



Credit Scoring, Inteligencia Artificial y Machine Learning Cuántico

Whitepaper de Fermac Risk

Abril 2024





Prefacio

Nuestro curso Credit Scoring, Inteligencia Artificial y Machine Learning Cuántico puede equipar a los participantes con habilidades de vanguardia para aprovechar los avances de la computación cuántica y las técnicas de inteligencia artificial en el análisis del riesgo crediticio. Este conocimiento permite modelos de calificación crediticia más precisos y eficientes, lo que conduce a una mejor evaluación de riesgos, decisiones crediticias optimizadas y una mayor inclusión financiera.

En este documento técnico, destacaremos las ventajas prácticas que puede adquirir a través de una formación especializada. Específicamente, discutiremos la importancia de la curva ROC en los modelos de calificación crediticia, las ventajas de los modelos de aprendizaje profundo y aprendizaje automático sobre la regresión logística y los beneficios de los modelos de aprendizaje automático cuántico sobre los modelos clásicos de aprendizaje automático. Por último, exploraremos el impacto económico de estos modelos en los bancos.

1. ¿Cuál es la importancia de la característica operativa del receptor (ROC) en la calificación crediticia?



En el contexto del desarrollo de cuadros de mando, la curva de característica operativa del receptor (ROC) es una herramienta crucial para evaluar el desempeño de un modelo de clasificación. El área bajo la curva ROC (AUC) mide qué tan bien el cuadro de mando distingue entre las dos clases (por ejemplo, riesgos crediticios buenos y malos). Obtener un ROC más alto (o específicamente, un AUC más alto) ofrece varios beneficios:

1. Mejor gestión de riesgos

Al identificar con precisión la probabilidad de incumplimiento, los prestamistas pueden adaptar sus productos crediticios y tasas de interés a los perfiles de riesgo individuales, mejorando la gestión general del riesgo. Esto puede reducir las tasas de incumplimiento y potencialmente aumentar la rentabilidad.

2. Eficiencia incrementada

Un cuadro de mando más preciso significa menos falsos positivos y negativos. Esta eficiencia puede mejorar la satisfacción del cliente, reducir las pérdidas crediticias innecesarias y optimizar la asignación de recursos, como verificaciones de crédito adicionales o esfuerzos de cobranza.

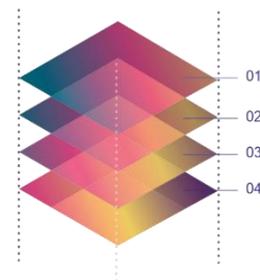
3. Ventaja competitiva

En un mercado competitivo, la capacidad de evaluar el riesgo de precios con mayor precisión puede ser una ventaja significativa. Puede conducir a una mejor segmentación de los clientes, precios más competitivos y el desarrollo de productos financieros innovadores adaptados a diferentes segmentos de riesgo.

4. Decisiones estratégicas mejoradas

Con un cuadro de mando confiable, las instituciones financieras pueden tomar decisiones estratégicas sobre los segmentos de mercado a los que dirigirse, los productos que ofrecerán y las políticas crediticias que implementarán. Esta ventaja estratégica puede conducir a una mejor diversificación de la cartera y rendimientos ajustados al riesgo.

2. ¿Cuáles son las ventajas de utilizar el aprendizaje profundo en contraste con la regresión logística al desarrollo de modelos de calificación crediticia?



En el desarrollo de modelos de calificación crediticia, la transición de métodos tradicionales como la regresión



logística a enfoques de aprendizaje profundo puede ofrecer ventajas significativas, particularmente a medida que aumentan la complejidad y el volumen de datos. A continuación, se detallan algunos beneficios clave de utilizar el aprendizaje profundo en lugar de la regresión logística para la calificación crediticia:

1. Relaciones no lineales

La regresión logística es fundamentalmente lineal y supone una relación lineal entre las variables independientes y las probabilidades logarítmicas de la variable dependiente. Sin embargo, puede tener problemas con relaciones complejas y no lineales inherentes a los datos del mundo real.

El aprendizaje profundo se destaca en la identificación y modelado de interacciones complejas y no lineales entre variables sin necesidad de ingeniería de características explícita. Esto puede conducir a predicciones más precisas en escenarios complejos.

2. Extracción y selección de características

La regresión logística requiere una cuidadosa selección de características e ingeniería para modelar las relaciones de manera efectiva. Este proceso suele ser manual y se basa en conocimientos del dominio y pruebas estadísticas.

