



# Futuro financiero: integración de la IA generativa y la computación cuántica en la gestión de activos y pasivos

White Paper de Fermac Risk

Abril 2024



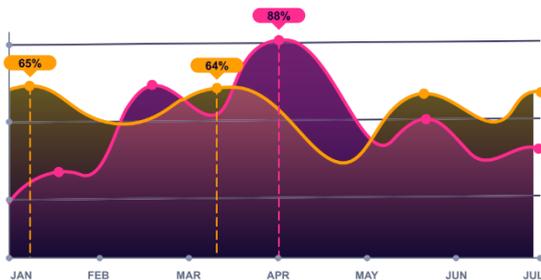


## Prefacio

La gestión de activos y pasivos (ALM) es una función crítica dentro de las instituciones financieras que se centra en gestionar la compleja interacción entre activos, pasivos y partidas fuera de balance. Su objetivo es optimizar la rentabilidad, mitigar los riesgos y garantizar la estabilidad a largo plazo de la organización. En el panorama financiero actual en rápida evolución, los enfoques tradicionales de ALM se ven desafiados por la creciente complejidad de los productos financieros, los requisitos regulatorios y la dinámica del mercado. Aquí es donde entra en juego la integración de la inteligencia artificial (IA) y la computación cuántica, ofreciendo un cambio de paradigma en las prácticas de ALM.

Este curso, "Futuro financiero: integración de la IA generativa y la computación cuántica en la gestión de activos y pasivos" explora las técnicas y metodologías de vanguardia que están transformando el campo de ALM. Aprovechando el poder de la IA y la computación cuántica, las instituciones financieras pueden revolucionar sus estrategias de gestión de riesgos, mejorar la toma de decisiones y desbloquear nuevas oportunidades de crecimiento e innovación.

### 1. ¿Cómo gestionar los Depósitos sin Vencimiento Definido (NMD)?



Los NMD, como las cuentas de ahorro, las cuentas corrientes y las cuentas del mercado monetario, no tienen un vencimiento o fecha de vencimiento fijos, lo que presenta desafíos únicos para administrarlos y modelarlos. Las instituciones financieras necesitan metodologías efectivas para gestionar el riesgo de tasa de interés y predecir el comportamiento de estos depósitos bajo diferentes condiciones. A continuación se presentan varias metodologías clave utilizadas en la gestión y modelización de depósitos sin vencimiento:

#### Análisis de comportamiento

Este enfoque implica analizar datos históricos sobre los patrones de comportamiento de los clientes para pronosticar comportamientos futuros. Las instituciones estudian cómo factores como los cambios en las tasas de interés, las condiciones económicas y los incentivos específicos de las instituciones afectan la entrada y salida de depósitos. Los conocimientos adquiridos pueden

ayudar a predecir la probabilidad de retiros y la duración de los depósitos que probablemente permanecerán dentro de la institución.

#### Estudio de depósitos básicos

Un estudio de depósitos básicos tiene como objetivo determinar la porción "básica" de los depósitos, que se espera que se mantenga estable en el tiempo. Esto implica un análisis estadístico de los niveles históricos de depósitos para comprender su sensibilidad a los cambios en las tasas de interés y las condiciones económicas. Los resultados ayudan a distinguir entre los depósitos centrales estables y las porciones más volátiles, sensibles a factores externos.

#### Análisis de la tasa de decadencia

Esta técnica implica estimar la tasa de decadencia de los depósitos, que es la tasa a la que se espera que los depósitos disminuyan con el tiempo. Al analizar la salida histórica de fondos, las instituciones pueden modelar la rapidez con la que podrían salir los depósitos en el futuro. El análisis de la tasa de caída es crucial para la planificación de la liquidez y la gestión del riesgo de tipos de interés.

