

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE OCCIDENTE

Departamento de Matemáticas y Física

Desarrollo tecnológico y generación de riqueza sustentable

PROYECTO DE APLICACIÓN PROFESIONAL (PAP)



ITESO

Universidad Jesuita
de Guadalajara

Programa de Modelación Matemática para el Desarrollo de Planes y Proyectos de
Negocio

4J05A Optimización de Programas de inversión en Intermediarios Financieros

Optimización Condicional de Portafolios con Máquinas de Vectores Soporte

PRESENTAN

Programas educativos y Estudiantes

Ingeniería Financia. Rania Paola Aguirre Rodriguez

Ingeniería Financiera. Sergio Renato González Mendoza

Ingeniería Financiera. Luis Adrián López Enríquez

Ingeniería Financiera. Samuel Alejandro Pérez Avalos

Ingeniería Financiera. Francisco Alexander Sotomayor Pineda

Profesor PAP: Sean Nicolás González Vázquez

Tlaquepaque, Jalisco, mayo de 2025

ÍNDICE

Contenido

REPORTE PAP	2
Presentación Institucional de los Proyectos de Aplicación Profesional	2
Resumen	2
1. Introducción.....	3
1.1. Objetivos.....	3
1.2. Justificación.....	4
1.3 Antecedentes.....	5
1.4. Contexto.....	6
2. Desarrollo	7
2.1. Sustento teórico y metodológico	7
2.2. Planeación y seguimiento del proyecto	15
3. Resultados del trabajo profesional.....	23
Resultados de entrenamiento y validación	23
Optimización de Hiperparámetros.....	27
Resultados de backtesting.....	35
4. Reflexiones del alumno o alumnos sobre sus aprendizajes, las implicaciones éticas y los aportes sociales del proyecto	41
Aprendizajes profesionales.....	41
Aprendizajes sociales	42
Aprendizajes éticos.....	42
Aprendizajes en lo personal.....	43
5. Conclusiones.....	49
6. Bibliografía.....	52
Anexos	53

REPORTE PAP

Presentación Institucional de los Proyectos de Aplicación Profesional

Los Proyectos de Aplicación Profesional (PAP) son una modalidad educativa del ITESO en la que el estudiante aplica sus saberes y competencias socio-profesionales para el desarrollo de un proyecto que plantea soluciones a problemas de entornos reales. Su espíritu está dirigido para que el estudiante ejerza su profesión mediante una perspectiva ética y socialmente responsable.

A través de las actividades realizadas en el PAP, se acreditan el servicio social y la opción terminal. Así, en este reporte se documentan las actividades que tuvieron lugar durante el desarrollo del proyecto, sus incidencias en el entorno, y las reflexiones y aprendizajes profesionales que el estudiante desarrolló en el transcurso de su labor.

Resumen

Este proyecto tiene como objetivo optimizar la asignación de activos financieros bajo condiciones de mercado cambiantes utilizando el modelo SVR-CPO. A partir del enfoque original del CPO basado en árboles de decisión con boosting, se proponen mejoras incorporando Support Vector Regression (SVR), redes neuronales, XGBoost y regresión lineal, con el fin de aumentar la precisión predictiva y la estabilidad del modelo.

El modelo utiliza indicadores financieros relevantes y técnicas de machine learning para predecir el Ratio de Sortino, priorizando la reducción del riesgo de pérdidas en entornos volátiles. La metodología incluye la creación de múltiples portafolios con simulaciones aleatorias, el ajuste de hiperparámetros mediante técnicas de optimización y la aplicación de algoritmos de clustering para identificar distintos regímenes de mercado.

Los resultados de las simulaciones de backtesting muestran que el modelo SVR-CPO presenta un rendimiento promedio comparable al modelo CPO original, pero con menor volatilidad. Destaca su robustez ante datos ruidosos y la capacidad de generalización gracias a su enfoque basado en márgenes óptimos. Además, el modelo logra un buen equilibrio entre riesgo y rentabilidad al maximizar el Ratio de Sortino en comparación con otras metodologías tradicionales.

En conclusión, la implementación de SVR en el contexto de CPO permite una mejor adaptación a mercados complejos, ofreciendo una estrategia de inversión más robusta frente a variaciones abruptas y condiciones de alta incertidumbre.

1. Introducción

1.1. Objetivos

El proyecto SVR CPO tiene como fin tomar como base la metodología utilizada por Ernest Chan, en Conditional Portfolio Optimization (CPO) empleando árboles de regresión con boosting para capturar relaciones no lineales y manejar grandes volúmenes de datos. Nuestro objetivo es replicar sus hallazgos y, a su vez, explorar mejoras en la calibración de los hiperparámetros para de esta manera mejorar la precisión predictiva y la estabilidad en la optimización de portafolios bajo condiciones de mercado cambiantes y volátiles. Para lograrlo, se utilizan modelos avanzados de machine learning, como Support Vector Regression (SVR), redes neuronales, árboles de regresión con boosting y regresión lineal. Cada modelo aporta características únicas que contribuyen a un enfoque robusto y adaptable.

Se busca integrar SVR para mejorar el rendimiento en contextos de alta volatilidad y colas pesadas, mientras que las redes neuronales permiten capturar patrones no lineales en grandes volúmenes de datos. Los árboles de regresión con boosting ayudan a modelar

relaciones complejas, y la regresión lineal ofrece una línea base de comparación, permitiendo un análisis claro de la relación entre factores de mercado y retornos esperados.

Esta combinación metodológica proporciona un enfoque integral que permite optimizar la asignación de activos en función de los regímenes del mercado, mejorando tanto la rentabilidad ajustada por riesgo como la capacidad de adaptación a distintos escenarios financieros.

1.2. Justificación

El modelo original del CPO se basa en árboles de decisión con boosting para optimizar la asignación de activos en función de las condiciones cambiantes del mercado.

Dado que el Ratio de Sharpe mide la rentabilidad ajustada por riesgo en función de la volatilidad, buscamos extender el modelo original explorando otros criterios de optimización, como el Ratio de Sortino, que penaliza más severamente las pérdidas en escenarios con colas pesadas y volatilidad asimétrica.

Adicionalmente, la regresión lineal se introduce como un modelo base para establecer una referencia clara y medible respecto a los enfoques más sofisticados. Aunque no es lo suficientemente flexible para capturar relaciones no lineales, su interpretabilidad permite analizar de manera sencilla la relación entre factores de mercado y retornos esperados.

Continuamos la metodología utilizada por Ernest Chan, empleando árboles de regresión con boosting para capturar relaciones no lineales y manejar grandes volúmenes de datos.

Las redes neuronales se integran para capturar relaciones no lineales y patrones profundos en los datos, aprovechando su flexibilidad y capacidad de aprendizaje con grandes volúmenes de información que las hace especialmente adecuadas para escenarios donde

las condiciones son altamente cambiantes y volátiles. Con ello, se logra un modelo capaz de adaptarse a diferentes regímenes.

Finalmente, Support Vector Regression se presenta como una alternativa para mejorar la capacidad del modelo en mercados financieros con colas pesadas y datos ruidosos. Su enfoque basado en la maximización del margen dentro de un intervalo de tolerancia permite una mejor generalización en escenarios con alta volatilidad.

1.3 Antecedentes

Se identifica la necesidad de metodologías cuantitativas para la asignación de activos en portafolios de inversión que superaran las limitaciones de los enfoques clásicos. Uno de los modelos más influyentes es la Teoría Moderna de Portafolios (MPT por sus siglas en inglés) es la de Harry Markowitz, que establece un marco cuantitativo basado en la diversificación eficiente. Su enfoque optimiza la asignación de activos minimizando la varianza del portafolio para un nivel de retorno esperado, construyendo la llamada "frontera eficiente". Sin embargo, este modelo depende de supuestos como la distribución normal de los retornos y la estabilidad de las correlaciones entre activos, lo que puede limitar su aplicabilidad en mercados reales con eventos extremos y cambios estructurales.

El modelo de Black-Litterman extiende la teoría de Markowitz al incorporar expectativas subjetivas de los inversionistas junto con datos históricos, permitiendo una asignación de activos más robusta. Por otro lado, estrategias como la Paridad de Riesgo buscan distribuir el riesgo de manera uniforme entre los activos del portafolio, en lugar de basarse únicamente en la rentabilidad esperada, lo que la hace adecuada para entornos con alta incertidumbre.

Otros enfoques incluyen modelos basados en la optimización robusta, que buscan soluciones menos sensibles a errores en las estimaciones de los parámetros del mercado, y

la optimización de media-CVaR (Valor en Riesgo Condicional), que prioriza la minimización del riesgo de cola, es decir, la probabilidad de pérdidas extremas.

En respuesta a estos desafíos, Ernest Chan, Haoyu Fan, Sudarshan Sawal y Quentin Vivillees presentaron en 2023 el Conditional Portfolio Optimization (CPO) que utiliza gradient-boosted regression trees para adaptar dinámicamente la asignación de activos a distintos regímenes de mercado. En este proyecto se otorga un paso adicional: se reemplaza el gradient boosting por Support Vector Regression (SVR) y se sustituye el Sharpe Ratio por el Sortino Ratio, enfocando la optimización en la penalización de la volatilidad negativa y mejorando la robustez ante datos ruidosos.

