



# Tecnologías avanzadas en XVA y Modelización del Riesgo de Contraparte

White Paper de Fermac Risk

Abril 2024



## Prefacio

En el acelerado panorama financiero actual, la modelización correcta y eficiente del riesgo de crédito de contraparte y XVA (Ajuste de Valoración Crediticia CVA, Ajuste de Valoración de Financiación FVA, Ajuste de Valoración de Capital KVA, etc.) se ha vuelto cada vez más crítica. Aunque los métodos tradicionales son útiles, a menudo se enfrentan a desafíos en términos de complejidad computacional, velocidad y capacidad para manejar los volúmenes cada vez mayores de datos y la complejidad del mercado. Aquí es donde las tecnologías de vanguardia como la Inteligencia Artificial (IA) y la Computación Cuántica pueden desempeñar un papel vital en la mejora del proceso de modelado.

Este curso tiene como objetivo dotar a los participantes de los conocimientos y habilidades necesarios para utilizar la IA y la computación cuántica en el riesgo de crédito de contraparte y el modelado XVA.

### 1. Modelización del Riesgo de Crédito de Contraparte (CCR) y ajuste del valor X (XVA)



La modelización del riesgo de crédito de contraparte (CCR) y el ajuste del valor X (XVA) son áreas complejas en las finanzas que se centran en la valoración y gestión del riesgo asociado con los derivados extrabursátiles (OTC) y otros instrumentos financieros. La aparición de tecnologías avanzadas como la Inteligencia Artificial (IA) y la Computación Cuántica ofrece nuevos enfoques a estos desafíos, mejorando los modelos y metodologías tradicionales.

#### Riesgo de Crédito de Contraparte (CCR)

CCR es el riesgo de que la contraparte de un contrato financiero incumpla antes de que expire el contrato y no realice todos los pagos según lo acordado. Este riesgo es particularmente significativo en el contexto de los mercados de derivados OTC, donde los contratos no se negocian en una bolsa centralizada y, por lo tanto, exponen a las partes a un posible incumplimiento de sus contrapartes. La medición y gestión del CCR implica estimar la exposición en caso de incumplimiento (EAD), la probabilidad de incumplimiento (PD) y la pérdida en caso de incumplimiento (LGD).

#### Ajuste del valor X (XVA)

XVA abarca una serie de ajustes realizados a la valoración de contratos de derivados para tener en cuenta diversos riesgos no cubiertos por la valoración simple neutral al riesgo. Estos ajustes incluyen el Ajuste del Valor del Crédito (CVA), que representa el CCR; Ajuste del Valor de la Deuda (DVA); Ajuste del valor de financiación (FVA); Ajuste del Valor del Capital (KVA); y Ajuste del Valor del Margen (MVA), entre otros. Cada ajuste considera los costos y riesgos de ingresar y mantener una operación.

#### IA en modelado CCR y XVA

La IA, y más específicamente el aprendizaje automático y el aprendizaje profundo, pueden mejorar significativamente el modelado de CCR y XVA al:

**Mejora de los modelos de predicción:** la IA puede procesar grandes conjuntos de datos para mejorar la predicción de incumplimientos (PD) y potenciales exposiciones futuras (PFE), incorporando una amplia gama de factores de mercado y no de mercado.

**Manejo de datos complejos:** los modelos de IA son expertos en analizar relaciones complejas y no lineales en datos financieros, incluidos datos no estructurados como artículos de noticias e informes financieros, lo que proporciona una evaluación de riesgos más matizada.

**Automatización y eficiencia:** Automatizar el cálculo de los ajustes XVA puede ahorrar mucho

tiempo y recursos, permitiendo la gestión de riesgos en tiempo real.

**Modelado bajo incertidumbre:** la IA puede ayudar a modelar y simular las posibles trayectorias futuras de las variables del mercado en diversos escenarios, mejorando la solidez de los cálculos XVA.

### Computación cuántica en modelado CCR y XVA

La computación cuántica promete revolucionar el modelado CCR y XVA mediante:

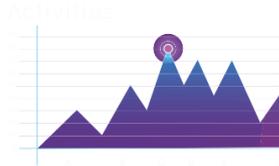
**Acelerar los cálculos:** los algoritmos cuánticos tienen el potencial de realizar cálculos complejos mucho más rápido que las computadoras clásicas, particularmente para tareas como las simulaciones de Monte Carlo, que se utilizan ampliamente en los cálculos CCR y XVA.