#### Análisis de duración

El análisis de la duración en el contexto de las NMD implica estimar la vida promedio de los depósitos bajo diferentes escenarios. Esto puede implicar técnicas de modelado complejas que incorporen



supuestos de comportamiento basados en datos históricos. Comprender la duración de los depósitos sin vencimiento ayuda a alinearlos con las duraciones adecuadas de los activos para gestionar el riesgo de tipos de interés.

## Análisis de segmentación

Los depósitos se segmentan según características como el tipo de cuenta, la demografía del depositante o el comportamiento de las transacciones. Esto permite modelos más matizados que pueden predecir diferentes comportamientos para diferentes segmentos, lo que es particularmente útil para estrategias de marketing personalizadas y gestión de riesgos.

## Modelos de simulación

Los modelos de simulación utilizan los datos y suposiciones de los análisis anteriores para proyectar escenarios futuros. Estos modelos suelen utilizar simulaciones de Monte Carlo para comprender la gama potencial de resultados para los niveles de depósitos en diferentes escenarios de tipos de interés y condiciones económicas. Esto ayuda en las pruebas de estrés y la planificación estratégica.

## Análisis de regresión

Se pueden emplear modelos de regresión para comprender la relación entre factores externos (como tasas de interés e indicadores económicos) y niveles de depósitos. Este método estadístico ayuda a cuantificar la sensibilidad de los depósitos a los cambios en el entorno externo, lo que ayuda en la evaluación de riesgos y la fijación de precios.

## Teoría del precio de opciones

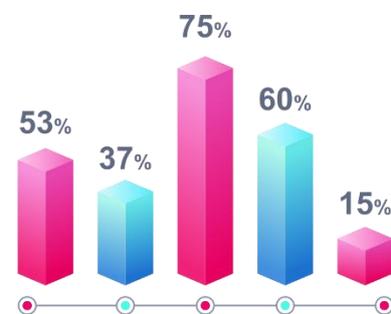
Algunos modelos avanzados tratan la opción de retiro de los depósitos sin vencimiento como una opción incorporada y utilizan técnicas de valoración de opciones para valorar estas opciones. Esto puede proporcionar información sobre el valor económico de los depósitos y ayudar a fijar el precio de los productos y gestionar los riesgos.

## Implementación y Mejora Continua

La implementación de estas metodologías requiere una sólida recopilación de datos, capacidades de

análisis estadístico y un seguimiento y actualización continuos de los modelos a medida que hay nuevos datos disponibles y las condiciones del mercado cambian. La gestión eficaz de los NMD es fundamental para las instituciones financieras, ya que estos depósitos forman una parte importante de su base de financiación. Al emplear estas metodologías, las instituciones pueden comprender mejor los comportamientos de los depósitos, mejorar la gestión de la liquidez, alinear las estrategias de activos y pasivos y mejorar la estabilidad financiera general.

## 2. Uso del aprendizaje automático para modelar depósitos sin vencimiento



ML ofrece metodologías avanzadas y dinámicas para gestionar y modelar NMD en el sector bancario. Al aprovechar las técnicas de ML, las instituciones financieras pueden comprender mejor los comportamientos de los depósitos, predecir tendencias futuras y optimizar las estrategias de gestión de riesgos. A continuación se muestran algunas metodologías clave de aprendizaje automático utilizadas para los NMD:

### Pronóstico de series temporales

Los modelos de aprendizaje automático como ARIMA (media móvil integrada autorregresiva), LSTM (memoria larga a corto plazo) y otros modelos de aprendizaje profundo predicen eficazmente los niveles futuros de depósitos basándose en datos históricos de series de tiempo. Estos modelos pueden tener en cuenta las tendencias, la estacionalidad y los comportamientos cíclicos de los flujos de depósitos, proporcionando a los bancos pronósticos precisos para la gestión de la liquidez.



