



# IFRS 9: Modelización del Riesgo Crédito 2.0

Whitepaper Fermac Risk

Abril 2024



## Prefacio

El campo de la modelización del riesgo crediticio está experimentando una profunda transformación, impulsada por los rápidos avances en la inteligencia artificial y la computación cuántica. A medida que las instituciones financieras se adaptan a la nueva norma contable IFRS 9, que requiere estimaciones prospectivas de las pérdidas crediticias esperadas, la necesidad de modelos predictivos sofisticados nunca ha sido mayor.

Este curso IFRS 9: Modelización de riesgo crédito 2.0 representa un esfuerzo pionero para aprovechar el poder de la IA generativa y la computación cuántica para el Modelización de riesgo crediticio IFRS 9. Al combinar técnicas de vanguardia de aprendizaje automático, finanzas computacionales y ciencia de la información cuántica, nuestro objetivo es equipar a los participantes con las herramientas y el conocimiento necesarios para desarrollar modelos de última generación para estimar las pérdidas crediticias esperadas.

La IA generativa, como las redes generativas adversarias (GAN) y los codificadores automáticos variacionales (VAE), ofrece un marco poderoso para aprender las relaciones complejas y no lineales entre los factores macroeconómicos y los parámetros de riesgo crediticio. Al basarse en datos históricos y generar escenarios económicos realistas, estos modelos pueden ayudar a las instituciones a realizar pruebas de resistencia a sus carteras y estimar las pérdidas crediticias esperadas en una amplia gama de condiciones plausibles.


La computación cuántica, con su capacidad de realizar ciertos cálculos exponencialmente más rápido que las computadoras clásicas, es inmensamente prometedora para la modelización del riesgo crediticio. Desde la optimización y la simulación hasta el aprendizaje automático, los algoritmos cuánticos pueden potencialmente revolucionar la forma en que construimos, calibramos e implementamos modelos de riesgo crediticio. Este curso explorará el estado actual del arte en computación cuántica para finanzas y brindará experiencia práctica con kits de desarrollo de software cuántico.

A lo largo del curso, los participantes trabajarán en proyectos y estudios de casos del mundo real, aplicando técnicas de IA generativa y computación cuántica a los desafíos de Modelización de riesgo crediticio de la IFRS 9. Obtendrán habilidades prácticas en la preparación de datos, desarrollo, validación e interpretación de modelos, así como una comprensión del panorama regulatorio y las mejores prácticas para la gestión de riesgos de modelos.

Este curso reúne a expertos del mundo académico y de la industria y ofrece una oportunidad única de mantenerse a la vanguardia de la innovación en la modelización del riesgo crediticio. Si usted es un profesional de riesgos, un científico de datos o un entusiasta de la computación cuántica, lo invitamos a unirse a nosotros en este emocionante viaje para remodelar el futuro de las finanzas.

---

### 1. Modelización de la probabilidad de incumplimiento (PD) de por vida según la IFRS 9 para carteras minoristas



Estimar la probabilidad de incumplimiento (PD) de por vida según la IFRS 9 en carteras minoristas es una tarea crítica para las instituciones financieras, que involucra

una variedad de metodologías, desde modelos de supervivencia tradicionales hasta análisis de supervivencia avanzados basados en aprendizaje automático. Estos enfoques tienen como objetivo predecir la probabilidad y el momento del incumplimiento a lo largo de la vida de los instrumentos financieros. Aquí, profundizaremos en los modelos de supervivencia tradicionales, como la regresión de Cox, y los contrastaremos con enfoques de aprendizaje automático de supervivencia, como el análisis de supervivencia con aprendizaje profundo, bosques aleatorios de supervivencia y aumento de la supervivencia.