**Mejora de la optimización:** las computadoras cuánticas pueden resolver eficientemente problemas de optimización fundamentales para la gestión de riesgos y la optimización del capital regulatorio.

**Mejora de las capacidades de modelado:** la computación cuántica podría permitir el modelado de mercados e instrumentos financieros a un nivel de complejidad y realismo que actualmente es inalcanzable, lo que podría conducir a valoraciones y evaluaciones de riesgos más precisas.

Tanto la IA como la computación cuántica ofrecen beneficios sustanciales al campo de la gestión de riesgos financieros, particularmente en las complejas áreas de modelado CCR y XVA. Si bien la IA ya se está integrando en estas áreas, ofreciendo mejoras en la predicción de riesgos, el análisis de datos y la eficiencia operativa, la computación cuántica sigue siendo en gran medida experimental. Sin embargo, su potencial para transformar los cálculos y modelos financieros es significativo, lo que indica un futuro en el que estas tecnologías podrían desempeñar un papel central en la gestión de riesgos financieros de manera más efectiva y eficiente.

## 2. Deep Learning para la fijación de precios de derivados



El aprendizaje profundo se puede aplicar eficazmente a la fijación de precios de derivados, permitiendo valoraciones más rápidas y precisas en comparación con los métodos numéricos tradicionales. A continuación, se ofrece una explicación de cómo se puede utilizar el aprendizaje profundo para fijar el precio de los derivados, junto con un ejemplo:

### Aproximación de precios:

- Los modelos de aprendizaje profundo, como las redes neuronales profundas, se pueden entrenar para aproximar las funciones de fijación de precios de los derivados.
- Los modelos de aprendizaje profundo pueden proporcionar estimaciones de precios rápidas y precisas al conocer la relación entre los parámetros de entrada (por ejemplo, precios de los activos subyacentes, volatilidades, tasas de interés) y los precios de los derivados correspondientes.
- Los modelos entrenados se pueden utilizar para fijar el precio de los derivados en tiempo real, sin la necesidad de métodos numéricos computacionalmente costosos como las simulaciones de Monte Carlo o los métodos de diferencias finitas.

### Calibración y estimación de parámetros:

- El aprendizaje profundo se puede utilizar para calibrar modelos de precios de derivados y estimar los parámetros del modelo a partir de datos de mercado.
- Las redes neuronales pueden aprender los parámetros óptimos que minimizan la diferencia entre los precios del modelo y los precios de mercado observados.
- Al entrenar modelos de aprendizaje profundo con datos de mercado, se puede lograr una calibración precisa y eficiente, lo que permite que los modelos

de precios reflejen mejor las condiciones del mercado.

### Superficies de volatilidad implícita:

- El aprendizaje profundo se puede aplicar para modelar e interpolar superficies de volatilidad implícita.
- Las redes neuronales pueden aprender los patrones complejos y las dependencias de las volatilidades implícitas en diferentes precios de ejercicio y vencimientos.
- Al entrenar modelos de aprendizaje profundo con datos históricos de volatilidad implícita, se pueden obtener predicciones precisas de las volatilidades implícitas para nuevas combinaciones de ejercicio-vencimiento, lo que facilita la fijación de precios de opciones con diferentes características.

### Cobertura y gestión de riesgos:

- El aprendizaje profundo se puede utilizar para estimar la sensibilidad al riesgo y desarrollar estrategias de cobertura para derivados.
- Las redes neuronales pueden aprender las relaciones entre los factores de riesgo de entrada y los precios de derivados correspondientes o medidas de riesgo (por ejemplo, delta, gamma, vega).
- Al entrenar modelos de aprendizaje profundo con datos históricos o simulados, se pueden obtener sensibilidades de riesgo precisas, lo que facilita una cobertura y una gestión de riesgos eficaces.

Sin embargo, es importante tener en cuenta que el uso del aprendizaje profundo en la fijación de precios de derivados debe ir acompañado de una validación adecuada del modelo, pruebas retrospectivas y evaluación de riesgos. También se debe considerar la interpretabilidad y explicabilidad de los modelos de aprendizaje profundo para garantizar la transparencia y el cumplimiento normativo.

### 3. Exposición al riesgo de crédito de contraparte (CCR)



Calcular la exposición al riesgo de crédito de contraparte (CCR) implica estimar la posible exposición crediticia futura a una contraparte en una transacción de derivados. Esta exposición es un aspecto crucial de la gestión de riesgos en las instituciones financieras, que afecta las decisiones sobre garantías, reservas de capital y estrategias de mitigación de riesgos. El enfoque clásico y los métodos de aprendizaje profundo ofrecen distintas vías para calcular la exposición al CCR, cada una con sus fortalezas y desafíos.