1.4. Contexto

El proyecto se desarrolla en el mercado de renta variable de Estados Unidos durante el periodo 2015–2025, un lapso que abarca la recuperación posterior a la pandemia, ciclos de ajuste de tasas y episodios de elevada volatilidad. Para capturar fielmente esta dinámica se seleccionaron 15 activos al azar entre los 100 de mayor capitalización del S&P 500 y se construyó un conjunto mensual de datos combinando sus rendimientos con 11 indicadores de mercado representativos de regímenes de volatilidad, tendencias macroeconómicas y variaciones de sentimiento extraídos de fuentes como Yahoo Finance, FRED, OECD, entre otros, limpiados y alineados en frecuencia para garantizar la consistencia en el entrenamiento de los modelos .

La arquitectura de datos contempla un flujo automatizado que descarga precios históricos y los indicadores seleccionados, procesa valores faltantes homogeneiza series de distinta periodicidad y fusiona todo en un único dataset listo para alimentar los algoritmos de machine learning. Este contexto marcado por la rápida adopción de inteligencia artificial y herramientas innovadoras en la industria, así como por la necesidad de estrategias ágiles capaces de gestionar eficazmente el riesgo de caídas exige metodologías de asignación de capital que se adapten de forma dinámica a los cambios estructurales del mercado. La

propuesta SVR-CPO con Sortino Ratio responde a este desafío al ofrecer asignaciones adaptativas centradas en la protección ante movimientos adversos.

2. Desarrollo

2.1. Sustento teórico y metodológico

Estado del Arte

El CPO ("Conditional Portfolio Optimization: Using Machine Learning to Adapt Capital Allocations to Market Regimes" de Ernest Chan, Haoyu Fan, Sudarshan Sawal y Quentin Vivilles) es un enfoque avanzado para la optimización de portafolios que incorpora información condicional en la toma de decisiones de inversión. A diferencia de los modelos tradicionales de optimización de portafolios, que se basan en distribuciones históricas de retornos y suposiciones estáticas sobre la relación riesgo-retorno, el CPO ajusta dinámicamente la asignación de activos en función de variables de estado, condiciones de mercado y eventos específicos que afectan la estructura de riesgos y oportunidades.

El CPO busca optimizar una función objetivo (usualmente alguna métrica de desempeño) por medio de variables de decisión óptimas, en este caso los pesos de cada activo w , para proponer un portafolio óptimo bajo la situación actual del mercado. Se define como:

$$\mathbf{w}^*(\mathbf{x}) = \arg \max_{\mathbf{w} \in \mathcal{W}} \mathbb{E}[U(R_p)|\mathbf{x}]$$

- $\mathbf{w} \in \mathbb{R}^n$ es el vector de pesos del portafolio.
- $R_p = \mathbf{w}^\top \mathbf{r}$ es el retorno del portafolio.
- $U(R_p)$ es una función de utilidad (como media-varianza o utilidad exponencial).
- $\mathbf{x} \in \mathbb{R}^d$ representa variables de estado del mercado.
- \mathcal{W} es el conjunto de restricciones sobre los pesos.

El modelo incorpora información condicional mediante una función de predicción de retornos ajustada a las condiciones del mercado:

$$\mathbb{E}[\mathbf{r}|\mathbf{x}] = f(\mathbf{x})$$

El riesgo condicional se modela a través de la matriz de covarianza condicional, que puede ser estimada mediante métodos como Shrinkage Estimators o GARCH.

$$\Sigma(\mathbf{x}) = \mathbb{E}[(\mathbf{r} - f(\mathbf{x}))(\mathbf{r} - f(\mathbf{x}))^\top | \mathbf{x}]$$

Usando un criterio de media-varianza condicional, el problema de optimización se reformula como:

$$\mathbf{w}^*(\mathbf{x}) = \arg \max_{\mathbf{w} \in \mathcal{W}} [\mathbf{w}^\top f(\mathbf{x}) - \lambda \mathbf{w}^\top \Sigma(\mathbf{x}) \mathbf{w}]$$

Donde λ controla la aversión al riesgo.

Este enfoque permite una asignación dinámica del capital que responde a cambios en los regímenes de mercado, mejorando la estabilidad y rentabilidad del portafolio.

Gradient-boosted regression trees, el modelo que utiliza CPO. Es una familia de algoritmos usados tanto en clasificación como en regresión basados en la combinación de modelos predictivos débiles (weak learners) -normalmente árboles de decisión- para crear un modelo predictivo fuerte. La generación de los árboles de decisión débiles se realiza de forma secuencial, creándose cada árbol de forma que corrija los errores del árbol anterior.

Los aprendices suelen ser árboles "poco profundos" (shallow trees), de apenas uno, dos o tres niveles de profundidad, típicamente.

El boosting del gradiente es una metodología que se aplica a otro algoritmo de aprendizaje automático. Informalmente, implica dos tipos de modelos:

- un "débil" de aprendizaje automático, que suele ser un árbol de decisión.

- un estado "fuerte" de aprendizaje automático, que consta de varios factores e implementa modelos automáticamente.

En Gradient-boosted, en cada paso, se entrena un nuevo modelo débil para predecir el "error" del modelo sólido actual. El "error" es la diferencia entre la predicción y una etiqueta regresiva.

La generación de los árboles de decisión débiles se realiza de forma secuencial, creándose cada árbol de forma que corrija los errores del árbol anterior.

El boosting de gradientes es iterativo. Cada iteración invoca la siguiente fórmula:

$$F_{i+1} = F_i - f_i$$

Donde:

- F_i es el modelo fuerte del paso i .
- f_i es el modelo débil del paso i .

Propuesta de mejora

Este proyecto propone mejorar la metodología de CPO mediante la implementación de cuatro modelos de ML.

- Regresión Lineal

La regresión lineal modela matemáticamente la variable desconocida o dependiente y la variable conocida o independiente como una ecuación lineal.

En esencia, una técnica de regresión lineal simple intenta trazar un gráfico lineal entre dos variables de datos, x e y . Proporciona una solución interpretable y eficiente para modelar la relación entre variables de estado del mercado y los retornos esperados.

Sirve como base para comparar el desempeño de modelos más complejos.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$$


La estimación de los coeficientes se realiza mediante mínimos cuadrados ordinarios (OLS):

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

- Árboles de regresión con Boosting

El boosting es una técnica de aprendizaje por ensamblado (ensemble learning) que combina múltiples modelos débiles (llamados aprendices débiles) para crear un modelo fuerte. La idea central es que cada nuevo modelo se enfoca en corregir los errores cometidos por los modelos anteriores.

El boosting mejora la precisión predictiva y el rendimiento de los modelos de machine learning, ya que convierte varios aprendices débiles en un modelo de aprendizaje fuerte y único.



Los árboles de decisión son estructuras de datos en el machine learning que dividen el conjunto de datos en subconjuntos cada vez más pequeños en función de sus

características. La idea es que los árboles de decisión dividan los datos reiteradamente hasta que solo quede una clase. Por ejemplo, es posible que el árbol haga una serie de preguntas de sí o no y divida los datos en categorías en cada paso.

El boosting crea un modelo de conjunto mediante la combinación secuencial de varios árboles de decisión débiles. Asigna ponderaciones a las salidas de los árboles individuales. Luego, a las clasificaciones incorrectas del primer árbol de decisión les da una ponderación más alta y una entrada al árbol siguiente. Después de numerosos ciclos, el método boosting combina estas reglas débiles en una única regla de predicción poderosa.

Donde:

$h_m(x)$ es el nuevo árbol de regresión ajustado a los residuos de la iteración anterior.
es el coeficiente de actualización, encontrado minimizando:

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i))$$

Uno de los algoritmos más utilizados en boosting es XGBoost, donde la optimización se realiza mediante una combinación de reducción del gradiente y regularización.


- Redes Neuronales:

Se trata de un tipo de proceso de machine learning llamado aprendizaje profundo, el cual utiliza los nodos o las neuronas interconectados en una estructura de capas que se parece al cerebro humano. Las redes neuronales pueden ayudar a tomar decisiones inteligentes con asistencia humana limitada.

Esto se debe a que pueden aprender y modelar las relaciones entre los datos de entrada y salida que no son lineales y que son complejos. Las redes neuronales pueden comprender datos no estructurados y hacer observaciones generales sin un entrenamiento explícito.

Las redes neuronales profundas, o redes de aprendizaje profundo, tienen varias capas ocultas con millones de neuronas artificiales conectadas entre sí. Un número, denominado peso, representa las conexiones entre un nodo y otro. El peso es un número positivo si un nodo estimula a otro, o negativo si un nodo suprime a otro. Los nodos con valores de peso más altos tienen mayor influencia en los demás nodos.

En teoría, las redes neuronales profundas pueden asignar cualquier tipo de entrada a cualquier tipo de salida. Sin embargo, también necesitan mucho más entrenamiento en comparación con otros métodos de machine learning. Necesitan millones de ejemplos de datos de entrenamiento en lugar de los cientos o miles que podría necesitar una red más simple.



- Support Vector Regression (SVR):

El SVR es una extensión de las Support Vector Machines (SVM), que originalmente se diseñaron para problemas de clasificación. En el caso de la regresión, el objetivo es predecir un valor continuo en lugar de una etiqueta de clase. La idea central del SVR es encontrar

una función que se ajuste a los datos de entrenamiento mientras minimiza el error de predicción, pero con una particularidad: en lugar de intentar pasar por todos los puntos de datos, el SVR permite un margen de error (llamado epsilon-tubo) dentro del cual no se penaliza el error. Esto lo hace más robusto frente a outliers y ruido en los datos.