## Modelos de supervivencia tradicionales (p. ej., regresión de Cox)

El modelo de riesgos proporcionales de Cox es un enfoque fundamental en el análisis de supervivencia tradicional. Está diseñado para modelar el tiempo hasta que ocurre un evento, considerando el efecto de varias covariables en este momento. Características clave incluir :

- Supuesto de riesgos proporcionales: Asume que el efecto de las covariables sobre el riesgo es multiplicativo y constante en el tiempo.
- Semiparamétrico: el modelo de Cox es semiparamétrico porque no hace suposiciones sobre la forma de la función de riesgo de referencia, lo que permite flexibilidad en el Modelización de los datos del tiempo transcurrido hasta el evento.
- Interpretabilidad: proporciona índices de riesgo para cada covariable, ofreciendo información sobre el riesgo relativo de incumplimiento asociado con diferentes características del prestatario o del préstamo.
- Limitaciones: Es posible que el supuesto de riesgos proporcionales no se cumpla en todos los conjuntos de datos y que el modelo tenga dificultades con relaciones no lineales complejas o datos de alta dimensión.

## Enfoques de aprendizaje automático de supervivencia

Los modelos de aprendizaje automático de supervivencia amplían el análisis de supervivencia tradicional al incorporar técnicas de aprendizaje automático para manejar relaciones e interacciones más complejas entre covariables, sin algunos de los supuestos restrictivos de los modelos tradicionales.

### Análisis de supervivencia del aprendizaje profundo

- Arquitectura: utiliza redes neuronales para modelar datos de supervivencia. La flexibilidad de las redes neuronales permite modelar relaciones e interacciones complejas y no lineales entre datos de alta dimensión.
- Modelos de ejemplo: DeepSurv , un modelo de aprendizaje profundo inspirado en el modelo de Cox pero capaz de capturar relaciones más complejas sin el supuesto de riesgos proporcionales .
- Fortalezas: puede manejar conjuntos de datos grandes y complejos, incluidos datos no estructurados como texto o imágenes, lo que potencialmente mejora la precisión de la predicción.
- Limitaciones: Menos interpretable que los modelos tradicionales y requiere grandes cantidades de datos y recursos computacionales.

## Random Forest de supervivencia

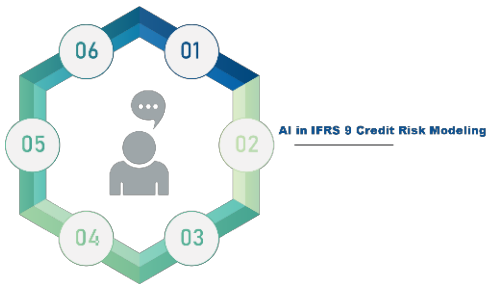
- Extensión de Random Forest: este enfoque aplica el concepto de Random Forest al análisis de supervivencia, creando un conjunto de árboles de supervivencia que pueden adaptarse a la censura.
- Ventajas: Más flexible y capaz de capturar interacciones complejas y relaciones no lineales sin asumir riesgos proporcionales.
- Interpretabilidad: ofrece cierto nivel de interpretabilidad a través de medidas de importancia variable, pero es menos transparente que la regresión de Cox.

## Comparación y consideraciones

- Precisión frente a interpretabilidad: los modelos de supervivencia basados en el aprendizaje automático a menudo proporcionan una mayor precisión al capturar patrones complejos en los datos, pero a costa de una interpretabilidad reducida en comparación con los modelos tradicionales como la regresión de Cox.
- Recursos computacionales: los modelos avanzados de aprendizaje automático requieren más potencia computacional y datos para entrenarse de manera efectiva, lo que podría ser una limitación para algunas instituciones.
- Consideraciones regulatorias: La elección del modelo también podría verse influenciada por los requisitos regulatorios para la transparencia y explicabilidad del modelo. Los modelos tradicionales como la regresión de Cox se entienden y aceptan bien en contextos regulatorios, mientras que los modelos de aprendizaje automático pueden requerir una justificación adicional.
- Requisitos de datos: los modelos de aprendizaje automático, especialmente el aprendizaje profundo, se benefician de grandes conjuntos de datos para aprender patrones complejos. Sin embargo, esto podría no ser necesario para los modelos tradicionales de análisis de supervivencia, que funcionan bien con conjuntos de datos estructurados más pequeños.