Deep Learning detecta automáticamente características e interacciones relevantes durante el proceso de capacitación. Las capas dentro de una red neuronal pueden aprender a representar patrones de datos simples y complejos, lo que reduce la necesidad de ingeniería manual de funciones.

3. Manejo de datos no estructurados

La regresión logística es adecuada principalmente para datos estructurados. El análisis de datos no estructurados, como texto o imágenes, requiere un preprocesamiento significativo para transformar los datos a un formato adecuado.

4. Personalización y adaptabilidad

Los modelos de regresión logística son generalmente estáticos, lo que significa que no se adaptan bien a los cambios en la distribución de datos subyacente sin una reevaluación y ajuste manuales. Los modelos de aprendizaje profundo se pueden entrenar y adaptar continuamente a nuevos datos, haciéndolos más resistentes a las condiciones del mercado o a los cambios de comportamiento de los clientes a lo largo del tiempo.

Si bien el aprendizaje profundo ofrece ventajas significativas al modelar patrones y relaciones complejas en los datos, es importante equilibrar estos beneficios con consideraciones como la interpretabilidad del modelo, los recursos computacionales y la disponibilidad de suficientes datos de entrenamiento. La regresión

logística, con su simplicidad, transparencia y facilidad de implementación, sigue siendo valiosa, especialmente en escenarios donde la explicabilidad es crucial o los datos son limitados.

3. ¿Cuáles son las ventajas del aprendizaje automático cuántico (QML) sobre las técnicas tradicionales de aprendizaje profundo para desarrollar modelos de calificación crediticia?



El uso del aprendizaje automático cuántico (QML) sobre las técnicas tradicionales de aprendizaje profundo, incluidas las redes neuronales de avance y las redes neuronales convolucionales (CNN), en la calificación crediticia es un área de interés emergente, principalmente debido a las ventajas teóricas que ofrece la computación cuántica. Si bien la aplicación práctica del aprendizaje automático cuántico en la calificación crediticia aún está en sus inicios, los beneficios teóricos sugieren un futuro prometedor. Estos son algunos de los beneficios clave que el aprendizaje automático cuántico podría ofrecer sobre los modelos tradicionales de aprendizaje profundo en el desarrollo de sistemas de calificación crediticia:

1. Velocidad y eficiencia

Debido al paralelismo cuántico, el aprendizaje automático cuántico puede, en teoría, procesar información mucho más rápido que los métodos informáticos clásicos. Los algoritmos cuánticos pueden reducir significativamente la complejidad computacional de algunos problemas, ofreciendo aceleraciones exponenciales para determinadas tareas. Esto podría hacer que el análisis de grandes conjuntos de datos sea más eficiente, lo que podría conducir a procesos de calificación crediticia más rápidos.

2. Complejidad y Dimensionalidad

Los sistemas cuánticos pueden manejar naturalmente espacios de datos complejos y de alta dimensión debido a la naturaleza de los bits cuánticos (qubits) que pueden representar múltiples estados simultáneamente mediante superposición. Esta capacidad podría permitir una modelización más matizada y sofisticada del riesgo crediticio, capturando patrones y relaciones complejos en



los datos que podrían resultar desafiantes para los modelos tradicionales.

3. Optimización

La computación cuántica puede mejorar los procesos de optimización, un componente clave en el entrenamiento de modelos de aprendizaje automático. Los algoritmos de optimización cuántica pueden encontrar el mínimo global de una función de pérdida de manera más eficiente que las técnicas de optimización clásicas, que a veces pueden quedar atrapadas en mínimos locales, especialmente en espacios complejos y de alta dimensión típicos del aprendizaje profundo.

4. Selección de funciones y compresión de datos

Quantum ML podría ofrecer potencialmente formas innovadoras de realizar la selección de funciones y la compresión de datos sin perder información crítica. Las técnicas cuánticas, como el análisis cuántico de componentes principales (qPCA), pueden procesar y reducir la dimensionalidad de grandes conjuntos de datos de manera más eficiente, lo que ayuda a identificar las características más informativas para la calificación crediticia.

5. Reconocimiento de patrones mejorado

Los modelos de aprendizaje automático cuántico, en particular aquellos que aprovechan el entrelazamiento y la interferencia cuánticos, podrían ser capaces de reconocer patrones y correlaciones en datos que no son evidentes para los algoritmos clásicos. Esto podría resultar particularmente útil para identificar señales sutiles de solvencia o riesgo de incumplimiento que los modelos tradicionales podrían pasar por alto.