## Análisis de conglomerados

Al utilizar técnicas de agrupación como K-means, agrupación jerárquica o DBSCAN (agrupación espacial de aplicaciones con ruido basada en densidad), las instituciones pueden segmentar a sus depositantes en grupos significativos según patrones de comportamiento, frecuencia de transacciones, montos de depósito y sensibilidad a los cambios en las tasas de interés. Esta segmentación ayuda a personalizar las estrategias de marketing y optimizar la oferta de servicios.

## Análisis de supervivencia

Los modelos de análisis de supervivencia, normalmente utilizados en ingeniería de confiabilidad y atención médica, se pueden adaptar para estimar la "vida útil" o la duración de los depósitos antes del retiro. Técnicas como el modelo de riesgos proporcionales de Cox pueden ayudar a predecir el tiempo hasta que se retira un depósito, lo cual es crucial para gestionar los riesgos de liquidez y tipos de interés.

## Modelos de regresión

Se utilizan técnicas de regresión avanzadas, incluida la regresión logística y la regresión cresta/lazo, para comprender la relación entre el comportamiento de los depositantes y diversos predictores, como indicadores macroeconómicos, cambios de política interna o tasas de interés competitivas. Estos modelos ayudan a ajustar las estrategias comerciales basándose en conocimientos predictivos.

## Bosques aleatorios y redes neuronales

Estos modelos de aprendizaje conjunto se utilizan tanto para tareas de clasificación como de regresión. Son particularmente útiles para predecir el comportamiento de los depositantes al aprender patrones e interacciones complejos entre múltiples variables sin la necesidad de una especificación explícita, lo que suele ser un desafío en los modelos econométricos tradicionales.

## Detección de anomalías

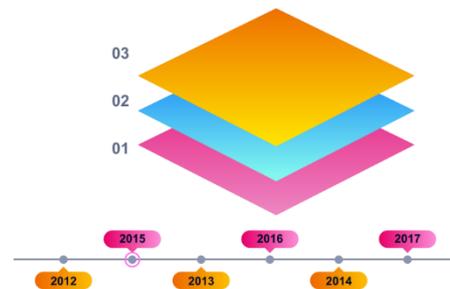
El uso de algoritmos de aprendizaje no supervisados para detectar patrones inusuales en las actividades de depósito puede ser fundamental para

identificar fraudes, grandes retiros inesperados u otros comportamientos atípicos. Esto ayuda a garantizar la estabilidad financiera y la respuesta oportuna a riesgos potenciales.

## Procesamiento del lenguaje natural (PNL)

La PNL se puede utilizar para analizar los comentarios y la comunicación de los depositantes para extraer sentimientos y preferencias. Esto puede informar el desarrollo de productos y las mejoras del servicio al cliente. Es particularmente útil para comprender la satisfacción de los depositantes y las posibles razones de la deserción.

## 3. IA generativa para gestionar y modelar depósitos sin vencimiento



de IA generativa ( GenAI ) se pueden aplicar eficazmente para gestionar y modelar NMD en la industria bancaria. Los NMD, como las cuentas de ahorro y las cuentas corrientes, carecen de una fecha de vencimiento contractual y los depositantes pueden retirarlos en cualquier momento, lo que dificulta su modelización y gestión. A continuación se muestran algunas metodologías GenAI que se pueden utilizar para la gestión y el modelado de NMD:

### Generación de datos sintéticos:

- GenAI , como las redes generativas adversarias (GAN) o los codificadores automáticos variacionales (VAE), se pueden utilizar para generar datos NMD sintéticos.
- Estos modelos pueden aprender los patrones y características subyacentes de los datos históricos de NMD y generar muestras de datos sintéticos realistas.
- La generación de datos sintéticos ayuda a aumentar los datos disponibles, abordar problemas de escasez de datos y mejorar la solidez de los modelos NMD.