En conclusión, la elección entre modelos de supervivencia tradicionales y enfoques de aprendizaje automático de supervivencia depende de necesidades específicas, incluida la complejidad del conjunto de datos, los requisitos regulatorios, la interpretabilidad deseada del modelo y los recursos computacionales disponibles. Si bien los modelos tradicionales como la regresión de Cox proporcionan una base sólida con buena interpretabilidad, los enfoques de aprendizaje automático de supervivencia ofrecen mayor flexibilidad y rendimiento a costa de una mayor complejidad y una menor transparencia.

## 2. IA en la Modelización del riesgo crediticio IFRS 9



Las técnicas de inteligencia artificial han revolucionado el enfoque de Modelización del riesgo crediticio de la IFRS 9, ofreciendo herramientas sofisticadas para predecir el riesgo crediticio de manera más precisa y eficiente. La IFRS 9, con su enfoque en las pérdidas crediticias esperadas (ECL), exige modelos que puedan evaluar el riesgo crediticio actual y futuro, incorporando una amplia gama de escenarios económicos. Así es como se aplican la IA y el aprendizaje automático (ML):

### Preparación y gestión de datos

- Integración de Big Data: los modelos de IA pueden manejar vastos conjuntos de datos de diversas fuentes, incluidas fuentes no tradicionales como redes sociales, patrones de transacciones e incluso imágenes satelitales, lo que proporciona una base más rica para la evaluación de riesgos.
- Limpieza y procesamiento de datos: las herramientas y algoritmos automatizados pueden preprocesar datos, manejar valores faltantes y garantizar que los datos introducidos en los modelos estén limpios y sean relevantes.

### Ingeniería y selección de características

- Ingeniería de funciones automatizada: la IA puede automatizar la creación de nuevas funciones que capturen mejor los matices del riesgo crediticio, mejorando significativamente el rendimiento del modelo.
- Reducción de dimensionalidad: se utilizan técnicas como PCA (Análisis de Componentes Principales) para reducir el número de variables, centrándose en aquellas más relevantes para predecir el riesgo crediticio.

### Modelización predictiva

- Algoritmos de aprendizaje automático avanzados: se han empleado modelos como el aumento de gradiente,

las redes neuronales y los métodos de conjunto para predecir la probabilidad de incumplimiento (PD), la pérdida en caso de incumplimiento (LGD) y la exposición en caso de incumplimiento (EAD) con mayor precisión.

- Aprendizaje profundo para patrones complejos: los modelos de aprendizaje profundo pueden capturar relaciones e interacciones no lineales complejas entre variables que los modelos tradicionales podrían pasar por alto.

### Incorporación de información prospectiva

- Análisis y simulaciones de escenarios: los modelos de IA pueden incorporar múltiples escenarios económicos y pronosticar su impacto en las ECL, lo que permite un ajuste dinámico de las provisiones por riesgo crediticio.
- Procesamiento del lenguaje natural (NLP): la IA puede analizar artículos de noticias, informes financieros y otros datos textuales para extraer opiniones e indicadores que pronostican las tendencias económicas que afectan el riesgo crediticio.

### Validación de modelos y pruebas retrospectivas

- Pruebas de modelos automatizadas: la IA puede automatizar el proceso de validación del modelo, incluidas las pruebas retrospectivas con datos históricos y las pruebas de estrés en diversos escenarios.
- Aprendizaje y adaptación continuos: los modelos de IA pueden aprender continuamente de nuevos datos, mejorando su precisión con el tiempo y ajustándose a los factores de riesgo emergentes.

### Cumplimiento normativo e informes

- Transparencia y explicabilidad: a pesar de su complejidad, los modelos de IA para la IFRS 9 deben ser interpretables para satisfacer los requisitos regulatorios, empleando técnicas como SHAP (explicaciones aditivas de Shapley) para explicar las predicciones.

### Informes automatizados


- La IA puede agilizar la generación de informes regulatorios, asegurando el cumplimiento de los requisitos de la IFRS 9 a través de documentación detallada de las evaluaciones y provisiones de riesgos.