#### Enfoque clásico

El enfoque clásico para calcular la exposición al CCR generalmente implica metodologías como el Método de exposición actual (CEM), el Método estandarizado (SA) y el Método de modelo interno (IMM). Estos métodos tienen sus raíces en marcos regulatorios y técnicas tradicionales de modelado financiero.

**El Método de Exposición Actual (CEM)** calcula la exposición como la suma del costo de reposición actual (si es positivo) y un complemento para la posible exposición futura basada en montos nominales y factores predefinidos.

**El método estándar (SA)** implica factores más matizados en comparación con el CEM, teniendo en cuenta el tipo de derivado, el vencimiento y el tipo de activo subyacente.

**El Método de Modelo Interno (IMM)** permite a las instituciones utilizar sus propios modelos probabilísticos para estimar la exposición futura potencial (PFE) con base en simulaciones de variables de mercado que afectan el valor del derivado.

#### Ventajas:

- **Cumplimiento normativo:** estos métodos son ampliamente aceptados por los organismos reguladores.



- **Transparencia:** Los cálculos y supuestos son sencillos y están bien documentados.
- **Facilidad de comprensión:** familiaridad con la industria financiera, lo que la hace accesible a una amplia gama de profesionales.

#### Desafíos:

- **Simplificación:** Es posible que esto no capture adecuadamente factores de riesgo complejos o eventos extremos.
- **Análisis estático:** generalmente, no tiene en cuenta las condiciones cambiantes del mercado o el comportamiento de las contrapartes a lo largo del tiempo.
- **Demanda computacional:** IMM, por ejemplo, requiere simulaciones extensas y puede consumir muchos recursos.

#### Enfoque de aprendizaje profundo

El aprendizaje profundo ofrece un enfoque más dinámico y basado en datos para estimar la exposición al CCR. Utilizando redes neuronales, los modelos de aprendizaje profundo pueden procesar grandes cantidades de datos de transacciones y de mercado para predecir la posible exposición futura en una amplia gama de condiciones de mercado.

#### Ventajas:

- **Manejo de la complejidad:** puede modelar relaciones e interacciones no lineales entre muchas variables del mercado.
- **Análisis dinámico:** capaz de actualizar predicciones en tiempo real a medida que hay nuevos datos disponibles.
- **Integración de datos:** esto puede incorporar diversos tipos de datos, incluidos datos de mercado, noticias y redes sociales, lo que podría conducir a predicciones de exposición más precisas.

#### Desafíos:

- **Requisito de datos:** los modelos eficaces de aprendizaje profundo requieren grandes conjuntos de datos para la capacitación, que pueden ser difíciles de obtener para todos los instrumentos financieros.
- **Interpretabilidad:** los modelos de aprendizaje profundo a menudo se consideran "cajas negras", lo que dificulta comprender cómo se derivan las

predicciones, lo que puede afectar el cumplimiento normativo.

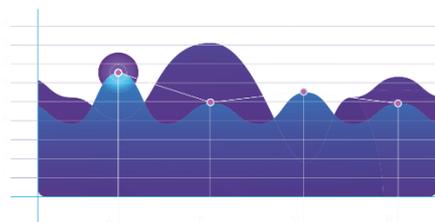
- **Complejidad del modelo:** el desarrollo y la capacitación de modelos de aprendizaje profundo requieren conocimientos especializados y recursos computacionales.

#### Integración de enfoques clásicos y de Deep Learning

Combinando metodologías clásicas y aprendizaje profundo, un enfoque híbrido puede ofrecer una solución equilibrada. Por ejemplo, el aprendizaje profundo puede mejorar el IMM al predecir una distribución más precisa de las posibles condiciones futuras del mercado, que luego pueden introducirse en simulaciones de Monte Carlo para estimar la exposición. Esta integración puede aprovechar las fortalezas de ambas metodologías: los conocimientos basados en datos del aprendizaje profundo y la aceptación regulatoria y la transparencia del enfoque clásico.

En conclusión, mientras que el enfoque clásico ofrece transparencia y cumplimiento normativo, el aprendizaje profundo proporciona un método dinámico basado en datos capaz de capturar relaciones de mercado complejas. La elección entre estos métodos (o una combinación de los dos) depende de las capacidades de la institución, los requisitos regulatorios y la naturaleza específica de la exposición al riesgo crediticio de la contraparte que se evalúa.