## Modelado de comportamiento:

- GenAI, como las redes neuronales recurrentes (RNN) o los modelos Transformer, pueden capturar los complejos patrones de comportamiento de los depositantes de NMD.
- Estos modelos pueden aprender de datos históricos para comprender los factores que influyen en el comportamiento de los depositantes, como las tasas de interés, las condiciones económicas y la demografía de los clientes.
- Los bancos pueden predecir mejor los saldos de NMD, anticipar posibles retiros y optimizar sus estrategias de financiación modelando el comportamiento de los depositantes.

## Generación de escenarios y pruebas de estrés:

- GenAI se pueden utilizar para generar escenarios realistas para los saldos de NMD en diversas condiciones económicas y de mercado.
- Los modelos generativos, como GAN o VAE, se pueden entrenar con datos históricos para generar escenarios futuros plausibles, considerando factores como cambios en las tasas de interés, volatilidad del mercado y comportamiento del cliente.
- Estos escenarios generados se pueden utilizar para realizar pruebas de tensión y evaluar el impacto de eventos adversos en los saldos de NMD, lo que permite a los bancos desarrollar estrategias sólidas de gestión de riesgos.

## Modelado de tasas de interés:

- GenAI se pueden aplicar para modelar la relación entre los saldos de NMD y las tasas de interés.
- Los modelos de aprendizaje profundo, como las redes neuronales o las máquinas de impulso de gradiente, pueden aprender las complejas relaciones no lineales entre las tasas de interés y los saldos de NMD a partir de datos históricos.
- Al modelar con precisión la sensibilidad a las tasas de interés de los NMD, los bancos pueden optimizar sus estrategias de fijación de precios, gestionar el riesgo de tasas de interés y tomar decisiones informadas sobre cobertura y gestión de activos y pasivos.

## Segmentación y personalización de clientes:

- GenAI, como los algoritmos de agrupación en clústeres o los mapas autoorganizados, se pueden utilizar para segmentar a los clientes en función de patrones de comportamiento NMD.

- Al identificar distintos segmentos de clientes con características NMD similares, los bancos pueden adaptar sus productos, precios y estrategias de marketing a grupos de clientes específicos.
- GenAI también pueden permitir recomendaciones personalizadas y ofertas específicas basadas en perfiles de clientes individuales, mejorando la satisfacción y retención del cliente.

Al implementar metodologías GenAI para la gestión y modelado de NMD, es crucial considerar la interpretabilidad y explicabilidad de los modelos. Los reguladores y las partes interesadas pueden exigir transparencia para comprender los factores que influyen en el comportamiento de NMD y los supuestos de los modelos. Se pueden utilizar técnicas como los valores de Shapley o las explicaciones independientes del modelo interpretable local (LIME) para proporcionar información sobre el proceso de toma de decisiones del modelo.

Además, la integración de los modelos GenAI en los marcos de gestión de riesgos y sistemas ALM existentes es esencial para una adopción perfecta y una utilización eficaz. La colaboración entre científicos de datos, expertos en el dominio y administradores de riesgos es necesaria para garantizar que los modelos se alineen con los objetivos comerciales y los requisitos regulatorios.

En general, las metodologías GenAI ofrecen herramientas poderosas para gestionar y modelar NMD, lo que permite a los bancos obtener conocimientos más profundos, tomar decisiones basadas en datos y optimizar sus estrategias de gestión de riesgos de liquidez y tasas de interés.

## 4. Pruebas de estrés en la cartera bancaria IRRBB



Las pruebas de estrés son un componente crítico del IRRBB. Implica someter el balance del banco a varios escenarios hipotéticos de estrés para evaluar



el impacto potencial sobre las ganancias, el valor económico y la adecuación del capital. Las pruebas de tensión en el IRRBB tienen como objetivo identificar vulnerabilidades, cuantificar pérdidas potenciales y garantizar la resiliencia del banco ante movimientos adversos de las tasas de interés. A continuación se muestran algunos aspectos clave de las pruebas de estrés en IRRBB:

## Diseño de escenarios:

- Los escenarios de tensión deberían captar una gama de shocks de tasas de interés y cambios en la curva de rendimiento plausibles pero severos.
- Los escenarios pueden incluir cambios paralelos (por ejemplo, +/-200 puntos básicos), cambios no paralelos (por ejemplo, pronunciamiento o aplanamiento de la curva de rendimiento) y eventos de estrés históricos o hipotéticos.
- Los escenarios deben considerar el perfil de riesgo específico del banco, la combinación de productos y las condiciones del mercado.