6. Manejar la incertidumbre

La computación cuántica incorpora naturalmente el concepto de incertidumbre a través de la naturaleza probabilística de la mecánica cuántica. Esto podría resultar particularmente ventajoso en la calificación crediticia, donde la incertidumbre y los resultados probabilísticos (como la probabilidad de incumplimiento) son inherentes a los modelos.

Si bien los beneficios potenciales del aprendizaje automático cuántico en la calificación crediticia son significativos, es importante señalar que la computación cuántica y el aprendizaje automático cuántico aún son campos emergentes. Muchas de las ventajas teóricas aún no se han materializado plenamente en aplicaciones prácticas debido a las limitaciones tecnológicas actuales, incluida la disponibilidad de computadoras cuánticas suficientemente potentes y estables. Además, las cuestiones relacionadas con la interpretabilidad de los modelos, la privacidad de los datos y la complejidad de los algoritmos cuánticos también plantean desafíos. Sin

embargo, a medida que la tecnología de computación cuántica madure, podría ofrecer avances sustanciales en la precisión, eficiencia y capacidades de los modelos de calificación crediticia con respecto a los enfoques tradicionales de aprendizaje profundo.

4. ¿Cuál ha sido la experiencia de Fermac Risk en el desarrollo de scoring crediticio utilizando aprendizaje profundo y computación cuántica?



En Fermac Risk, comenzamos a desarrollar modelos de calificación crediticia utilizando enfoques tradicionales como regresión logística, aprendizaje automático moderno y técnicas de aprendizaje profundo.

En 2017, trabajamos con una base de datos de alta calidad para desarrollar modelos de calificación crediticia. Utilizamos regresión logística con las variables normalizadas y obtuvimos una ROC del 85%. Con las variables discretizadas por WOE, tuvimos un ROC del 91%, lo cual fue un buen resultado. Sin embargo, estábamos ansiosos por utilizar técnicas de aprendizaje automático.

Ese mismo año, comenzamos a utilizar el lenguaje de programación R y sus potentes bibliotecas de aprendizaje automático, como las galardonadas e1071 y caret. Aplicamos modelos SVM, K-vecinos más cercanos, embolsado, impulso y bosque aleatorio. El modelo Random Forest arrojó una ROC del 98%, siete puntos porcentuales más que la regresión logística. Estamos muy contentos con este resultado.

En 2018, los reguladores estaban preocupados por medir el riesgo de los modelos debido a las pérdidas económicas causadas por algunos modelos. Para abordar este problema, empleamos poderosas técnicas de validación, como validación cruzada k-fold, bootstrapping, jackknifing, kappa, matrices de confusión y estadísticas de poder discriminante (Gini, ROC, KS, Kullback-Leibler, etc.). Medimos el riesgo del modelo eliminando la mejor variable y midiendo la nueva ROC, lo que resultó en una caída predecible de la ROC. El ROC de la regresión logística cayó significativamente del 91% al 77%. Esta reducción en el poder discriminante afectó posteriormente la precisión del PD.



En 2017, creamos modelos de aprendizaje profundo feed-forward. La República de China fue del 80%, sólo 3 puntos porcentuales más que la regresión logística. La arquitectura de la red neuronal tenía 4 capas ocultas y poco más de 1000 neuronas. A pesar del importante esfuerzo computacional, no fue suficiente para mejorar la República de China.

Entonces, en 2018, trabajamos duro para optimizar los hiperparámetros, incluidas las funciones de activación, la cantidad de capas ocultas, la cantidad de neuronas, la tasa de aprendizaje, etc. El mejor modelo de red neuronal tuvo un ROC del 86%, mejorando en 9 puntos porcentuales en comparación con la regresión logística.

En 2019, utilizamos una red neuronal convolucional para mejorar la ROC de nuestro modelo. Excluimos la mejor variable y obtuvimos un impresionante ROC del 95%.

En 2020, implementamos técnicas SMOTE para datos desequilibrados. También utilizamos técnicas avanzadas de abandono y detención temprana. Además, a pedido de nuestros clientes, incorporamos técnicas de inteligencia artificial explicables, como la biblioteca shap, para asegurar que nuestros modelos fueran interpretables.