## 4. Modelización de XVA con Deep Learning



El aprendizaje profundo puede mejorar significativamente el cálculo de los XVA (ajuste de valoración crediticia, ajuste de valoración de financiación, ajuste de valoración de capital, etc.) de varias maneras. A continuación, se muestran algunos aspectos clave de cómo el aprendizaje

profundo puede resultar beneficioso para los cálculos XVA:

### Modelización de la exposición:

- Se pueden utilizar modelos de aprendizaje profundo, como redes neuronales profundas o redes neuronales recurrentes, para modelar los perfiles de exposición de los contratos de derivados.
- Estos modelos pueden aprender patrones complejos y dependencias de datos históricos del mercado, términos de contratos y factores de riesgo para predecir exposiciones futuras.
- Se pueden obtener estimaciones de exposición precisas para los cálculos de XVA entrenando modelos de aprendizaje profundo en grandes conjuntos de datos de escenarios de mercado y los valores de exposición correspondientes.

### Modelización de compensación (netting) y garantías:

- El aprendizaje profundo se puede utilizar para modelar los efectos de los acuerdos de compensación y garantía en los cálculos de XVA.
- Después de considerar estas técnicas de mitigación de riesgos, las redes neuronales pueden aprender las complejas relaciones entre los conjuntos de compensación, las garantías depositadas y la exposición resultante.
- Al incorporar modelos de compensación y garantía en el marco de aprendizaje profundo, se pueden obtener estimaciones XVA más precisas.

### Generación de escenarios y modelado de factores de riesgo de mercado:

- Los modelos de aprendizaje profundo, como las redes generativas adversarias (GAN) o los codificadores automáticos variacionales (VAE), se pueden utilizar para generar escenarios de mercado realistas para los cálculos XVA.
- Estos modelos pueden aprender las distribuciones y dependencias de los factores de riesgo de mercado, como las tasas de interés, los diferenciales de crédito y la volatilidad, a partir de datos históricos.
- El aprendizaje profundo puede ayudar a capturar toda la gama de posibles exposiciones futuras generando muchos escenarios de mercado plausibles y mejorando la precisión de las estimaciones XVA.

### Cálculo y aproximación eficientes:

- Los modelos de aprendizaje profundo se pueden utilizar como aproximadores eficientes para cálculos XVA complejos.
- En lugar de realizar simulaciones Monte Carlo computacionalmente costosas o soluciones numéricas para cada cálculo XVA, se puede entrenar un modelo de aprendizaje profundo para aproximar los valores XVA directamente.
- Los modelos de aprendizaje profundo pueden proporcionar aproximaciones rápidas y precisas al aprender el mapeo entre los factores de riesgo de entrada y las estimaciones XVA correspondientes, lo que permite cálculos XVA en tiempo real o casi en tiempo real.

Es importante tener en cuenta que, si bien el aprendizaje profundo ofrece un potencial significativo para los cálculos XVA, debe usarse junto con una validación rigurosa, pruebas retrospectivas y supervisión de expertos. Los modelos de aprendizaje profundo deben diseñarse, entrenarse y validarse cuidadosamente para garantizar su precisión, estabilidad y alineación con los principios financieros y los requisitos regulatorios.

En general, el aprendizaje profundo proporciona un marco poderoso para abordar la complejidad, la alta dimensionalidad y la no linealidad inherente a los cálculos XVA. Al aprovechar las capacidades del aprendizaje profundo, las instituciones financieras pueden mejorar potencialmente la precisión, eficiencia y escalabilidad de sus sistemas XVA.

## 5. Computación cuántica para modelizar XVA

|   |    |
|---|----|
| A | 80 |
| B | 70 |
| C | 74 |
| D | 84 |
| E | 50 |

La computación cuántica tiene el potencial de revolucionar los cálculos XVA (Ajuste de valoración crediticia, Ajuste de valoración de financiación, Ajuste de valoración de capital, etc.) aprovechando las propiedades únicas de los sistemas cuánticos. A

continuación, se muestra cómo se puede aplicar la computación cuántica a los cálculos XVA, junto con un ejemplo:

### Simulaciones cuánticas de Monte Carlo:

- Los cálculos de XVA se basan en gran medida en simulaciones de Monte Carlo para estimar las exposiciones esperadas y realizar la agregación de riesgos.
- Las computadoras cuánticas pueden realizar simulaciones cuánticas de Monte Carlo, lo que potencialmente puede proporcionar una aceleración cuadrática en comparación con los métodos clásicos de Monte Carlo.
- Al aprovechar el paralelismo cuántico y la estimación de la amplitud cuántica, las computadoras cuánticas pueden tomar muestras de manera eficiente a partir de distribuciones de probabilidad complejas y estimar métricas XVA con mayor precisión y convergencia más rápida.