## Sensibilidad del margen de intereses (NII):

- La sensibilidad del NII analiza el impacto de los cambios en las tasas de interés en los ingresos netos por intereses del banco durante un horizonte temporal específico (por ejemplo, 12 meses).
- Considera las brechas de repreciación, los descuentos de vencimientos y las opciones incorporadas en los activos y pasivos del banco.
- Las pruebas de tensión evalúan la posible compresión o expansión de las NII en diferentes escenarios de tipos de interés.

## Sensibilidad del Valor Económico del Patrimonio (EVE):

- La sensibilidad del EVE mide la variación del valor actual de los activos, pasivos y partidas fuera de balance del banco bajo diferentes escenarios de tipos de interés.
- Capta el impacto a largo plazo de los cambios en las tasas de interés sobre el valor económico del banco.
- Las pruebas de estrés evalúan la potencial erosión del EVE y sus implicaciones para la adecuación de capital y solvencia del banco.

## Supuestos de comportamiento:

- Las pruebas de tensión deberían incorporar supuestos de comportamiento para los depósitos sin vencimiento, los pagos anticipados y otras opciones implícitas.

- El modelado NMD debe considerar la estabilidad, rigidez y elasticidad del saldo de depósitos en escenarios de estrés.
- Los modelos de pago anticipado deben tener en cuenta la sensibilidad de las velocidades de pago anticipado a los cambios en las tasas de interés y al comportamiento de los prestatarios.

## Agregación e informes:

- Los resultados de las pruebas de tensión deben agregarse en diferentes líneas de negocio, carteras y factores de riesgo.
- Los informes deben proporcionar un resumen claro y conciso de los resultados de las pruebas de resistencia, incluidas métricas de riesgo clave, incumplimientos de límites y acciones de gestión.
- Los resultados deben comunicarse a la alta dirección, a la junta directiva y a las partes interesadas relevantes para una toma de decisiones informada.

## Integración con el apetito por el riesgo y sus límites:

- Los resultados de las pruebas de tensión deben integrarse en el marco de apetito de riesgo del banco y en el proceso de fijación de límites.
- Las declaraciones y límites del apetito por el riesgo deben considerar el impacto potencial de los escenarios de estrés en las métricas del IRRBB.
- Los incumplimientos del apetito o de los límites de riesgo deberían desencadenar acciones de gestión y procedimientos de escalamiento adecuados.

## Pruebas de estrés inverso:

- Las pruebas de estrés inverso comienzan con un resultado adverso predefinido (por ejemplo, compresión significativa de NII o erosión EVE) y funcionan hacia atrás para identificar los escenarios de estrés que podrían conducir a tal resultado.
- Ayuda a identificar las vulnerabilidades del banco y los posibles puntos de ruptura.
- Las pruebas de estrés inversas pueden informar estrategias de mitigación de riesgos y planes de contingencia.

## Validación y Backtesting:

- Los modelos y supuestos de las pruebas de tensión deben validarse y someterse a pruebas retrospectivas periódicamente.
- La validación garantiza la precisión, confiabilidad y adecuación de la metodología de las pruebas de estrés y de los supuestos.
- Las pruebas retrospectivas comparan los resultados reales con las proyecciones de las pruebas de estrés.

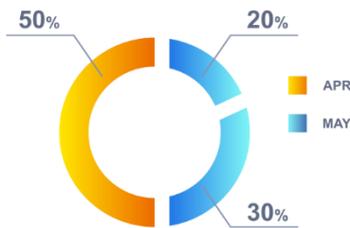


para evaluar el desempeño del modelo e identificar áreas de mejora.