Optimiza la predicción de retornos minimizando el error dentro de una tolerancia específica, lo que la hace robusta frente a datos ruidosos.

Se adapta bien a mercados financieros, donde los retornos no siguen distribuciones normales y presentan colas pesadas.

$$y = C \sum_{i=1}^n \varepsilon_i^P K(x_i, x_j) + b$$

El objetivo principal es comparar el desempeño de estos modelos en términos de precisión predictiva y robustez en la optimización del portafolio condicional. Al seleccionar el modelo más adecuado, se busca mejorar la eficiencia de la asignación de activos y reducir el riesgo en la toma de decisiones financieras.

- Ratio de Sortino

Además de los cuatro modelos de Machine Learning antes mencionados, se busca implementar el Ratio de Sortino en lugar del Ratio de Sharpe como métrica de rendimiento.

En términos simples, el Ratio de Sortino es un Ratio de Sharpe con unos ligeros ajustes. Recordemos que el Ratio de Sharpe es la diferencia entre la rentabilidad de la cartera menos la rentabilidad de la tasa libre de riesgo, todo esto dividido entre la volatilidad. Para el cálculo de la volatilidad, el Ratio de Sharpe toma en cuenta las variaciones positivas y negativas.

$$\text{Sharpe} = \frac{\mathbb{E}[r_\pi] - r_f}{\sigma_\pi}$$

Por su parte, el Ratio de Sortino mantiene la diferencia entre la rentabilidad del portafolio y la rentabilidad de la tasa libre de riesgo pero realiza un pequeño ajuste en la volatilidad, considerando solamente la volatilidad negativa.

$$\text{Sortino} = \frac{\mathbb{E}[r_\pi] - r_f}{\sigma_d}$$

El Ratio de Sortino indica cuánta rentabilidad esperamos obtener en función del riesgo de caídas que tiene nuestra inversión. Dado que este indicador se centra solamente en la volatilidad negativa, puede dar un mejor punto de vista que el Ratio de Sharpe, ya que la volatilidad positiva resulta ser un beneficio y es algo que a muchos inversionistas, analistas y gerentes de cartera no suele preocupar. Lo que sí suele preocupar a la mayoría de jugadores en el mercado son las caídas que puede llegar a tener nuestro portafolio, y es ahí donde el Ratio de Sortino tiene un mejor desempeño que el Ratio de Sharpe.

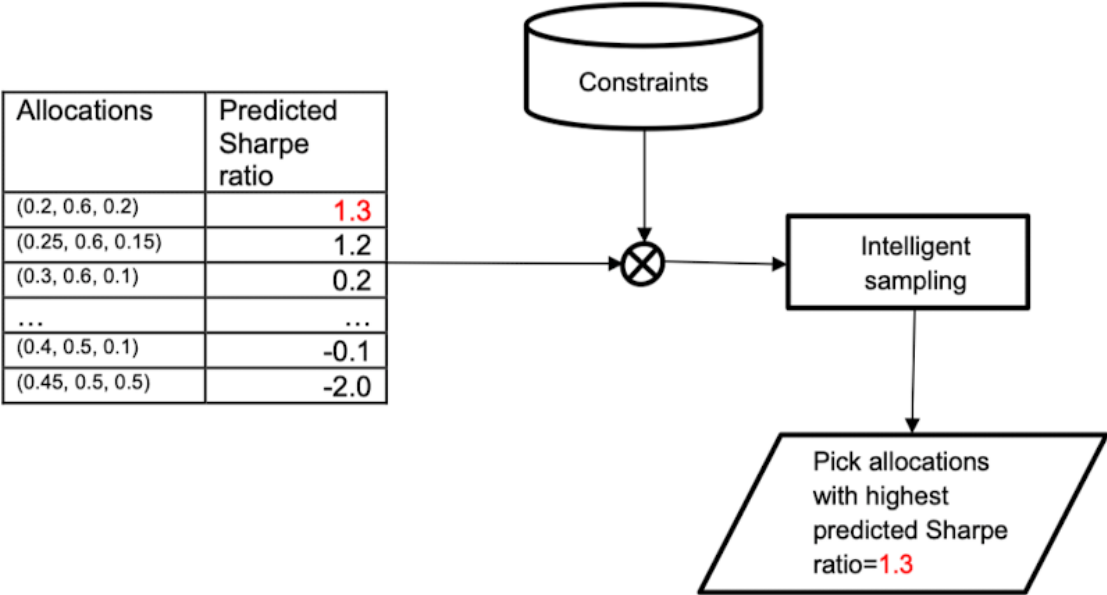
Modelado Preliminar

El modelo original de Conditional Portfolio Optimization, propuesto por Ernest Chan, optimiza la asignación de activos mediante árboles de decisión con boosting, con el objetivo de maximizar el Ratio de Sharpe bajo distintos regímenes de mercado. Este enfoque permite identificar asignaciones óptimas considerando condiciones cambiantes. Pero, ¿cómo es que el Ratio de Sharpe es implementado?

El autor estructura su modelo de optimización en tres etapas principales. La primera etapa consiste en la selección de las características del mercado (feature markets), las cuales contribuirán a la predicción del Ratio de Sharpe.

Posteriormente, a través del algoritmo Gradient-Boosted Regression Trees, el modelo estima el Ratio de Sharpe esperado para cada posible asignación de activos en función de las condiciones del mercado. En este proceso, no se busca predecir los retornos exactos de cada activo seleccionado, sino identificar qué combinaciones de asignaciones generan un mayor Ratio de Sharpe en el futuro.

Finalmente, en la etapa de optimización de la asignación de activos, se evalúan diversas combinaciones de asignación de capital, seleccionando aquella que maximiza el Ratio de Sharpe, lo que permite adaptar el portafolio a los cambios en el mercado de manera eficiente.



2.2. Planeación y seguimiento del proyecto

Descripción del Proyecto

El presente proyecto tiene como objetivo implementar y evaluar la metodología de Conditional Portfolio Optimization (CPO) propuesta por Ernest Chan et al., la cual emplea algoritmos de aprendizaje automático para adaptar las asignaciones de capital en

portafolios financieros según los diferentes regímenes del mercado. A diferencia de los métodos tradicionales que dependen de estadísticas históricas, CPO utiliza características dinámicas del entorno financiero para proponer asignaciones óptimas con base en las condiciones actuales, permitiendo una respuesta más ágil y efectiva a los cambios estructurales del mercado.

Este enfoque resulta especialmente pertinente en contextos de alta volatilidad y transformación económica, ya que ofrece una herramienta robusta para gestionar portafolios de manera dinámica, maximizando el desempeño ajustado por riesgo. A lo largo del proyecto, se siguen varias etapas metodológicas que permiten desde el entendimiento teórico hasta la validación empírica del modelo.

Etapas de Intervención

1ª Etapa – 8 de febrero de 2025

Se realizó una revisión exhaustiva del artículo original de Chan y colaboradores, con el fin de comprender a profundidad el marco conceptual de CPO. Se elaboró un glosario con términos clave y se identificó el software a utilizar (Python, Scikit-learn, Keras, entre otros). Además, se desarrolló una propuesta hipotética de variables (inputs) que conformarán la base de datos para alimentar los modelos de machine learning.

2ª Etapa – 1 de marzo de 2025

Se construyó la base de datos histórica con activos seleccionados y variables de mercado representativas de diferentes regímenes. A partir de ella, se entrenaron cuatro modelos de aprendizaje supervisado: regresión lineal, árboles de decisión con boosting, redes neuronales y soporte vectorial de regresión (SVR). Esto permitió comparar enfoques distintos para predecir métricas de desempeño como el ratio de Sharpe.

3ª Etapa – 22 de marzo de 2025

Se realizó un ajuste de hiperparámetros en cada modelo para optimizar su rendimiento. Posteriormente, se seleccionó el modelo con mejor capacidad predictiva y se almacenó en un archivo .pickle para su uso en producción. Con este modelo final, se generaron predicciones sobre las asignaciones de portafolio en distintos escenarios.

4ª Etapa – 12 de abril de 2025

Se implementó un esquema de backtesting para evaluar el desempeño del modelo CPO en comparación con metodologías tradicionales: estrategia pasiva, mínima varianza, máximo de Sharpe y risk parity. Se calcularon métricas clave como el CAGR, la desviación estándar y el ratio de Sortino para cada estrategia.

5ª Etapa – 3 de mayo de 2025

Se generaron visualizaciones comparativas de los resultados por estrategia, lo que permitió evidenciar las ventajas de CPO bajo ciertos regímenes de mercado. Finalmente, se realizaron ajustes finales al código y a la documentación para preparar la presentación del proyecto y su entrega formal.

Plan de trabajo

Para lograr los objetivos del proyecto de Conditional Portfolio Optimization, se estableció una planeación organizada en cinco etapas con una duración aproximada de cuatro semanas cada una. Las actividades desarrolladas se clasificaron en profesionales, técnicas y operativas, integrando reuniones periódicas entre el equipo y asesorías con el profesor PAP.

Reuniones internas del equipo:

- Martes: Planificación de actividades semanales, definición de objetivos y asignación de tareas.

- Viernes: Revisión de avances y preparación de dudas o temas para las asesorías.

Asesorías con el profesor PAP:

- Frecuencia: Semanal, usualmente los sábados después de clase.
- Contenido: Revisión de avances, solución de dudas técnicas, retroalimentación metodológica y orientación general del proyecto.

A continuación, se presentan las etapas del proyecto, así como las actividades y el tipo de actividad correspondiente a cada etapa.