En 2021, comenzamos a utilizar técnicas probabilísticas de aprendizaje automático, como redes neuronales bayesianas, para medir el riesgo de los parámetros en nuestros modelos. Descubrimos que la red neuronal bayesiana convolucional solo mejoró ligeramente con respecto a la red neuronal convolucional normal.

Comenzamos a explorar el campo de la computación cuántica y la mecánica cuántica en 2021. En 2022, experimentamos con varias bibliotecas de Python y utilizamos técnicas de aprendizaje automático cuántico. Nuestro equipo desarrolló nuestro primer modelo cuántico, la máquina cuántica de vectores de soporte, que resultó ser una mejora con respecto al SVC tradicional. Además, diseñamos un modelo híbrido, una red neuronal convolucional cuántica, que logró una ROC del 97% en una muestra excluyendo la mejor variable. Este fue, con diferencia, nuestro mejor modelo.

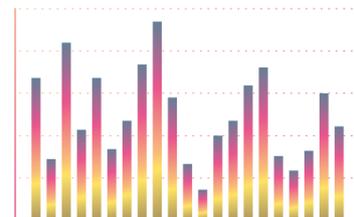
En 2023, exploramos modelos tradicionales de aprendizaje automático probabilístico, como las redes neuronales bayesianas GAN, para crear datos sintéticos. También estamos probando clasificadores variacionales, redes tensoriales y redes neuronales bayesianas cuánticas en el dominio cuántico. Hemos utilizado redes tensoriales en redes neuronales para reducir el número de parámetros de 1.000.000 a solo 1.000. Esto no sólo genera una mayor velocidad de cálculo sino que también reduce el riesgo del modelo.

Nuestros modelos han sido probados tanto en ordenadores tradicionales como en ordenadores cuánticos en la nube, aunque tenemos un número limitado de qubits. Sin embargo, hemos trabajado para mejorar la velocidad de las computadoras tradicionales.

La próxima revolución cuántica está a la vuelta de la esquina y los bancos deben estar preparados para gestionar los riesgos y beneficios de las nuevas computadoras cuánticas.

En 2024, trabajaremos con Gen AI porque puede generar datos sintéticos que imitan las distribuciones de datos del mundo real. Esto puede aumentar el conjunto de datos de entrenamiento, mejorando el rendimiento del modelo al proporcionar un conjunto de datos más rico que cubre más escenarios potenciales. La generación de IA puede equilibrar el conjunto de datos generando muestras sintéticas de la clase subrepresentada, lo que lleva a predicciones más precisas y justas. La Gen AI puede crear conjuntos de datos realistas pero sintéticos que no se asignan directamente a individuos reales, lo que permite el desarrollo y las pruebas de modelos de una manera que preserve la privacidad y cumple con regulaciones como GDPR en la UE.

5. ¿Cuál es el impacto económico de aumentar el poder discriminativo en el modelo de calificación crediticia de un banco?



Supongamos que un banco, XYZ, utiliza un modelo tradicional, como la regresión logística, para desarrollar un modelo de calificación crediticia para la cartera minorista. Esta calificación crediticia respalda el paso de decisión crediticia de un proceso de originación de crédito. El banco necesita utilizar la curva de pérdidas para determinar el nivel de aceptación, que es un umbral numérico utilizado como puntuación de corte. Esta curva se calcula mediante una fórmula específica.

$$\text{Pérdida } i = (\text{fpi} * \text{PérdidaC} + \text{fni} * \text{PérdidaB}) / (\text{tni} + \text{fpi} + \text{fni} + \text{tpi})$$

Dónde:

Lossi = pérdida en el umbral i,
fpi = número de falsos positivos en el umbral i,
fni = número de falsos negativos en el umbral i,



entonces yo = número de verdaderos negativos en el umbral i ,

tp yo = verdaderos positivos en el umbral i .

LossC = Pérdida por aceptar un falso positivo.

LossB = Pérdida por rechazar un falso negativo.

Para estimar esto, necesitamos estimar la República de China porque calcula matrices de confusión para varios valores de umbral. Una matriz de confusión contiene el número de casos de verdadero positivo (tp), falso negativo (fn), falso positivo (fp) y verdadero negativo (tn).

