuelve mucho más complicado

(\*) El uso de Redes Neuronales (Deep Learning) presenta retos adicionales que por el momento dificultan su uso

El aumento de la complejidad lleva asociado una reducción en la explicabilidad

# Explicabilidad de los modelos de Machine Learning

## ¿Para qué quiero entender lo que hay dentro de un modelo de ML?

- Controlar **comportamientos indeseados**, ej. de intervención humana en su construcción:
  - “Que a más ingresos peor sea el output del modelo de scoring”, es necesario un análisis caso a caso
  - “Alucinaciones” de los modelos de redes neuronales
  - **Garantizar la equidad** sobre determinados colectivos, genero, edad... No se trata únicamente de **eliminar** esas variables ya que puede haber **correlaciones con otras**
  - Explicar impactos posteriores en **provisiones/capital** así como su dinámica
- Entendimiento por parte de los **usuarios de los modelos**
- **Regulación:**
  - **Genérica GDPR y AI Act**, los sistemas de calificación para concesión de créditos son sistemas de Alto-Riesgo
  - **Bancaria CRR y EBA**
    - Se están **empezando** a usar modelos de ML para requerimiento de capital regulatorio
    - Pero se piden **analysis** “... Assess the economic relationship of each risk driver with the output variable to ensure that the model estimates are plausible and intuitive ...”

Existen técnicas que permiten explicar los modelos de ML (ej. SHAP)

# Retos y Conclusiones

Se han hecho avances importantes para el uso de modelo de ML en funciones de riesgos por las entidades financieras y los reguladores



- El ML tiene **ventajas** tanto para las **entidades** como para los **clientes** por inclusión financiera gracias a una mejor **diferenciación**
- **Cambio cultural y de infraestructuras** en las entidades, Equipos de Negocio y Riesgos, Ingeniería, Riesgos, Validación Interna.... Es necesaria formación específica para facilitar la transición
- Adaptación de la **gobernanza interna** específica para los modelos de ML. Tanto para su **desarrollo** y **validación** como **seguimiento**
- Profundización en las **técnicas de explicabilidad** (Lime/SHAP/Permutation) en el proceso de modelización y uso. Una capa de explicabilidad es requerida en el **uso de los modelos**
- **Variables protegidas** (ej. género) no pueden ser incluidas en el modelo. Es necesario el desarrollo de un **marco de equidad** más profundo (Modelo vs Políticas)
- Problemas de **infraestructura** principalmente en las fases de despliegue (por ejemplo, limitaciones de los motores de riesgos para desplegar ciertos algoritmos)
- **Reflexión del Regulador** sobre la aplicación de modelos ML para carteras IRB. Enfoque actual en carteras bajo capital standard y casos de uso de modelos no regulatorios



**BBVA**

Creando Oportunidades



**INSTITUTO ESPAÑOL  
DE ANALISTAS** DESDE 1965

# Aplicaciones de la IA a la gestión de riesgo en entidades financieras

## Usos y limitaciones en modelos de Riesgo de Crédito

Rubén García Céspedes

Barcelona 27 de Febrero 2024