- Las pruebas de tensión en IRRBB son un proceso iterativo que requiere un refinamiento y una adaptación continuos a las condiciones cambiantes del mercado, los requisitos regulatorios y el perfil de riesgo del banco. Debería ser parte integral del marco general de gestión de riesgos del banco, informando las decisiones estratégicas, las estrategias de mitigación de riesgos y la planificación de capital.

Las pruebas de tensión efectivas en IRRBB permiten a los bancos identificar y gestionar proactivamente los riesgos de tasas de interés, garantizar una capitalización adecuada y mantener la estabilidad financiera frente a posibles escenarios adversos. Es esencial que los bancos cuenten con metodologías sólidas de pruebas de estrés, una infraestructura de sistemas y datos adecuada y personal capacitado para realizar pruebas de estrés significativas y esclarecedoras.

### 5. Soluciones de computación cuántica para pruebas de estrés en IRRBB



Las pruebas de tensión del riesgo de tipos de interés en la cartera bancaria (IRRBB) mediante computación cuántica son un área emergente que combina los principios de la computación cuántica con las metodologías tradicionales de pruebas de tensión. La computación cuántica ofrece el potencial de una importante aceleración computacional y la capacidad de resolver problemas de optimización complejos, lo que puede resultar beneficioso en el contexto de las pruebas de estrés IRRBB. Así es como se puede aplicar la computación cuántica a las pruebas de estrés del IRRBB:

#### Cuántica:

- Los algoritmos cuánticos, como el algoritmo de Shor para factorización y el algoritmo de Grover para búsqueda, pueden proporcionar una aceleración

exponencial en comparación con los algoritmos clásicos.

- En el contexto de las pruebas de resistencia del IRRBB, se pueden utilizar algoritmos cuánticos para acelerar el cálculo de métricas de riesgo, como la sensibilidad del ingreso neto de intereses (NII) y la sensibilidad del valor económico del capital (EVE).
- La aceleración cuántica puede permitir a los bancos realizar pruebas de estrés más extensas y granulares en un período de tiempo más corto, lo que permite una evaluación de riesgos y una toma de decisiones más rápidas.

#### Optimización cuántica para la generación de escenarios:

- Los algoritmos de optimización cuántica, como el algoritmo de optimización aproximada cuántica (QAOA) y 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 vasto espacio de escenarios posibles e identificar los más relevantes e impactantes para las pruebas de estrés IRRBB.
- La optimización cuántica puede ayudar a descubrir patrones y dependencias ocultos en los datos, lo que lleva a escenarios de estrés más completos y realistas.

#### Aprendizaje automático cuántico para modelado del comportamiento:

- Los algoritmos de aprendizaje automático cuántico, como las redes neuronales cuánticas (QNN) y las máquinas de vectores de soporte cuántico (QSVM), se pueden utilizar para modelar patrones de comportamiento complejos de depósitos sin vencimiento (NMD) y otras partidas del balance.
- Estos algoritmos pueden potencialmente aprender relaciones y dependencias complejas en los datos de manera más eficiente que los métodos clásicos de aprendizaje automático.
- El aprendizaje automático cuántico puede mejorar la precisión y el poder predictivo de los modelos de comportamiento utilizados en las pruebas de estrés IRRBB.

#### Simulaciones de Monte Carlo mejoradas cuánticamente:

- Las simulaciones de Monte Carlo se utilizan comúnmente en las pruebas de tensión IRRBB para evaluar el impacto de los shocks de las tasas de interés en el balance del banco.
- Las simulaciones de Monte Carlo mejoradas cuánticamente, que aprovechan técnicas como la



estimación de amplitud cuántica y el muestreo cuántico, pueden proporcionar potencialmente una aceleración cuadrática en comparación con los métodos de Monte Carlo clásicos.

