WHITE PAPER

Machine Learning aplicado al Riesgo de Crédito en Banca
Generación de poblaciones sintéticas

Mesa Redonda Club de Gestión de Riesgos: Nuevas tendencias en el uso de modelos y datos para la admisión, gestión y seguimiento del riesgo de crédito – 10 Mayo 2021

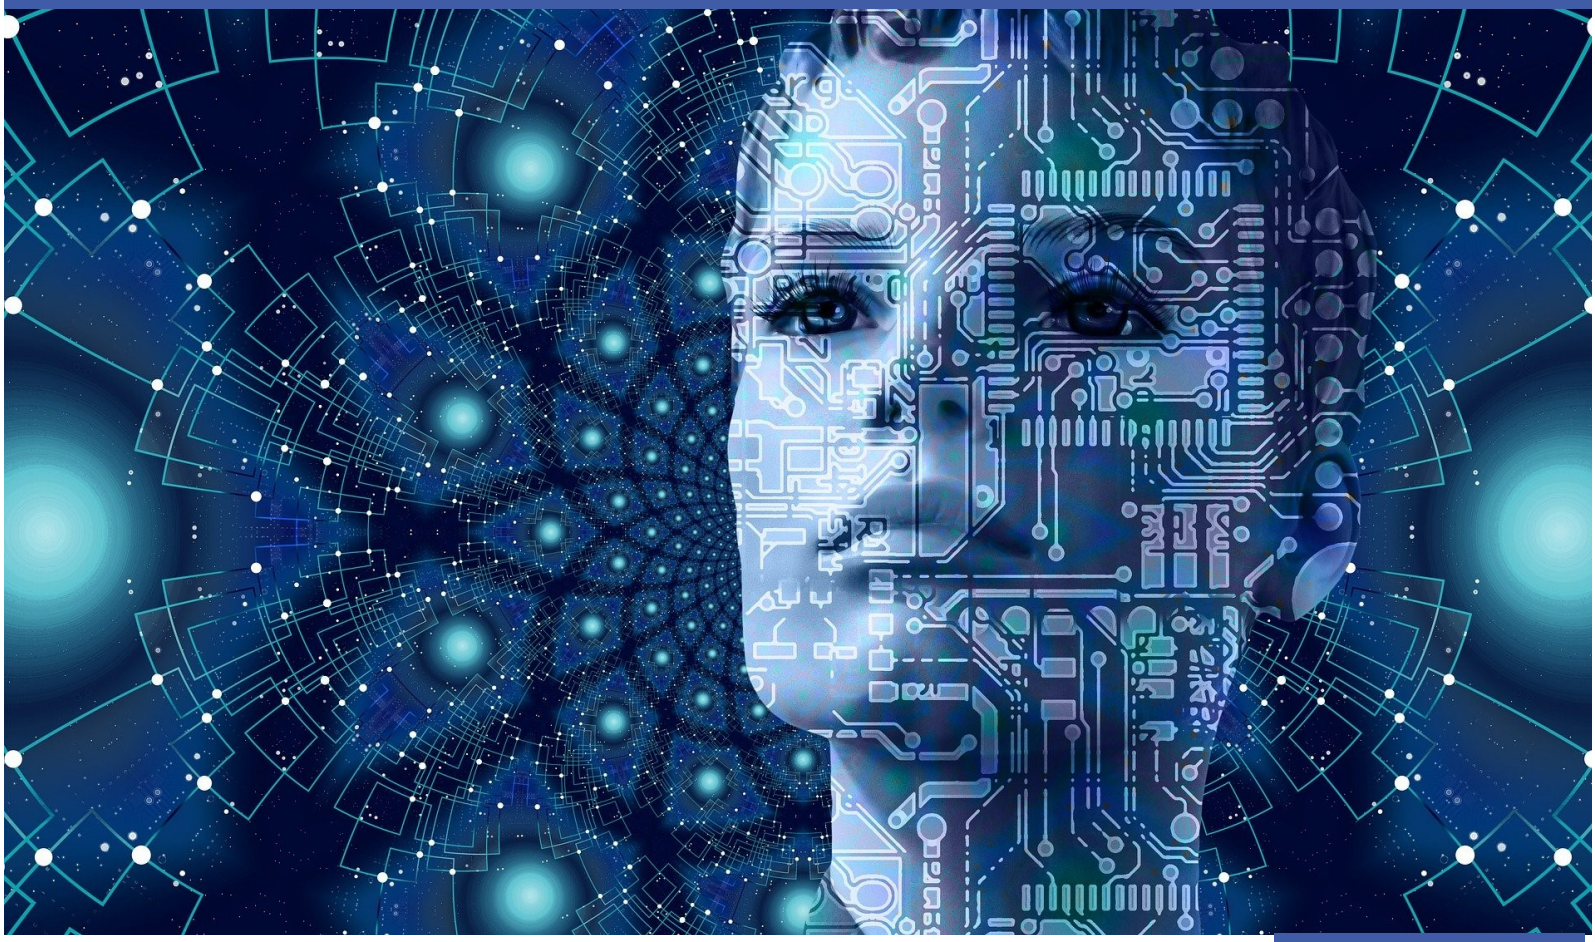

Carles Cerdà - carlos.cerda@sas.com
Risk Solutions Manager – South West Europe
SAS Institute

THE POWER TO KNOW.

Machine Learning en el ciclo de vida del crédito

Cuando hablamos de técnicas de *inteligencia artificial y machine learning* aplicadas al riesgo de crédito en el sector bancario, tendemos automáticamente a pensar en modelos regulatorios y técnicas de *Gradient Boosting*. E inmediatamente se nos vienen a la cabeza una serie de problemáticas que hacen de la aplicación de estas técnicas una tarea más bien ardua: explicabilidad, interpretabilidad, sesgos, etc… después validar que el nuevo modelo es mejor que los construidos con técnicas tradicionales y finalmente convencer al regulador.

Pero *Machine Learning* no es sólo *Gradient Boosting*; las entidades financieras están utilizando con éxito estas herramientas a lo largo de todo el ciclo de vida del crédito en ámbitos menos sujetos al escrutinio regulatorio. Podemos enumerar algunos ejemplos:

*Las entidades financieras están utilizando con éxito las herramientas de **Machine Learning** a lo largo de todo el ciclo de vida del crédito en ámbitos menos sujetos al escrutinio regulatorio.*

- La automatización de tareas de preparación de datos.
    - Existen herramientas que utilizan técnicas de AI/ML para analizar los datos y automáticamente recomendar acciones de limpieza y preparación que ayudan a los científicos de datos a invertir su tiempo en tareas más interesantes y de mayor valor añadido.