La IA para la Modelización de riesgo crediticio de la IFRS 9 no consiste solo en emplear la tecnología más avanzada. Se trata de integrar estas tecnologías en el ecosistema de la institución financiera para mejorar la toma de decisiones, garantizar el cumplimiento normativo y, en última instancia, gestionar el riesgo



crediticio de manera más eficaz en un panorama económico en constante cambio.

### 3. IA para pruebas de estrés del riesgo crediticio



La IA se puede utilizar de varias maneras para realizar pruebas de tensión del riesgo crediticio. A continuación, se detallan algunos pasos y consideraciones clave:

**Preparación de datos:** recopile datos históricos sobre carteras de crédito, incluidas las características de los préstamos, información del prestatario y variables macroeconómicas. Asegúrese de que los datos sean limpios, consistentes y cubran un período suficiente, incluidas las condiciones económicas normales y estresadas.

**Generación de escenarios:** para crear escenarios de estrés realistas, utilice técnicas de inteligencia artificial como redes generativas adversarias (GAN) o codificadores automáticos variacionales (VAE). Estos modelos pueden aprender de datos históricos y generar escenarios económicos nuevos y plausibles que capturen posibles crisis o shocks.

**Selección de funciones:** aplique técnicas de aprendizaje automático como árboles de decisión, bosques aleatorios o regresión regularizada para

identificar las variables más relevantes que impactan el riesgo crediticio. Esto ayuda a centrar las pruebas de resistencia en los factores clave del rendimiento de la cartera.

**Desarrollo de modelos:** cree modelos de IA para estimar la relación entre las variables macroeconómicas y los parámetros de riesgo crediticio, como la probabilidad de incumplimiento (PD), la pérdida en caso de incumplimiento (LGD) y la exposición en caso de incumplimiento (EAD). Técnicas como redes neuronales, máquinas de vectores de soporte o aumento de gradiente pueden capturar relaciones complejas y no lineales.

**Validación de modelos:** evalúe el rendimiento y la estabilidad de los modelos de IA utilizando técnicas como validación cruzada, pruebas retrospectivas y

análisis de sensibilidad. Asegúrese de que los modelos sean sólidos, interpretables y estén alineados con el conocimiento del dominio.

**Pruebas de estrés:** aplique los modelos de IA a los escenarios de estrés generados para estimar el impacto potencial en las carteras de crédito. Esto incluye calcular las pérdidas esperadas, los requisitos de capital y otras métricas de riesgo en cada escenario.


**Interpretación e informes:** Analice los resultados de las pruebas de estrés para identificar vulnerabilidades, evaluar la resiliencia de la cartera e informar las decisiones de gestión de riesgos. Utilice la visualización de datos y la generación de lenguaje natural para crear informes claros y procesables para las partes interesadas.

#### Algunos beneficios de utilizar IA para las pruebas de estrés del riesgo crediticio incluyen:

- Manejo de conjuntos de datos grandes y complejos y captura de relaciones no lineales
- Generar una amplia gama de escenarios de estrés plausibles más allá de la experiencia histórica.
  - Automatizar y acelerar el proceso de pruebas de estrés, permitiendo análisis más frecuentes o ad hoc.
  - Proporcionar información explicable sobre los factores que impulsan el riesgo crediticio en situaciones de estrés.

Sin embargo, es importante utilizar la IA de manera responsable, garantizando que los modelos sean transparentes, justos y alineados con los requisitos regulatorios. La supervisión y el juicio humanos siguen siendo cruciales para validar modelos, interpretar resultados y tomar decisiones de gestión de riesgos.