Etapas	Fecha	Actividades	Tipo de Actividad
1ª Etapa	8 feb 2025	Lectura del artículo base, glosario de términos, justificación del proyecto, propuesta de inputs para base de datos.	Profesional – Técnica
2ª Etapa	1 mar 2025	Recolección y construcción de base de datos, entrenamiento inicial de 4 modelos (Regresión Lineal,	Técnica – Operativa

		Boosting, Redes Neuronales, SVR).	
3ª Etapa	22 mar 2025	Ajuste de hiperparámetros, selección del modelo óptimo, exportación a archivo .pickle, generación de predicciones.	Técnica
4ª Etapa	12 abr 2025	Implementación de <i>backtesting</i> , comparación contra estrategias clásicas (Pasiva, Sharpe, Varianza, Risk Parity), evaluación de métricas.	Técnica – Profesional
5ª Etapa	3 may 2025	Visualización de resultados, correcciones finales, documentación formal y presentación del proyecto.	Técnica – Profesional – Operativa

Recursos necesarios

Humanos:

- Equipo multidisciplinario de estudiantes con formación en finanzas y programación.
- Asesoría y supervisión del profesor PAP.

Materiales:

- Artículos académicos, bibliografía técnica.

Económicos:

- No se incurrió en gastos monetarios directos. Todos los recursos utilizados fueron gratuitos o institucionales.

Tecnológicos:

- Software: Python, Jupyter Notebook, Scikit-learn, Keras, Matplotlib, Pickle.
- Herramientas colaborativas: Google Drive, Canva, GitHub, Microsoft Teams para reuniones.
- Hardware: Computadoras personales y conexión a internet.

Tiempo estimado por etapa:

- 4 semanas por etapa aproximadamente, con dedicación semanal dividida entre investigación, programación y reuniones.

Desarrollo de propuesta de mejora

A continuación, se describen las actividades realizadas en cada una de las etapas del proyecto *Conditional Portfolio Optimization*, en conformidad con el plan de trabajo

previamente establecido. En cada sección se deja espacio para incluir evidencias visuales que respalden lo realizado.

1ª Etapa – Fundamentos teóricos y preparación inicial

Fecha: 8 de febrero de 2025

Actividades realizadas:

- Lectura y análisis del paper “Conditional Portfolio Optimization: Using Machine Learning to Adapt Capital Allocations to Market Regimes” de Ernest Chan.
- Elaboración de un glosario con términos clave (por ejemplo: Sharpe Ratio, Regímenes de mercado, Backtesting, SVR, etc.).
- Justificación del proyecto con base en las limitaciones de los métodos tradicionales de optimización.
- Propuesta de variables de entrada (market features) para el modelo, considerando tanto factores de mercado como variables de control (asignaciones de capital).

2ª Etapa – Construcción de base de datos y entrenamiento inicial de modelos

Fecha: 1 de marzo de 2025

Actividades realizadas:

- Recolección de datos históricos de activos financieros y variables de mercado.
- Limpieza, normalización y estructuración de la base de datos.
- Entrenamiento de los siguientes modelos:
 - Regresión lineal.
 - Árboles de decisión con boosting.
 - Redes neuronales artificiales.
 - Support Vector Regression (SVR).

3ª Etapa – Optimización del modelo y generación de predicciones

Fecha: 22 de marzo de 2025

Actividades realizadas:

- Ajuste de hiperparámetros de cada modelo mediante técnicas como *GridSearchCV*, *Random Search* u *Optuna*.
- Selección del modelo óptimo con base en métricas de rendimiento (por ejemplo, MAE, MSE o R^2).
- Serialización y guardado del modelo final mediante Pickle para su uso en predicciones.

4ª Etapa – Backtesting y comparación con estrategias tradicionales

Fecha: 12 de abril de 2025

Actividades realizadas:

- Desarrollo de un esquema de *backtesting* para simular el desempeño del modelo en datos fuera de muestra.
- Comparación de la estrategia de SVR-CPO con las siguientes estrategias tradicionales:
 - Estrategia Pasiva (Equal Weight).
 - Mínima Varianza.
 - Máximo Sharpe.
 - Risk Parity.
 - CPO original.
- Evaluación de métricas de desempeño: CAGR, Desviación estándar, Ratio de Sortino, Drawdown máximo y Rendimiento anual promedio.

5ª Etapa – Visualización de resultados, correcciones y presentación final

Fecha: 3 de mayo de 2025

Actividades realizadas:

- Generación de gráficas comparativas entre las estrategias.
- Redacción de conclusiones y observaciones sobre el comportamiento del modelo SVR-CPO bajo distintos regímenes de mercado.
- Correcciones a código y estructura de presentación.
- Documentación final del proyecto (reporte, presentación, cuaderno de trabajo).

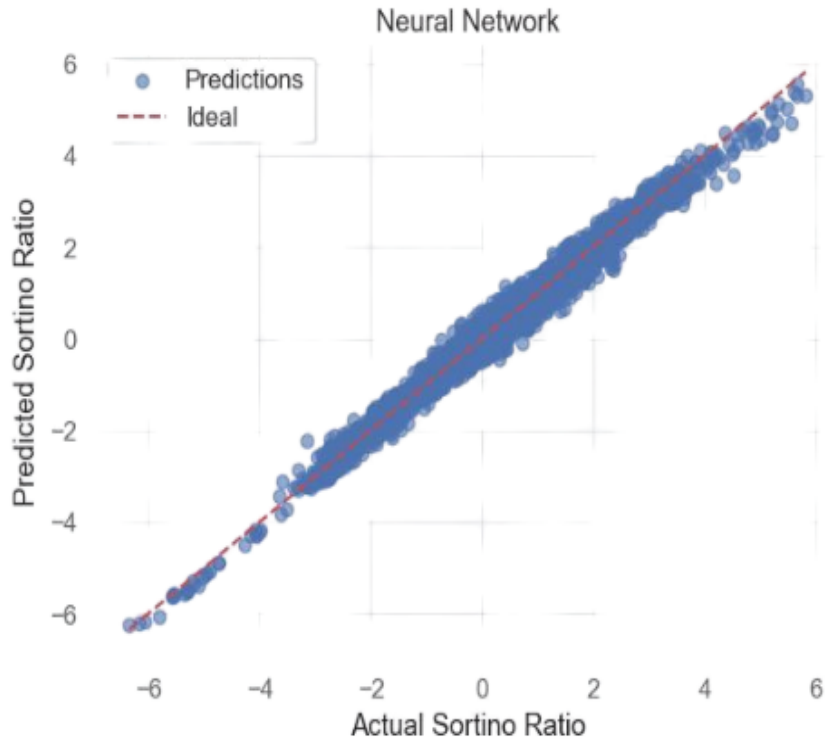
3. Resultados del trabajo profesional

Resultados de entrenamiento y validación

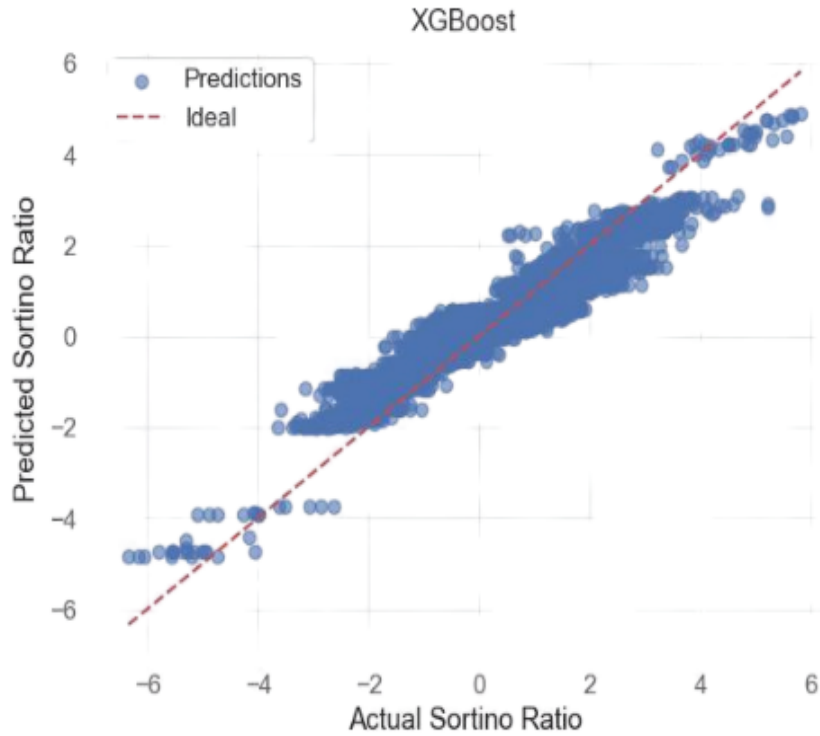
Durante la fase inicial del proyecto, se evaluó el desempeño de cuatro modelos de aprendizaje automático: **Regresión Lineal**, **Redes Neuronales**, **Support Vector Regression (SVR)** y **XGBoost**, utilizando sus configuraciones por defecto, es decir, sin ajuste de hiperparámetros. Para esta etapa, los modelos fueron entrenados y evaluados sobre un conjunto de datos común, y las métricas utilizadas para medir su rendimiento fueron el **Error Cuadrático Medio (RMSE)** y el **Coefficiente de Determinación (R²)**.