    - Esas mismas herramientas ayudan también en la generación automática de características con mayor poder explicativo que las variables originales (lo que se conoce como *feature engineering*).

- La generación de datos sintéticos
    - Desde inferir características individuales, tales como estimar o validar el nivel de ingresos, estimar el precio de los inmuebles,
    - hasta la generación de poblaciones en las que se simulan todas las características añadiendo nuevas observaciones sintéticas.

- El análisis de grandes cantidades de información, como información transaccional, para generar nuevos indicadores
    - La aplicación de técnicas de AI puede ayudar a detectar pagos anómalos marcando los movimientos inusuales a los controllers humanos.
    - El análisis de transacciones de tarjetas de crédito permite añadir los patrones de gasto como predictores adicionales en los modelos de probabilidad de impago. Por ejemplo, perfiles con una concentración de compras de productos de suscripción (TV por cable, Apps, etc…) está asociada con una mayor tasa de default que un perfil de compra con menor concentración y con un alto porcentaje de compras en tiendas de comestibles.

- Mediante tratamiento de lenguaje natural se obtiene información estructurada a partir de textos libres.
    - Se puede ahorrar mucho tiempo de los analistas para localizar las partidas del balance y cuenta de resultados que intervienen en las ratios de un rating que miden la calidad crediticia de las empresas y hacerlas comparables unas con otras.
    - Analizando el contenido de documentos tanto internos como públicos se puede llegar a determinar conexiones entre clientes que no resultan obvias a primera vista.