### 4. Computación cuántica para Stress Testing de riesgo de crédito



La computación cuántica tiene el potencial de revolucionar las simulaciones de Monte Carlo para las pruebas de tensión del riesgo crediticio. Aprovechando los principios de la mecánica cuántica, las



computadoras cuánticas pueden realizar ciertos cálculos exponencialmente más rápido que las computadoras clásicas. Así es como se puede aplicar la computación cuántica a las simulaciones de Monte Carlo para las pruebas de tensión del riesgo crediticio:

## Generación cuántica de números aleatorios:

- Las computadoras cuánticas pueden generar números aleatorios verdaderos utilizando la aleatoriedad inherente de los sistemas cuánticos
  - Esto puede mejorar la calidad y eficiencia de la generación de números aleatorios requerida para las simulaciones de Monte Carlo.
  - Los generadores cuánticos de números aleatorios pueden producir rápidamente grandes volúmenes de números aleatorios de alta calidad, mejorando la precisión y la velocidad de las simulaciones.

## Estimación de amplitud cuántica:

- La estimación de amplitud cuántica (QAE) es una técnica que puede estimar la probabilidad de eventos raros de manera más eficiente que los métodos clásicos de Monte Carlo.
  - En las pruebas de estrés del riesgo crediticio, la QAE se puede utilizar para estimar la probabilidad de incumplimiento (PD) u otros eventos crediticios raros con mayor precisión y menos simulaciones.
  - QAE aprovecha el principio de superposición cuántica para codificar y manipular amplitudes de probabilidad, lo que permite una convergencia más rápida hacia estimaciones precisas.

## Optimización cuántica para la generación de escenarios:

- Los algoritmos de optimización cuántica, como el recocido cuántico o los solucionadores propios cuánticos variacionales (VQE), se pueden utilizar para generar escenarios óptimos de pruebas de estrés.
  - Estos algoritmos pueden explorar de manera eficiente un amplio espacio de escenarios posibles e identificar los más relevantes e impactantes para la evaluación del riesgo crediticio.
  - La optimización cuántica puede ayudar a descubrir patrones y dependencias ocultos en los datos, lo que lleva a escenarios de pruebas de estrés más completos y realistas.

## Aprendizaje automático cuántico para Modelización de riesgo crediticio:

- Los algoritmos de aprendizaje automático cuántico, como las redes neuronales cuánticas o las máquinas de vectores de soporte cuánticos, se pueden integrar en los modelos de riesgo crediticio.

- Estos algoritmos pueden potencialmente aprender patrones y relaciones complejos en datos crediticios de manera más eficiente que los métodos clásicos de aprendizaje automático.

- El aprendizaje automático cuántico puede mejorar el poder predictivo y la capacidad de generalización de los modelos de riesgo crediticio utilizados en simulaciones de pruebas de estrés.

## Aceleración cuántica para simulaciones a gran escala:

- Las computadoras cuánticas pueden potencialmente realizar ciertos cálculos, como operaciones matriciales y resolución de sistemas lineales, mucho más rápido que las computadoras clásicas.
  - Esta aceleración cuántica puede reducir significativamente el tiempo de cálculo necesario para simulaciones Monte Carlo a gran escala en pruebas de estrés de riesgo crediticio.
  - Los algoritmos cuánticos, como el algoritmo HHL para sistemas lineales o la transformada cuántica de Fourier, se pueden aprovechar para acelerar componentes clave del proceso de simulación.

## Enfoques híbridos cuánticos-clásicos:

- En el corto plazo, los enfoques híbridos cuánticos y clásicos que combinen las fortalezas de la computación cuántica y clásica probablemente sean los más prácticos.
  - Los circuitos cuánticos se pueden utilizar para realizar cálculos específicos dentro de la simulación de Monte Carlo, mientras que las computadoras clásicas manejan el marco general de simulación y el procesamiento de datos.
  - Los enfoques híbridos pueden aprovechar el estado actual del hardware cuántico y al mismo tiempo aprovechar la madurez y escalabilidad de la infraestructura informática clásica.

Es importante señalar que la computación cuántica para las pruebas de estrés del riesgo crediticio sigue siendo un campo emergente, y las implementaciones prácticas pueden enfrentar desafíos relacionados con las limitaciones del hardware cuántico, el desarrollo de algoritmos y la integración con los sistemas de gestión de riesgos existentes. Sin embargo, a medida que las tecnologías cuánticas continúan avanzando, son muy prometedoras para mejorar la eficiencia, la precisión y los conocimientos obtenidos de las simulaciones de

Monte Carlo en las pruebas de tensión del riesgo crediticio.