Modelo de ML	RMSE	R ²
Regresión Lineal	1.6632	0.2599
Redes Neuronales	0.0348	0.9845
SVR	1.8244	0.1882
XGBoost	0.3220	0.8567

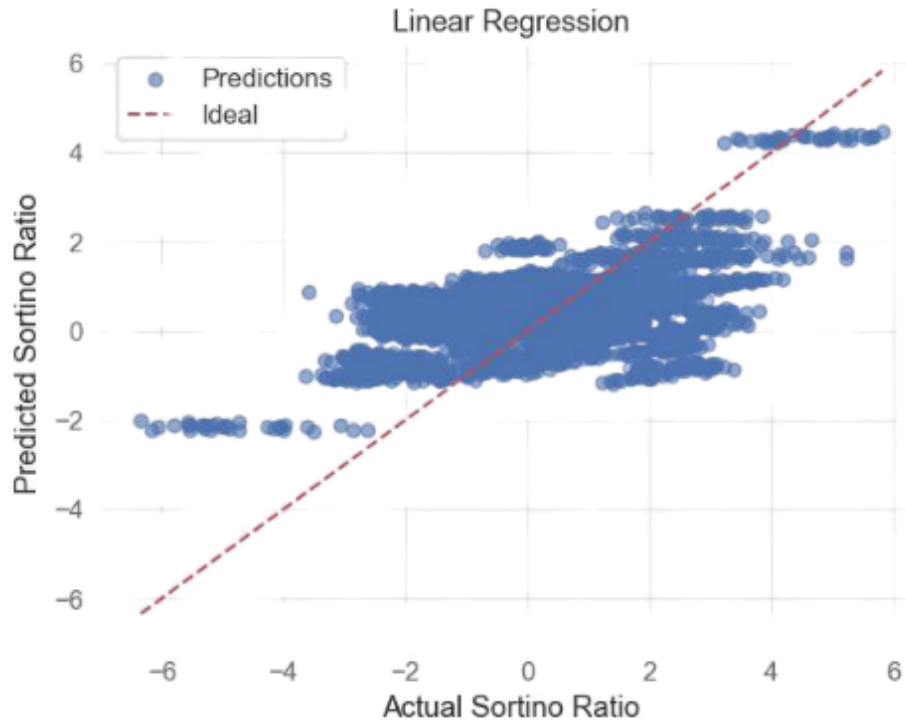
Los resultados obtenidos muestran un amplio contraste entre los modelos. El modelo de redes neuronales se posicionó como el más preciso, alcanzando el menor RMSE (0.0348) y el mayor R² (0.9845). Estas métricas reflejan una excelente capacidad de ajuste al conjunto de entrenamiento, lo cual se corrobora visualmente en el gráfico de dispersión entre valores reales y predichos, donde se observa una alineación casi perfecta con la línea ideal.



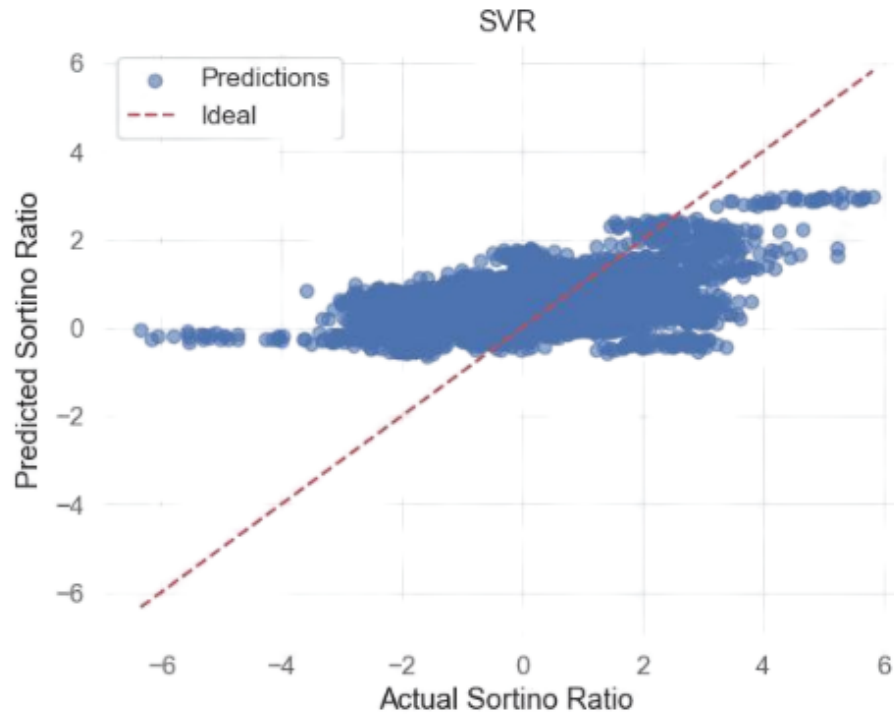
XGBoost, por su parte, mostró un desempeño consistente, con un RMSE de 0.3220 y un R^2 de 0.8567. Aunque menos ajustado que la red neuronal, el modelo evidenció una capacidad estable de predicción sin indicios evidentes de sobreajuste. Resulta destacable que esta evaluación se realizó sin reducción de dimensionalidad, técnica que posteriormente sería aplicada para fortalecer su generalización. El patrón de dispersión en sus predicciones presenta una alineación razonable con los valores reales, con ligeras desviaciones atribuibles a la falta de optimización.



La Regresión Lineal, en cambio, mostró dificultades para capturar adecuadamente las relaciones subyacentes. Su RMSE fue de 1.6632 y el R^2 apenas alcanzó 0.2599, reflejando una capacidad predictiva limitada. Visualmente, la dispersión de los puntos respecto a la diagonal deja en evidencia la incapacidad del modelo para adaptarse a la naturaleza no lineal de los datos, lo que refuerza su papel como punto de comparación más que como alternativa viable.



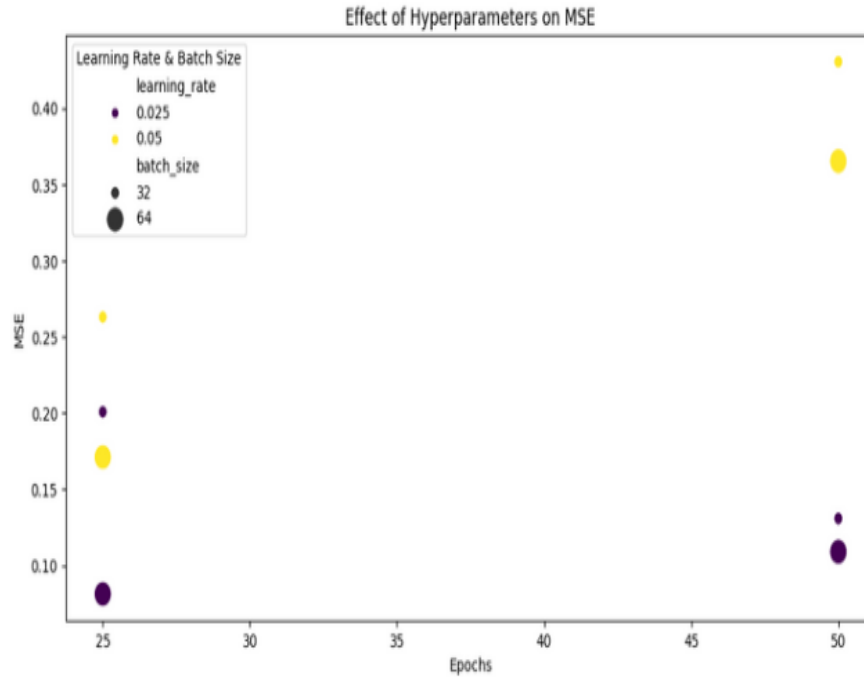
Finalmente, el modelo SVR, en su configuración inicial, mostró un rendimiento aún más discreto, con un RMSE de 1.8244 y un R^2 de 0.1882. A pesar de su potencial teórico, el comportamiento observado sugiere una sensibilidad considerable a su configuración de parámetros y a la escala de los datos. La distribución de errores fue amplia, con predicciones visiblemente alejadas de los valores reales.



En conjunto, estos resultados permitieron establecer un punto de partida crítico para el trabajo posterior de ajuste y mejora. Mientras que las Redes Neuronales y XGBoost emergieron como candidatos viables, SVR y Regresión Lineal evidenciaron limitaciones estructurales que requerían ajustes sustanciales o reconsideración metodológica.

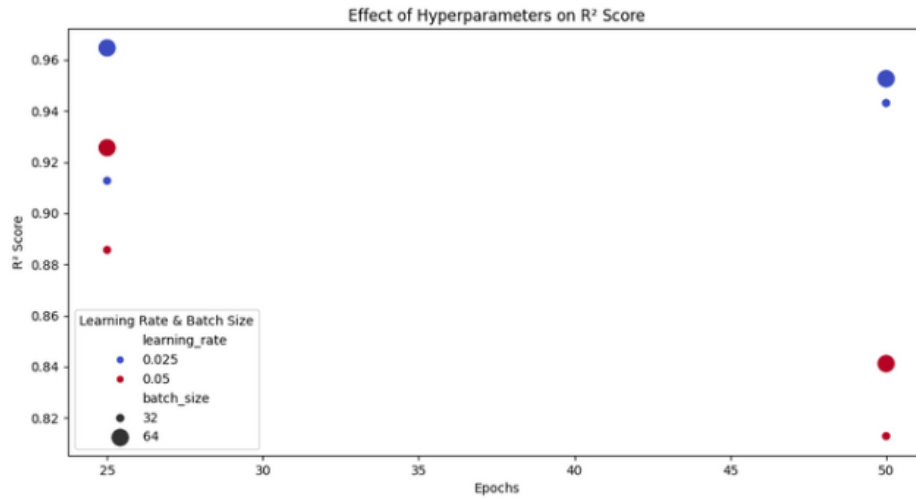
Optimización de Hiperparámetros

A partir de las observaciones previas, se procedió a optimizar los modelos con mayor potencial: Redes Neuronales, XGBoost y SVR. El objetivo fue mejorar su desempeño sin comprometer su capacidad de generalización. Para ello, se aplicaron técnicas de grid search y, en el caso de XGBoost, reducción de dimensionalidad mediante Análisis de Componentes Principales (PCA). La Regresión Lineal se mantuvo como referencia, dado que carece de parámetros significativos ajustables.