- Las simulaciones Monte Carlo más rápidas y eficientes pueden permitir a los bancos realizar un mayor número de simulaciones y obtener estimaciones de riesgo más precisas.

### Optimización inspirada en lo cuántico para la mitigación de riesgos:

- Los algoritmos de optimización de inspiración cuántica, que son algoritmos clásicos que imitan los principios de la optimización cuántica, se pueden utilizar para identificar estrategias óptimas de mitigación de riesgos.
- Estos algoritmos pueden buscar de manera eficiente las mejores posiciones de cobertura, asignación de activos o estrategias de fijación de precios para minimizar el impacto de los shocks de las tasas de interés en el balance del banco.
- La optimización inspirada en la tecnología cuántica puede ayudar a los bancos a tomar decisiones de gestión de riesgos más informadas y eficaces en el contexto del IRRBB.

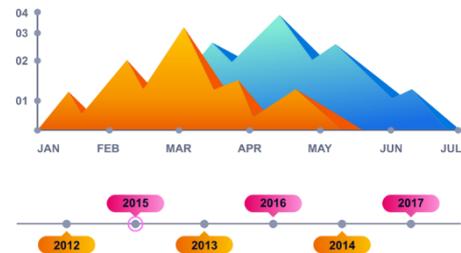
Es importante señalar que la aplicación de la computación cuántica a las pruebas de estrés IRRBB aún se encuentra en sus primeras etapas, y las implementaciones prácticas pueden enfrentar desafíos relacionados con las limitaciones actuales del hardware cuántico y la necesidad de corrección de errores cuánticos. Además, la integración de la computación cuántica con los sistemas regulatorios y los sistemas de gestión de riesgos existentes requiere una consideración cuidadosa.

Sin embargo, a medida que las tecnologías cuánticas continúan avanzando, los beneficios potenciales de la computación cuántica en las pruebas de estrés IRRBB son significativos. La computación cuántica puede permitir a los bancos realizar pruebas de estrés más completas y precisas, descubrir riesgos ocultos y tomar decisiones de gestión de riesgos mejor informadas.

Para aprovechar el poder de la computación cuántica en las pruebas de estrés IRRBB, los bancos deben invertir en investigación y desarrollo, colaborar con proveedores de tecnología cuántica y desarrollar la experiencia y la infraestructura necesarias. A medida que el campo madure, podemos esperar ver más aplicaciones prácticas y

estudios de casos que demuestren el valor de la computación cuántica en las pruebas de estrés del IRRBB y otras áreas de la gestión de riesgos financieros.

## 6. Pruebas de estrés del riesgo de liquidez



Las pruebas de tensión del riesgo de liquidez son un ejercicio crucial para que los bancos evalúen su capacidad para resistir eventos adversos de liquidez y garantizar que tengan suficientes activos líquidos para cumplir con sus obligaciones. Implica someter la posición de liquidez del banco a varios escenarios hipotéticos de estrés y evaluar el impacto sobre los flujos de efectivo, las fuentes de financiamiento y los índices de liquidez. Estos son los aspectos clave de las pruebas de estrés del riesgo de liquidez:

### Diseño de escenarios:

- Desarrollar una variedad de escenarios de estrés que capturen shocks de liquidez tanto idiosincrásicos (específicos de los bancos) como sistémicos (que afectan a todo el mercado).
- Considere eventos históricos, escenarios hipotéticos y una combinación de ambos.
- Los escenarios deben incluir diversos grados de gravedad, duración y velocidad del deterioro de la liquidez.
- Ejemplos de escenarios: una crisis de financiación específica de un banco, una crisis de liquidez en todo el mercado, un evento combinado de estrés crediticio y de liquidez.