## 5. Nuestra Experiencia en IFRS 9: Modelización de Riesgo de Crédito 2.0



En 2016, estuvimos entre los pioneros en la formación de modelos de riesgo crediticio para la directiva IFRS 9. Desde entonces, hemos formado a muchos participantes bancarios de todo el mundo. Nuestro curso IFRS 9: Modelización de riesgo crediticio cubre varios modelos econométricos y enfoques clásicos para estimar la PD de por vida, como regresiones logísticas, modelos de supervivencia como la regresión de Cox, la regresión bayesiana y la regresión de datos de panel.

Utilizamos matrices de transición y modelos avanzados, como el modelo de Markov Multiestado, para estimar la PD de por vida. Otro modelo actuarial interesante que utilizamos es el Exogenous Maturity Vintage (EMV) derivado de la metodología de cohorte de período de edad. Además, utilizamos el modelo de factor de riesgo único asintótico (ASRF), que se utiliza para calcular el capital regulatorio de Basilea IV y también se puede utilizar para estimar la PD de por vida.

En 2018, integramos modelos de aprendizaje automático para la estimación de PD y LGD. Estos modelos incluían modelos de redes neuronales, random forest y support vector machine. Para garantizar una comprensión integral del curso, hemos incluido numerosos ejercicios de Python, R y Excel.

Para estimar las pérdidas crediticias esperadas (ECL), incluimos información prospectiva (FLI), que involucra escenarios macroeconómicos. Inicialmente, utilizamos un método que creaba 3 o 5 escenarios para estimar el resultado ponderado por probabilidad. Sin embargo, luego exploramos más escenarios utilizando la simulación de Monte Carlo. Empleamos varios modelos econométricos tradicionales como ARIMA, Vector Autoregresivo (VAR), Vector Error-Correction (VEC) y Vector Autoregresivo Bayesiano (BVAR), entre otros, y explicamos las pruebas estadísticas involucradas en el uso de estos modelos. Estas pruebas incluyen multicolinealidad, heterocedasticidad, autocorrelación serial, detección de series estacionarias, normalidad y valores atípicos.

Los cursos están diseñados para abordar cuestiones relacionadas con la implementación, la falta de datos, las metodologías para determinar aumentos significativos del riesgo crediticio (SICR) y la tipología de overlays utilizadas por las instituciones financieras. Estos overlays pueden incluir las utilizadas durante la crisis de COVID-19, así como los overlays utilizadas para

mitigar las deficiencias de datos. Los cursos también cubrirán los desafíos que plantea la nueva definición de default (DoD) en EBA, la vida útil de las tarjetas de crédito, las matrices de transición de las exposiciones S1, S2 y S3, el backtesting y otros temas relacionados.

Con el surgimiento de nuevas tecnologías, presentamos el curso IFRS 9: Modelización de riesgo crediticio 2.0, donde incorporamos el uso de modelos de IA y computación cuántica para calcular parámetros de riesgo como PD y LGD. Para desarrollar modelos de calificación crediticia minorista, ahora utilizamos modelos de redes neuronales convolucionales en lugar de modelos clásicos de regresión logística, lo que ha dado como resultado un aumento de 15 puntos porcentuales en el ROC. De manera similar, para crear modelos satelitales, comenzamos a comparar los modelos de regresión de Cox con un 68% de ROC con modelos de supervivencia de aprendizaje profundo con un 89% de ROC.

Tener un alto poder discriminante es crucial para lograr resultados de calidad en el backtesting .

Comparamos la regresión multinomial con SVM y modelos de aprendizaje profundo que utilizan funciones de activación softmax. Los modelos ML exhiben una ROC multiclase que es 18 puntos porcentuales mayor que la de la regresión multinomial.