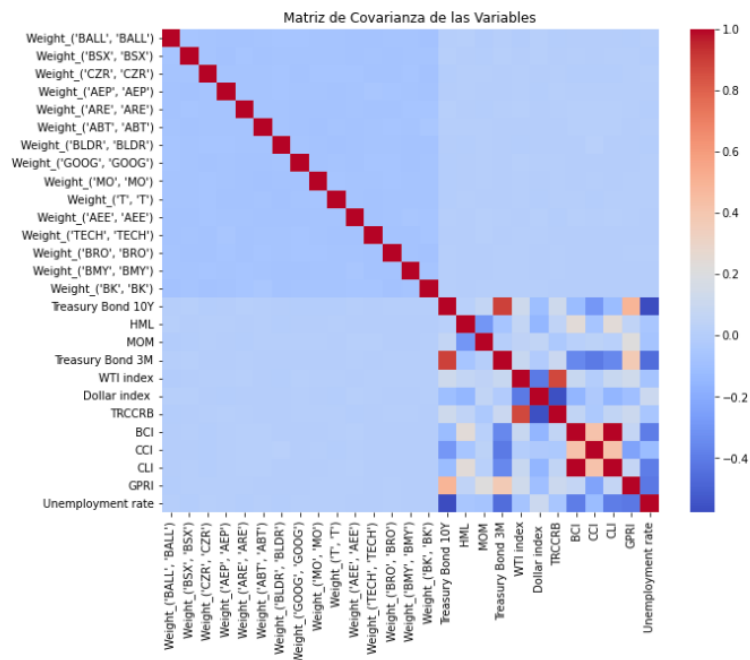
Redes Neuronales

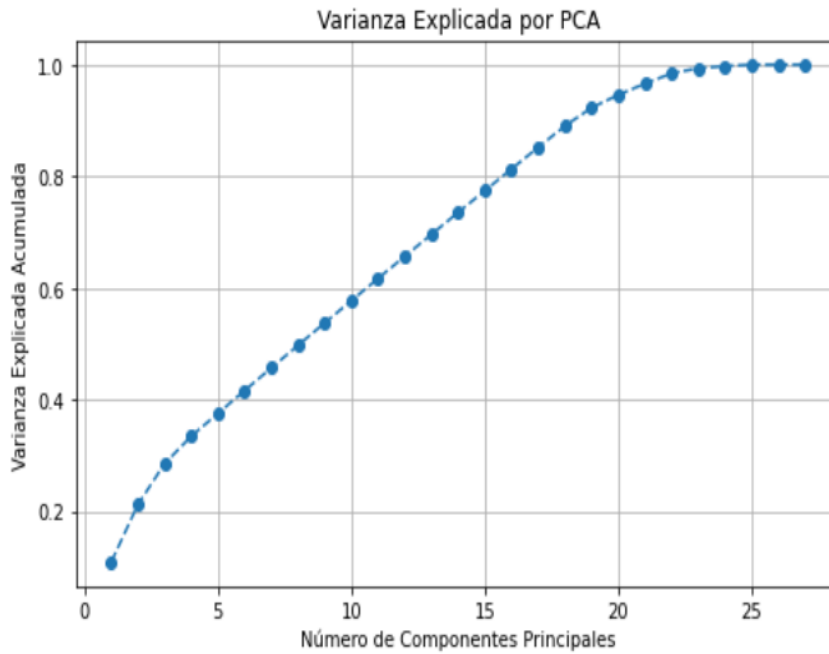
A lo largo del proceso de tuning, se evaluó el efecto combinado del número de epochs, el tamaño del batch y la tasa de aprendizaje sobre el rendimiento del modelo. Los resultados se muestran en las siguientes gráficas, donde se aprecia cómo ciertas combinaciones (particularmente aquellas con menor número de epochs y tasa de aprendizaje moderada) favorecieron un MSE más bajo y un R^2 más estable, evitando caídas abruptas que suelen asociarse con sobreajuste o mala adaptación.



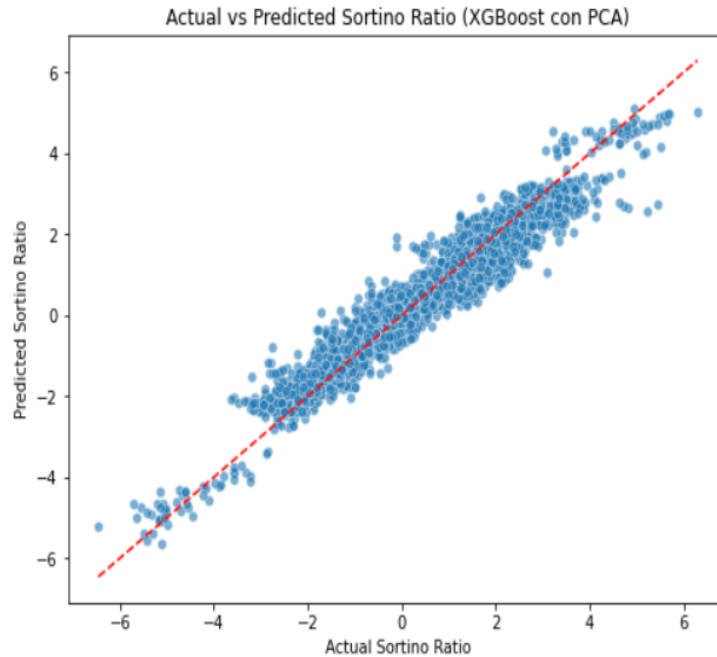
XGBoost

Para XGBoost, se identificó redundancia significativa entre variables mediante un análisis de covarianza, lo que motivó la aplicación de PCA. La retención de 21 componentes principales permitió preservar el 95% de la varianza total, reduciendo la complejidad del modelo y mejorando su eficiencia.





Posteriormente, el modelo fue sometido a un ajuste fino de parámetros, incluyendo profundidad de árboles, número de estimadores, tasa de aprendizaje y regularización. La configuración óptima encontrada mejoró el equilibrio entre sesgo y varianza, elevando el R^2 a 0.9221 y reduciendo el MSE a 0.1793.



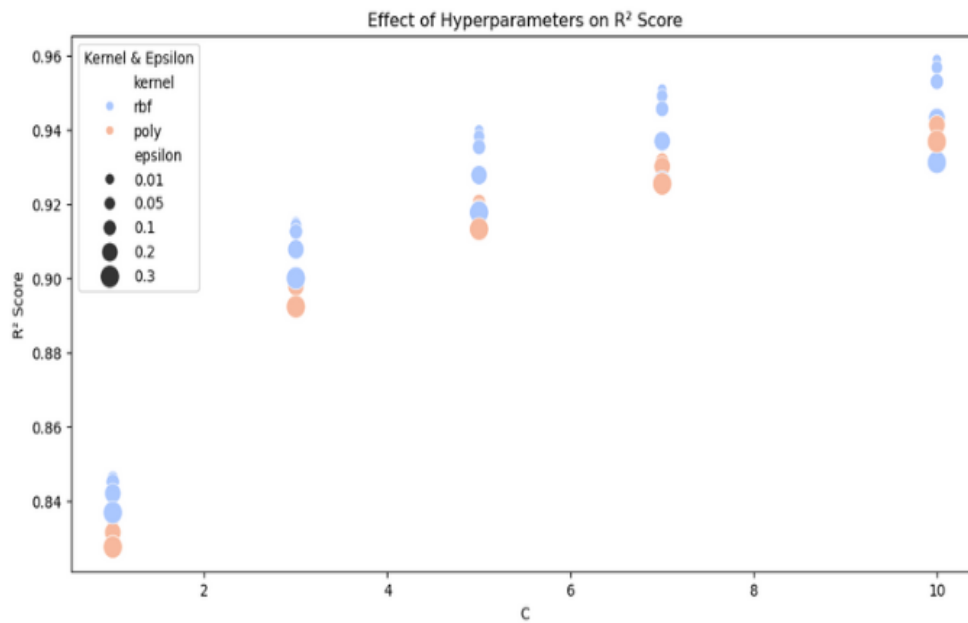
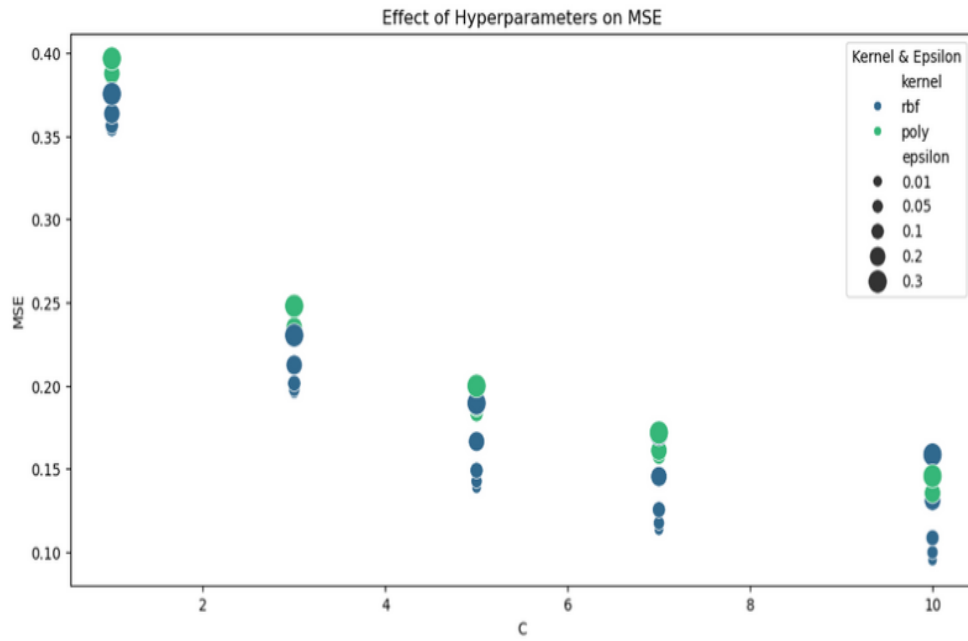
Support Vector Regression (SVR)