- Incorporar un scoring de sentimiento (sentiment score)
    - Hablamos de generar un indicador que básicamente mide si la información y comentarios publicados sobre una contrapartida (una empresa) son positivos, negativos o neutros
    - El scoring de sentimiento se utiliza como otro componente adicional en los modelos de alertas tempranas para anticipar el tiempo hasta insolvencia de las empresas.
    - Una POC realizada en un banco de inversiones de Singapur para una cartera de grandes empresas mostró un 15% de incremento de poder predictivo usando un indicador de sentimiento extraído de las noticias publicadas sobre las empresas objeto de seguimiento.
    - A continuación, utilizando análisis cluster sobre ratios financieros, y probabilidades ponderadas por métricas de distancia, se clasifican modelos de negocios similares y se extrapolan los índices de sentimiento a una cartera de medianas empresas

- Validación de modelos
    - Todos hemos oído hablar del clásico uso de modelos de ML como benchmark de los modelos regulatorios construidos con técnicas tradicionales de regresión logística.

En el resto del documento analizaremos con más detalle una experiencia concreta que puede resultar especialmente relevante para la validación de los modelos de riesgo de crédito; seguramente con aplicabilidad en el ámbito regulatorio.

Generación de poblaciones sintéticas

Mucho se ha dicho y escrito acerca de que los modelos basados en técnicas de *gradient boosting* funcionan sustancialmente mejor que los modelos tradicionales basados en *regresión logística*. Pero para acelerar la aplicación de estas técnicas, sobre todo en el ámbito regulatorio, es necesario resolver el problema de la "**caja negra**".

El trabajo hecho en UK, entre SAS, Nationwide y la universidad de Edinburgo propone una métrica basada en contrafactuales para evaluar la interpretabilidad de las técnicas de Machine Learning.

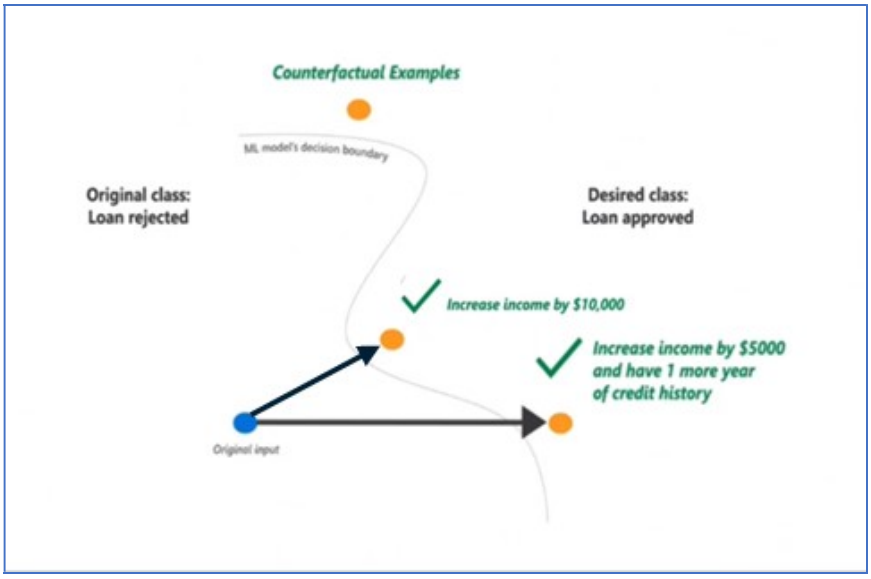

*Un **contrafactual** se define como una observación generada (sintética) que está tan próxima como sea posible a la observación original pero que el modelo clasifica de forma contraria.*

Un contrafactual se define como una observación generada (sintética) que está tan próxima como sea posible a la observación original pero que el modelo clasifica de forma contraria. Por ejemplo… para un cliente al que se le ha denegado un préstamo un contrafactual podría ser… si sus ingresos fueran 10.000 € por año mayores su préstamo hubiera sido aprobado. Los contrafactuales explican qué características de los datos (y cuánto) tienen que cambiarse para que la clasificación prevista por el modelo cambie.