### Solucionadores de sistemas lineales cuánticos:

- Los cálculos XVA a menudo implican resolver grandes sistemas de ecuaciones lineales, como los que surgen de la discretización de ecuaciones diferenciales estocásticas o el cálculo de sensibilidades.
- Las computadoras cuánticas pueden potencialmente resolver sistemas lineales exponencialmente más rápido que los métodos clásicos utilizando algoritmos como el algoritmo Harrow-Hassidim-Lloyd (HHL).
- Al codificar el sistema lineal en un estado cuántico y realizar operaciones cuánticas, las computadoras cuánticas pueden encontrar de manera eficiente el vector de solución, lo que permite un cálculo más rápido de las métricas XVA.

### Optimización cuántica para XVA:

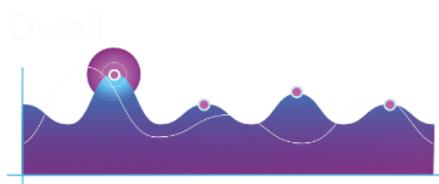
- Los cálculos de XVA a menudo implican problemas de optimización, como encontrar las estrategias de cobertura óptimas o determinar la mejor asignación de garantías.
- Las computadoras cuánticas pueden realizar optimización cuántica utilizando algoritmos como el Algoritmo de optimización aproximada cuántica (QAOA) o los Eigensolvers cuánticos variacionales (VQE).

- Al codificar el problema de optimización en un circuito cuántico y optimizar iterativamente los parámetros, las computadoras cuánticas pueden encontrar soluciones casi óptimas más rápido que los métodos clásicos.

Es importante señalar que la computación cuántica para cálculos XVA sigue siendo un campo emergente y las implementaciones prácticas pueden enfrentar desafíos relacionados con las limitaciones del hardware cuántico, la corrección de errores y la necesidad de enfoques híbridos cuánticos-clásicos. Sin embargo, a medida que las tecnologías cuánticas continúan avanzando, son muy prometedoras para mejorar la eficiencia y precisión de los cálculos XVA.

Los investigadores y las instituciones financieras están explorando activamente el potencial de la computación cuántica para XVA y otras aplicaciones financieras. Si bien es posible que las implementaciones prácticas aún estén en el futuro, se están buscando activamente fundamentos teóricos y desarrollos algorítmicos para aprovechar el poder de la computación cuántica para los cálculos XVA.

## 6. Nuestra Experiencia en Consultoría y Formación



Cubrimos los siguientes casos de estudio y ejercicios en nuestros servicios de consultoría y capacitación: modelado de precios de derivados, cálculos XVA, técnicas de aprendizaje profundo y computación cuántica.

### Precios de Derivados

- **Ejercicio en Python:** fijación del precio de una opción de compra europea. Se puede entrenar una red neuronal profunda con un gran conjunto de datos de parámetros de opciones (por ejemplo, precio subyacente, precio de ejercicio, tiempo hasta el vencimiento, volatilidad, tasa de interés) y sus



precios teóricos correspondientes (calculados utilizando la fórmula de Black-Scholes u otros modelos de precios). Una vez entrenado, el modelo de aprendizaje profundo puede predecir con precisión el precio de nuevas opciones con diferentes combinaciones de parámetros, proporcionando estimaciones de precios instantáneas.

- **Ejercicio en Python:** Calibración del modelo de volatilidad estocástica de Heston a los precios de mercado de las opciones. Se puede entrenar un modelo de aprendizaje profundo para aprender los parámetros óptimos del modelo de Heston (por ejemplo, volatilidad inicial, volatilidad a largo plazo, volatilidad de la volatilidad, correlación) que minimizan la diferencia entre el modelo y los precios de mercado observados. El modelo calibrado se puede utilizar luego para valorar con precisión otras opciones con características similares.

- **Ejercicio en Python:** Modelado de la superficie de volatilidad implícita de las opciones del S&P 500. Un modelo de aprendizaje profundo, como una red neuronal convolucional (CNN), se puede entrenar a partir de datos históricos de volatilidad implícita, con precios de ejercicio y vencimientos como entradas y las correspondientes volatilidades implícitas como salidas. Luego, el modelo entrenado se puede utilizar para interpolar y extrapolar las volatilidades implícitas para cualquier precio de ejercicio y vencimiento determinados, lo que permite fijar precios precisos de opciones en toda la superficie.