El ajuste del modelo SVR se centró en tres elementos clave: el tipo de kernel, el parámetro de penalización C y el margen de tolerancia definido por ϵ (epsilon). Tras múltiples iteraciones, la configuración que mejor desempeño ofreció fue el uso del kernel RBF, con $C = 10$ y $\epsilon = 0.01$.

El kernel RBF resultó ser el más adecuado para capturar relaciones no lineales entre las variables predictoras y el ratio de Sortino, permitiendo una representación más flexible de los datos sin requerir transformaciones explícitas. Por su parte, un valor alto de C favoreció un ajuste más estricto del modelo, penalizando errores con mayor severidad y reduciendo la tolerancia a desviaciones significativas. Esto fue particularmente útil para mejorar la precisión sin comprometer la estabilidad.

Finalmente, el valor reducido de ϵ implicó un margen más estrecho de tolerancia a errores sin penalización, haciendo que el modelo fuera más sensible a pequeñas desviaciones entre las predicciones y los valores reales. Esta combinación de parámetros permitió una mejora sustancial en el rendimiento del modelo, especialmente en el tercer conjunto de datos,

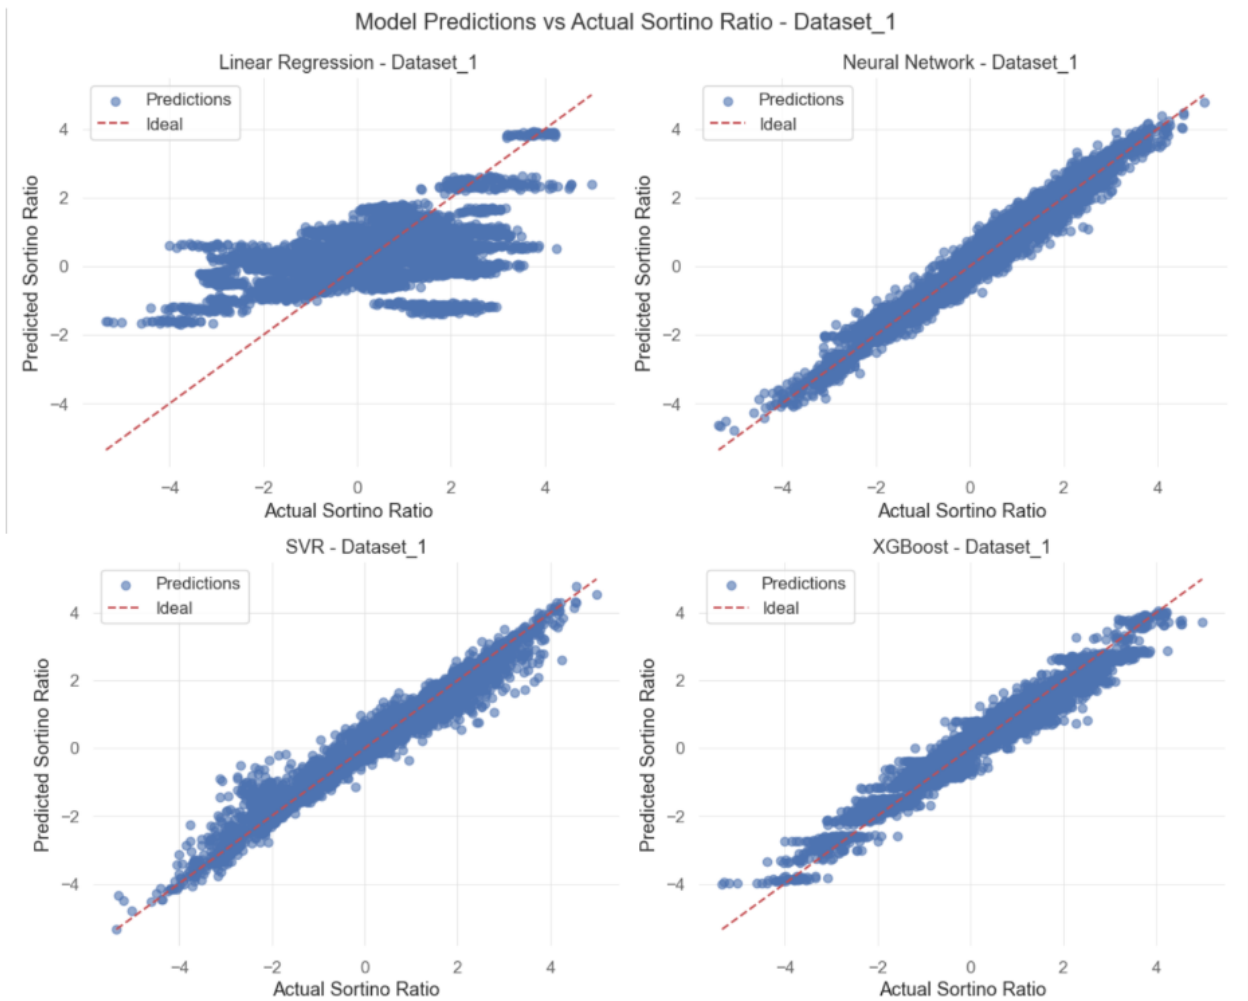
donde SVR alcanzó un R^2 de 0.9704 y un MSE de 0.0534, posicionándose como la mejor opción en términos de precisión tras el tuning.



Evaluación por Dataset

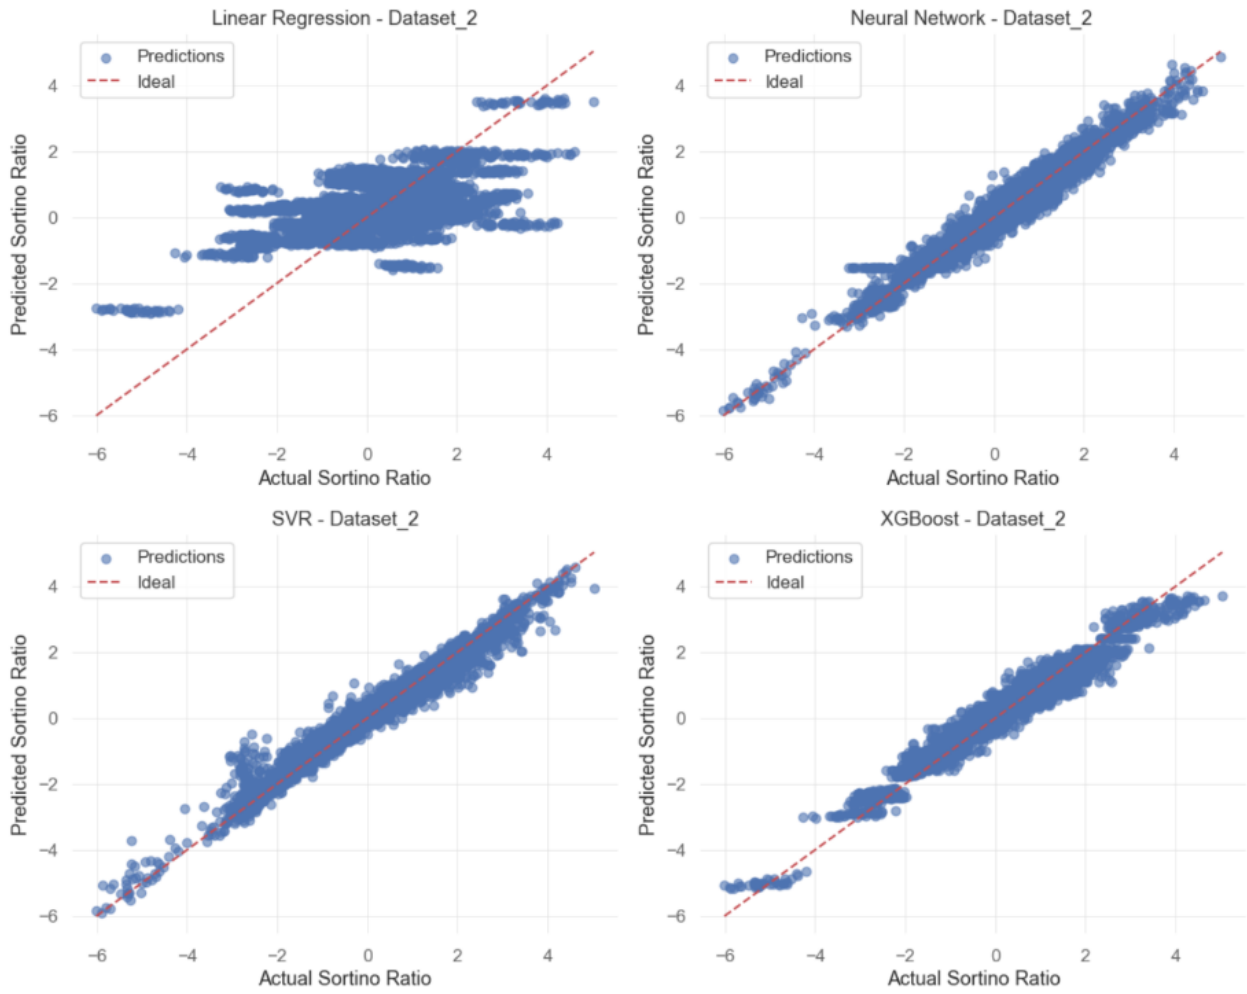
Tras la optimización, se reevaluó el desempeño de todos los modelos en tres conjuntos de datos distintos. En el primero, Redes Neuronales se mantuvo a la cabeza; en el segundo, SVR alcanzó el mejor MSE; y en el tercero, SVR superó a todos con el mayor R^2 y la menor dispersión de errores.