Observamos mejoras significativas en la Modelización de LGD utilizando aprendizaje automático en lugar de modelos econométricos. Las redes neuronales, la regresión forestal aleatoria y SVC/SVR redujeron significativamente los errores de tipo RSME entre los valores estimados y observados.

Hemos estado explorando diferentes métodos para pronosticar la PD y hemos comenzado a utilizar modelos econométricos como ARIMA, SARIMA, VAR, VEC y VARMAX. También los comparamos con modelos de aprendizaje automático como la tradicional memoria a largo plazo y corto plazo (LSTM), y descubrimos que esta última es más precisa que los modelos tradicionales.

Hemos implementado modelos más sofisticados como la Memoria Bayesiana de Corto Plazo. Este modelo nos permite establecer intervalos de confianza basados en distribuciones previas estimadas por expertos. La combinación del juicio de expertos y datos


empíricos permite un mejor control sobre los ajustes realizados por los expertos.

El LSTM cuántico es un modelo cuántico híbrido que permite una convergencia rápida y logra una mayor precisión.

Los modelos de inteligencia artificial generativa, como Transformers, permiten realizar pronósticos mediante procesamiento paralelo y captura de dependencias a largo plazo.

Los modelos Transformers y Quantum LSTM han superado a los modelos LSTM tradicionales en las pruebas retrospectivas. A pesar de requerir grandes volúmenes de datos, pueden permitir a los bancos tomar mejores decisiones.

## 6. Nuestra Experiencia en Pruebas de Estrés en IFRS 9



Utilizamos métodos de pruebas de estrés del riesgo crediticio, como el modelo del Banco de Finlandia, que se basa en el modelo de capital económico Credit Portfolio Views. Esto nos ayuda a crear escenarios de PD (Probabilidad de Incumplimiento) y variables macroeconómicas mediante simulación Monte Carlo. Además, creamos modelos de dependencia PD-LGD, inspirados en el modelo de Vasicek. Estos modelos nos ayudan a crear escenarios de PD y LGD con variables macroeconómicas.

Estamos descubriendo que técnicas de computación cuántica como la estimación de amplitud cuántica (QAE) se pueden utilizar para estimar la probabilidad de incumplimiento (PD) con mayor precisión y menos simulaciones que las simulaciones clásicas de Monte Carlo. Quantum Monte Carlo proporciona una aceleración cuadrática en comparación con Monte Carlo clásico, es decir, para obtener cierta precisión en el resultado, necesitamos  $n$  operaciones en una computadora clásica, mientras que solo  $\sqrt{n}$  operaciones en una computadora cuántica.

Otra opción avanzada en la que estamos trabajando es el recocado simulado, una técnica probabilística para aproximar el óptimo global de una función determinada. Esta técnica proporciona un marco sólido para realizar pruebas de tensión a las carteras de

crédito. Simular condiciones extremas del mercado y evaluar su impacto en el riesgo crediticio ayuda a evaluar la resiliencia de la cartera e identificar vulnerabilidades potenciales.

Otra forma de crear escenarios de estrés realistas es utilizar técnicas de Gen AI, como redes generativas

adversarias (GAN) o codificadores automáticos variacionales (VAE). Estos modelos pueden aprender de datos históricos y generar escenarios económicos nuevos y plausibles que capturen posibles crisis o shocks.

Los resultados obtenidos con estos nuevos modelos muestran mejoras significativas respecto a los modelos tradicionales, mayor velocidad, precisión y ampliación de escenarios plausibles y robustos.

Las pruebas de tensión son un aspecto importante de la IFRS 9, que trata de la contabilidad de instrumentos financieros. Las pruebas de tensión según la IFRS 9 implican evaluar el impacto de escenarios económicos adversos sobre las pérdidas crediticias esperadas (PCE) de los activos financieros. Estos son los puntos clave que explicamos durante el curso a considerar al realizar pruebas de estrés bajo la IFRS 9:

### Diseño de escenarios:

- Desarrollar una gama de escenarios económicos adversos plausibles que podrían afectar el riesgo crediticio.
  - Considere factores macroeconómicos como el crecimiento del PIB, las tasas de desempleo, las tasas de interés y las tensiones sectoriales específicas.
  - Incorporar información prospectiva y juicio de expertos en el diseño de escenarios.
  - Utilizando técnicas de IA cuántica y genética, defina la gravedad y la duración de los escenarios de estrés en función de datos históricos y expectativas futuras.