### Análisis de flujo de caja:

- Proyecte las entradas y salidas de efectivo en cada escenario de estrés en diferentes horizontes temporales (por ejemplo, 30 días, 90 días, 1 año).
- Considere los perfiles de vencimiento contractual, los supuestos de comportamiento (por ejemplo, tasas de retiro de depósitos) y los compromisos fuera de balance.
- Evaluar la capacidad del banco para generar suficientes entradas de efectivo para cumplir con



sus obligaciones y mantener reservas de liquidez adecuadas.

## Estabilidad de financiación:

- Evaluar la estabilidad y concentración de las fuentes de financiamiento bajo escenarios de estrés.
- Analizar el impacto en los depósitos básicos, la financiación mayorista y el acceso a los mercados de financiación a corto plazo.
- Evalúe el riesgo de retiros de fondos, mayores costos de financiamiento y posibles perturbaciones del mercado.

## Ratio de cobertura de liquidez (LCR) y Ratio de financiación estable neta (NSFR):

- Calcule el impacto de los escenarios de estrés sobre el LCR y el NSFR del banco.
- LCR mide la capacidad del banco para satisfacer las necesidades de liquidez a corto plazo utilizando activos líquidos de alta calidad (HQLA).
- NSFR evalúa el perfil de financiación estable del banco en un horizonte de un año.
- Garantice el cumplimiento de los requisitos mínimos reglamentarios incluso en condiciones de estrés.

## Plan de Financiamiento de Contingencia (CFP):

- Evaluar la eficacia de la PPC del banco para mitigar el estrés de liquidez.
- Identifique fuentes potenciales de financiamiento contingente, como servicios del banco central, ventas de activos o líneas de liquidez de otras instituciones.
- Evaluar la viabilidad y rapidez de acceso a fuentes de financiamiento contingente bajo escenarios de estrés.

## Gestión de Liquidez Intradía:

- Poner a prueba la capacidad del banco para gestionar las necesidades de liquidez intradía, particularmente en los sistemas de pago y liquidación.
- Evaluar el impacto de las interrupciones operativas, los incumplimientos de las contrapartes o las fallas del sistema en las posiciones de liquidez intradía.
- Garantizar suficientes colchones de liquidez intradía y procesos operativos sólidos para hacer frente a condiciones de tensión.

## Apetito y límites del riesgo de liquidez:

- Establecer declaraciones claras de apetito por el riesgo de liquidez y límites de tolerancia al riesgo.

- Definir métricas de riesgo de liquidez e indicadores de alerta temprana para monitorear las posiciones de liquidez.
- Establecer procedimientos de escalamiento y acciones de gestión desencadenadas por incumplimientos de límites o deterioro de las condiciones de liquidez.

## Gobernanza e informes:

- Involucrar a la alta dirección y a la junta directiva en la revisión y aprobación de los supuestos, escenarios y resultados de las pruebas de estrés.
- Informe periódicamente los resultados de las pruebas de estrés, incluidas métricas de riesgo clave, incumplimientos de límites y acciones de gestión propuestas.
- Utilice los resultados de las pruebas de estrés para informar decisiones estratégicas, estrategias de mitigación de riesgos y planificación de contingencias.

---

Las pruebas de tensión del riesgo de liquidez deben ser un proceso continuo, con actualizaciones periódicas de escenarios, supuestos y modelos para reflejar los cambios en el perfil de riesgo del banco, las condiciones del mercado y los requisitos regulatorios. Es esencial contar con sistemas sólidos de gestión de datos, personal capacitado y marcos de gobernanza efectivos para respaldar pruebas de estrés significativas y procesables.

Las pruebas de tensión de liquidez eficaces permiten a los bancos identificar vulnerabilidades potenciales, cuantificar el impacto de eventos adversos y desarrollar estrategias para mitigar el riesgo de liquidez. Ayuda a garantizar que los bancos mantengan suficiente liquidez para cumplir con sus obligaciones, incluso en condiciones de tensión, y contribuye a la resiliencia general del sistema bancario.