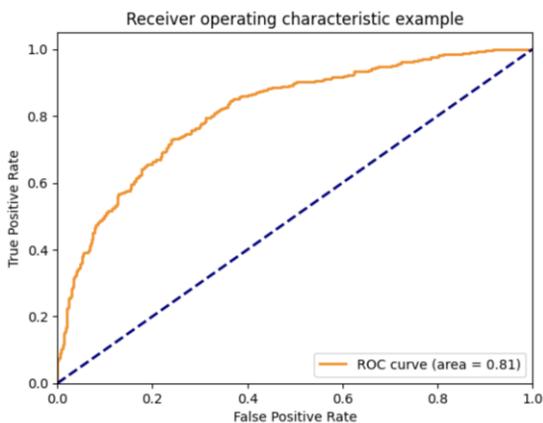
El banco ha determinado que la variable LossC representa la LGD de pérdida en caso de incumplimiento promedio de la cartera minorista. Esto se debe a que representa el costo de aceptar un falso positivo, que se refiere a una transacción que ha sido aceptada por la calificación crediticia pero luego incumplida. La LGD se representa como un porcentaje de la exposición total en el momento del incumplimiento.

LossB representa el costo de oportunidad, el beneficio potencial perdido por una oportunidad perdida, de rechazar una transacción que se pensaba que era predeterminada pero que resultó ser buena.

El banco decidió utilizar otros modelos de aprendizaje automático y aprendizaje profundo para aumentar su poder discriminativo. Examinemos los resultados.

El valor de LossC es 40%, lo que significa LGD=40%, y el LossB es 20%, el costo de oportunidad.

Para empezar, el primer paso es estimar la ROC (característica operativa del receptor) de cada modelo.



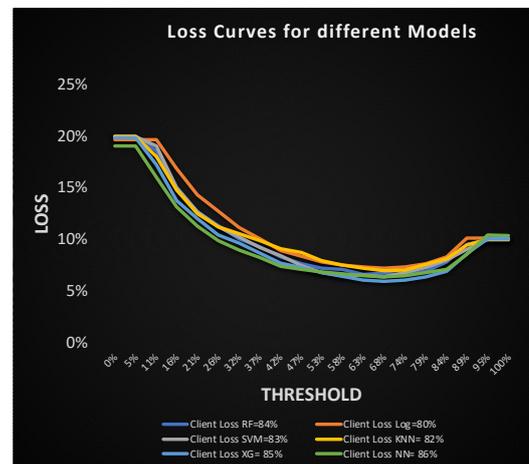
Cuadro 1: Gráfico de la República de China

El segundo paso es estimar fn , fp , tp , tn y la curva de pérdidas, como se muestra en la Tabla 1 a continuación.

Table with 8 columns: Threshold, TN, FP, FN, TP, Specificity, Sensitivity, Client Loss. It lists 20 rows of data for different thresholds from 0 to 19.

Tabla 1: Pérdida de clientes para cada umbral

El segundo gráfico (anexo 2) muestra que cada curva representa un modelo con su respectiva ROC. La selección de corte es donde la curva de pérdidas tiene el valor mínimo. El punto de corte se sitúa en el umbral de puntuación de aproximadamente el 70%.



Cuadro 2: Curvas de pérdida para diferentes modelos y ROC

Comparemos las curvas de pérdida del modelo de regresión logística con las de los modelos Machine Learning ML en el umbral de corte. La ROC para el modelo de regresión logística es del 80%; mientras tanto, los modelos ML tienen mayores valores de ROC. Las diferencias porcentuales para los K vecinos más cercanos, Support Vector Machine, Random Forest, Xgboosting y Neural Network en comparación con el modelo de regresión logística son 3,5%, 7,4%, 8,0%, 14,6% y 15,4%, respectivamente, como mostramos en el Anexo 3. Esto indica que los modelos de Machine Learning han reducido la pérdida en un margen significativo, que oscila entre el 3,5% y el 15,4%.



Cuadro 3: Comparativo de reducción de pérdidas

pérdidas, mejorar la gestión de riesgos y generar beneficios tangibles. Sin embargo, es importante tener en cuenta que seleccionar un modelo basándose únicamente en el resultado de la característica operativa del receptor (ROC) es insuficiente. La explicabilidad y transparencia del modelo, junto con las pruebas de validación avanzadas, también son factores cruciales para determinar la incertidumbre de los parámetros y la estabilidad del modelo en el tiempo.

El banco XYZ tiene fuertes incentivos para implementar modelos de aprendizaje automático (ML) basados en sus parámetros. Hacerlo podría potencialmente reducir las

Desde hace más de 15 años, Fermac Risk utiliza tecnologías de vanguardia para crear modelos cada vez más precisos y avanzados. Te invitamos a explorar nuestros programas de formación.