### Modelización ECL:

- Utilice los modelos ECL de la IFRS 9 existentes como punto de partida para las pruebas de estrés.
  - Evaluar la sensibilidad de las estimaciones de ECL a cambios en las variables macroeconómicas y otros factores de riesgo.
  - Modificar los modelos ECL para incorporar escenarios de estrés y su impacto en los parámetros de riesgo de crédito (PD, LGD, EAD)
  - Considerar la segmentación de la cartera y aplicar factores de estrés con un nivel de granularidad adecuado.





## Datos y suposiciones:

- Garantizar la disponibilidad y calidad de los datos necesarios para las pruebas de estrés, incluidos datos históricos e información prospectiva.
  - Revisar y validar los supuestos utilizados en los modelos ECL, como estimaciones de parámetros de riesgo, tasas de curación y valores de garantía.
  - Evaluar el impacto de los escenarios de estrés en los supuestos clave y realizar los ajustes necesarios para reflejar la gravedad del estrés.

## Puesta en escena y migración:

- Evaluar la potencial migración de activos financieros entre las etapas de la IFRS 9 (Etapa 1, Etapa 2, Etapa 3) bajo escenarios de estrés.
  - Considere los factores desencadenantes de un aumento significativo del riesgo crediticio (SICR) y cómo pueden verse afectados por las condiciones de estrés.
  - Evaluar el efecto del estrés sobre los ratios de cobertura y la proporción de activos en cada etapa

## Ajustes de superposición y gestión:

- Considerar la necesidad de realizar ajustes de superposición para capturar los riesgos que no se reflejan adecuadamente en los modelos de ECL.
  - Aplicar el criterio de la gerencia y ajustes cualitativos para garantizar que los resultados de las pruebas de estrés sean razonables y estén alineados con las expectativas de los expertos.
  - Documentar y justificar cualquier ajuste superpuesto realizado en los resultados de las pruebas de estrés.

## Informes y gobernanza:

- Presentar los resultados de las pruebas de estrés a la alta dirección y a los comités pertinentes, incluido el impacto en las ECL, el capital regulatorio y las métricas clave de desempeño.
  - Proporcionar explicaciones claras y concisas sobre la metodología, los supuestos y las limitaciones de las pruebas de estrés.
  - Establecer un marco de gobernanza sólido para las pruebas de estrés, incluidos procesos de validación de modelos, revisión independiente y aprobación.
  - Utilice los resultados de las pruebas de estrés para informar las decisiones de gestión de riesgos, como el establecimiento del apetito de riesgo, el monitoreo de límites y la planificación de contingencias.

## Análisis de sensibilidad y benchmarking:

- Realizar análisis de sensibilidad para evaluar el impacto de supuestos y escenarios de estrés alternativos en las estimaciones de ECL.
  - Compare los resultados de las pruebas de estrés con los puntos de referencia de la industria y las expectativas regulatorias para garantizar la razonabilidad.
  - Realizar pruebas de estrés inversas para identificar los escenarios que podrían conducir a incumplimientos en el apetito por el riesgo o la adecuación del capital.

---

Las pruebas de resistencia eficaces según la IFRS 9 requieren una combinación de modelos cuantitativos, juicio de expertos y una gobernanza sólida. Es un proceso iterativo que debe revisarse y actualizarse periódicamente para reflejar los cambios en el entorno económico, las características de la cartera y las mejores prácticas en evolución. Los conocimientos adquiridos a partir de las pruebas de tensión pueden ayudar a las instituciones financieras a comprender y gestionar mejor sus exposiciones al riesgo crediticio, mantener reservas de capital adecuadas y garantizar la resiliencia de sus modelos de negocio en condiciones adversas.