### Cálculo de XVA mediante aprendizaje profundo

- **Ejercicio en Python:** Tener una cartera de swaps de tipos de interés. Un aprendizaje profundo La memoria a corto plazo (LSTM) se puede entrenar con datos históricos de tasas de interés, términos de contratos de swap y escenarios de mercado simulados. El modelo aprende a predecir los valores de exposición futuros de los swaps en diferentes momentos. Teniendo en cuenta el riesgo crediticio de la contraparte, estas predicciones de exposición se pueden utilizar para calcular el Ajuste de Valoración Crediticia (CVA) de la cartera.

- **Ejemplo:** Considere una cartera con múltiples contrapartes y acuerdos de compensación. Se

puede entrenar un modelo de retroalimentación de red neuronal para predecir la exposición neta después de considerar los efectos de compensación y las garantías depositadas. El modelo puede aprender las relaciones entre los factores de riesgo subyacentes, los conjuntos de compensación y los montos de las garantías. Esto permite un cálculo más preciso del Ajuste de Valoración de Financiamiento (FVA), considerando los costos de financiamiento asociados con las exposiciones netas.

- **Caso de Estudio:** Considere el cálculo del Ajuste de Valoración de Capital (KVA), que requiere simular las condiciones futuras del mercado para determinar los requisitos de capital. Un modelo de aprendizaje profundo, como una GAN, se puede entrenar con datos históricos del mercado para generar escenarios realistas de tasas de interés, diferenciales de crédito y otros factores de riesgo relevantes. Estos escenarios generados se pueden utilizar para evaluar las necesidades futuras de capital y calcular el KVA de la cartera.

- **Caso de Estudio:** Considere una cartera grande con múltiples clases de activos y una estructura compleja. Dados los factores de riesgo de entrada y las características de la cartera, entrenar una red neuronal profunda para aproximar los valores XVA directamente puede acelerar significativamente el proceso de cálculo. Una vez entrenado, el modelo de aprendizaje profundo puede proporcionar estimaciones XVA instantáneas para nuevos escenarios de mercado o cambios de cartera sin la necesidad de simulaciones que consumen mucho tiempo.

### Computación cuántica para el cálculo XVA

- **Ejercicio en Python:** considere una cartera de swaps de tasas de interés con múltiples contrapartes. Para calcular el ajuste de valoración crediticia (CVA), las simulaciones cuánticas de Monte Carlo pueden estimar la exposición esperada en cada momento futuro. Al preparar un estado cuántico que codifique la distribución de probabilidad de los factores de riesgo subyacentes (por ejemplo, tasas de interés y diferenciales de crédito), se puede aplicar la estimación de la amplitud cuántica para estimar eficientemente la exposición esperada. Esto conduce a cálculos de CVA más rápidos y precisos que los métodos clásicos de Monte Carlo.



- **Caso de Estudio:** Considere el cálculo del Ajuste de valoración de financiación (FVA), que requiere resolver un sistema de ecuaciones para determinar los costos de financiación asociados con una cartera de operaciones. Al formular las ecuaciones de financiación como un sistema lineal y codificarlas en un estado cuántico, el algoritmo HHL se puede aplicar para resolver el sistema de manera eficiente. Esto puede conducir a un cálculo más rápido del FVA y permitir actualizaciones más frecuentes de los costos de financiamiento en respuesta a las condiciones cambiantes del mercado.

- **Ejercicio en Python:** considere la optimización de la asignación de garantías para una cartera de operaciones con múltiples contrapartes para minimizar el Ajuste de valoración del capital (KVA). Al formular el problema de optimización de garantías como un programa cuadrático y codificarlo en un circuito cuántico, se puede aplicar el algoritmo QAOA para encontrar una asignación de garantías casi óptima. Esto puede ayudar a reducir los requisitos de capital y minimizar el KVA de la cartera.

---

Este curso está diseñado para personas que tienen experiencia en análisis cuantitativo, comercio, gestión de riesgos y aprendizaje automático. El objetivo principal de este curso es enseñarle cómo aplicar de manera eficiente métodos de computación cuántica y aprendizaje profundo para la fijación de precios de derivados, riesgo de crédito de contraparte y modelado XVA. Además, también aprenderá cómo integrar sin problemas estas técnicas en sus marcos de gestión de riesgos y precios existentes dentro de su organización.