La distancia de los contrafactuales al punto original refleja la robustez del modelo frente a ejemplos adversos. Si los contrafactuales están muy lejos de los originales será más difícil que el modelo genere falsos positivos y, por tanto, será más robusto.

Para esta generación de contrafactuales se utilizan técnicas de algoritmos genéticos que permiten añadir restricciones y restringir los casos generados a subpoblaciones y rangos específicos de datos.

De esa forma, los contrafactuales se pueden utilizar como técnicas de perturbación de datos para generar escenarios de stress.

Los modelos tradicionales, que usan regresión logística, típicamente se comportan bien en épocas de recesión económica, en términos de su capacidad para clasificar a los peores prestatarios peor que a los buenos prestatarios. Es decir, la discriminación no se ve materialmente afectada. Sin embargo, estos modelos pueden deteriorarse desde la perspectiva de precisión, y la PD, para una determinada puntuación, deja de ser tan precisa.

La distancia de los contrafactuales al punto original refleja la robustez del modelo frente a ejemplos adversos.

Si los contrafactuales están muy lejos de los originales será más difícil que el modelo genere falsos positivos y, por tanto, será más robusto.

Dado que los modelos de ML no se vienen usando hace mucho tiempo, no existe una comprensión clara de cómo se comportarán bajo condiciones de recesión económica.

Cuando no tenemos información dinámica (de varios periodos) se puede usar el clasificador KNN (k Nearest Neighbours) para asignar la categoría de default o no default a los datos generados sintéticamente. KNN es un algoritmo de ML que clasifica un nuevo dato basado en una medida de similitud (en función de sus vecinos). En el gráfico siguiente, el caso sintético (marcado por la estrella) se clasifica en función de los vecinos de cada clase. Resultaría de la clase A usando 3NN o de la clase B si utilizamos 6NN. Tambien podemos usar este clasificador para alterar la proporción de defaults de la muestra ampliando la frontera de asignación de la clase.

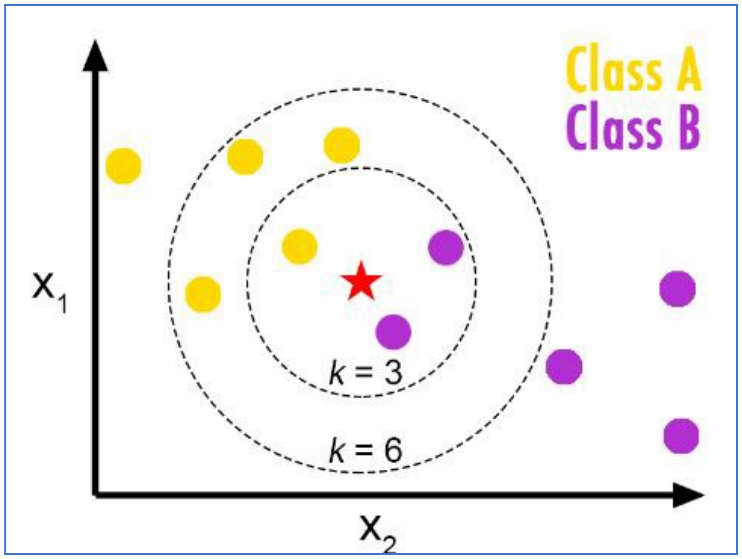

*Se puede usar el clasificador **KNN** (k Nearest Neighbours) para asignar la categoría de default o no default a los datos*

Las técnicas propuestas se aplicaron a una muestra de préstamos de Nationwide comparando modelos de regresión logística y stochastic gradient boosting.

Partiendo de una ratio de default de 6,8% se generaron varios conjuntos de datos con mayores probabilidades de default. Usando el AUC (Área bajo la curva) se observa que esta métrica disminuye a medida que se incrementa la morosidad de la muestra. La caída es mayor para la regresión logística mostrando que es menos robusta.

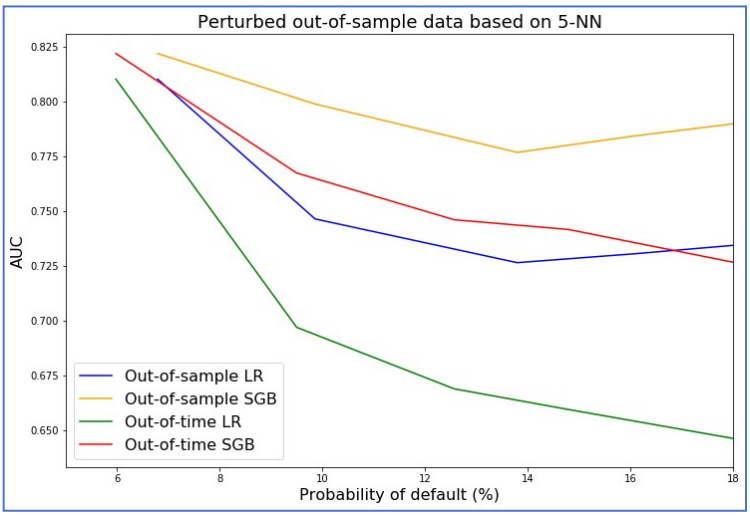

También se verificó (utilizando gráficas de SHAP-value) que las explicaciones de las decisiones hechas por el modelo son las mismas para los datos originales que para los perturbados. Es decir, que utiliza las mismas variables o características y con la misma importancia.

En gráfico inferior (en el que por temas de confidencialidad se han sustituido los nombres de las variables utilizadas por etiquetas genéricas) muestra una muy pequeña diferencia en la contribución aportada por las variables.

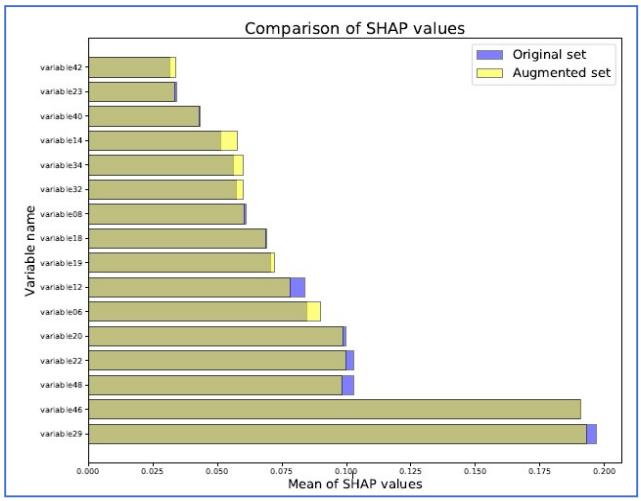

A continuación, usando la medida de robustez basada en distancias de los contrafactuales se confirmó que los modelos de Stochastic Gradient Boosting obtienen mejor nota que los de Regresión Logística para la mayoría de las características de la población. O lo que es lo mismo, es más difícil que clasifique erróneamente. La tabla siguiente muestra que la media de la distancia del modelo de Gradient Boosting es generalmente mayor que la de la Regresión Logística.

Variables	Logit model	SGB model
variable1	5.51±1.72	9.1±2.45
variable2	4.88± 1.30	8.5±2.41
variable3	7.02±1.84	10.3±2.42
variable4	5.92±3.09	9.90±2.51
variable5	7.76±1.91	9.84±2.51

Como conclusión podemos indicar que combinando la métrica de robustez basada en contrafactuales con la metodología kNN de perturbación de datos se pueden obtener poblaciones sintéticas que permitan inferir el comportamiento del modelo durante lo que podría ser una crisis financiera.

*Como **conclusión** podemos indicar que combinando la métrica de robustez basada en contrafactuales con la metodología kNN de perturbación de datos se pueden obtener poblaciones sintéticas que permitan inferir el comportamiento del modelo durante lo que podría ser una crisis financiera.*

To contact your local SAS office, please visit: sas.com/offices

SAS and all other SAS Institute Inc product or service names are registered trademarks or trademarks of SAS Institute Inc. in the USA and other countries.
® indicates USA registration. Other brand and product names are trademarks of their respective companies. Copyright © 2018, SAS Institute Inc. All rights reserved.