Primer Dataset

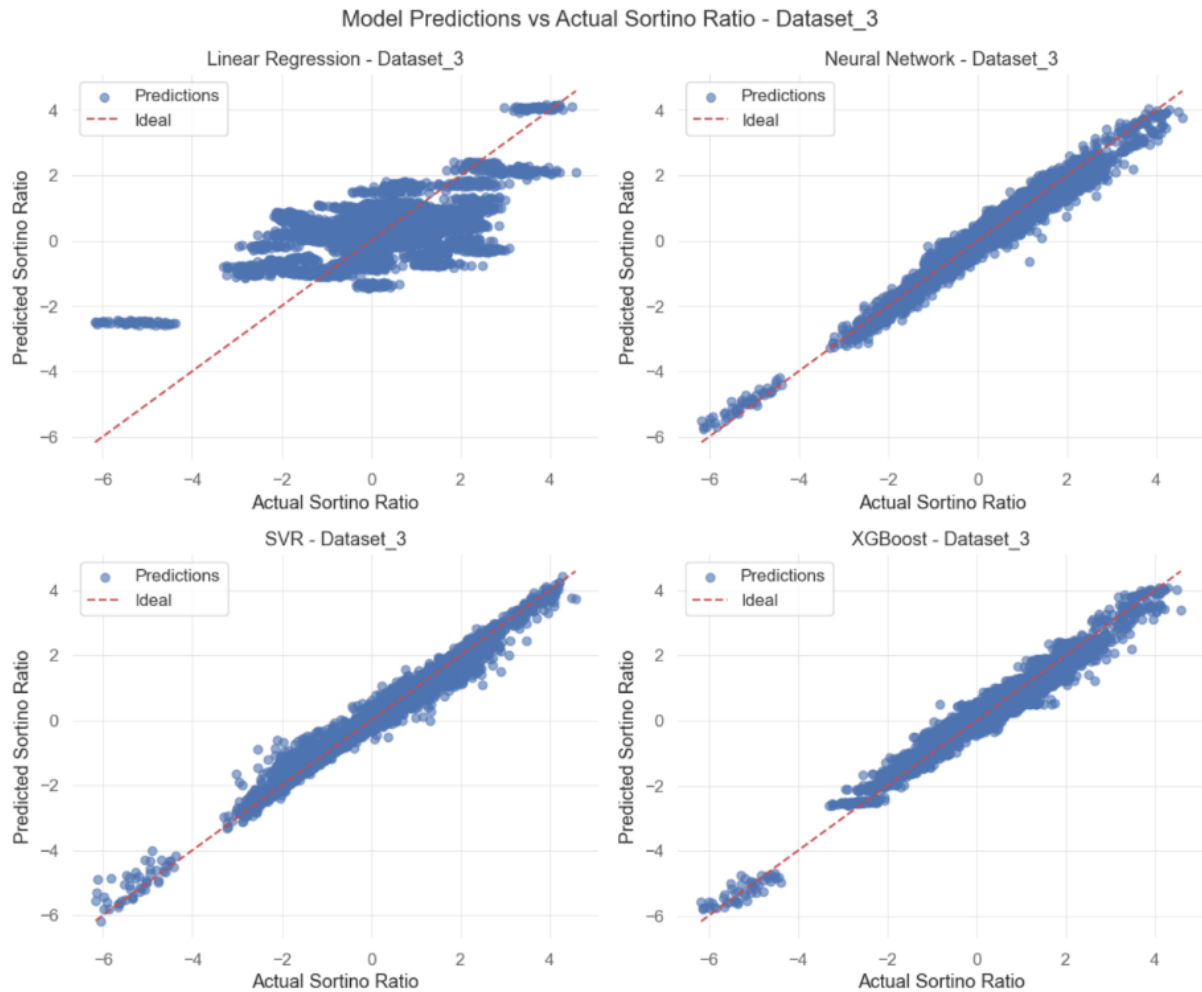


Segundo Dataset

Model Predictions vs Actual Sortino Ratio - Dataset_2



Tercer Dataset

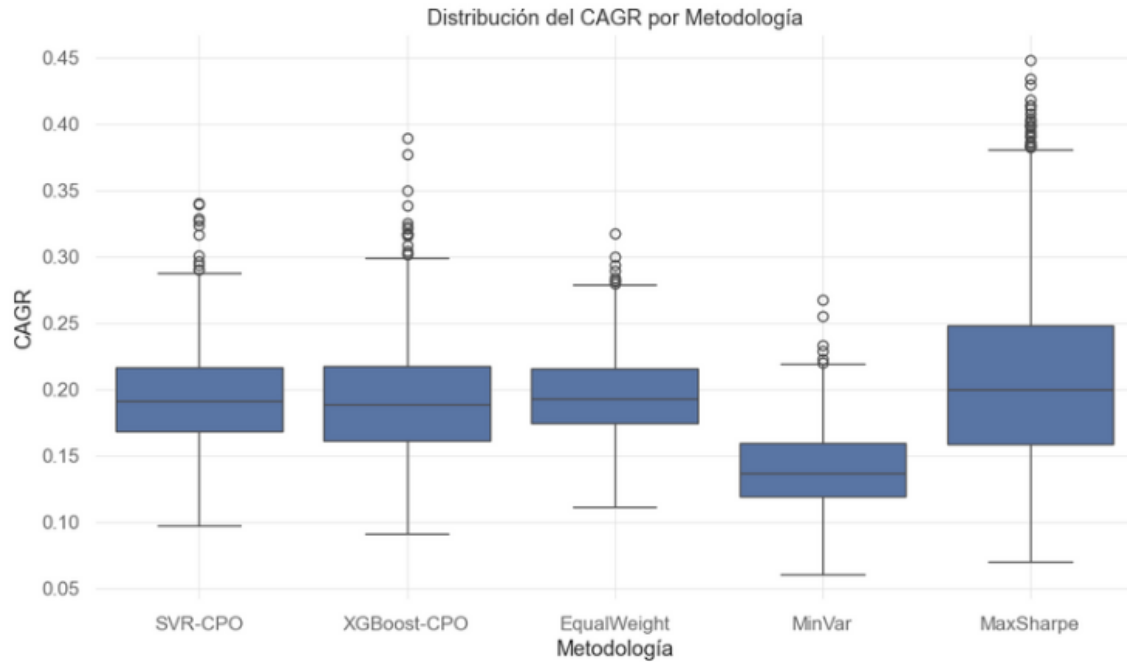


Resultados de backtesting






Los resultados del proceso de backtesting revelan que el modelo **SVR-CPO** ofrece un desempeño competitivo y balanceado frente a metodologías tradicionales y otros enfoques de machine learning. Con un **rendimiento anual promedio de 17.84%**, una **desviación estándar de 16.95%**, y una **tasa de crecimiento anual compuesta (CAGR) de 19.37%**, esta estrategia se posiciona entre las más sólidas del análisis. Solo fue superada por la estrategia de **Máximo Sharpe**, que alcanzó un rendimiento anual de 19.36% y un CAGR de 21.29%, aunque con mayor riesgo.

Metodología	Rendimiento Anual Promedio	Desviación Estándar	Rendimiento Efectivo	Downside Risk	CAGR	Sortino Ratio
Equal Weighting	17.87%	16.02%	516.14%	10.60%	19.58%	1.2939
S&P 500	13.65%	16.43%	187.76%	9.34%	12.46%	1.0120
Mínima Varianza	13.23%	14.20%	286.73%	9.33%	14.11%	0.9843
Máximo Sharpe	19.36%	17.56%	714.85%	10.82%	21.29%	1.4017
CPO original	17.82%	17.49%	518.78%	11.22%	19.24%	1.2255
<u>SVR-CPO</u>	<u>17.84%</u>	<u>16.95%</u>	<u>515.45%</u>	<u>11.06%</u>	<u>19.37%</u>	<u>1.2442</u>

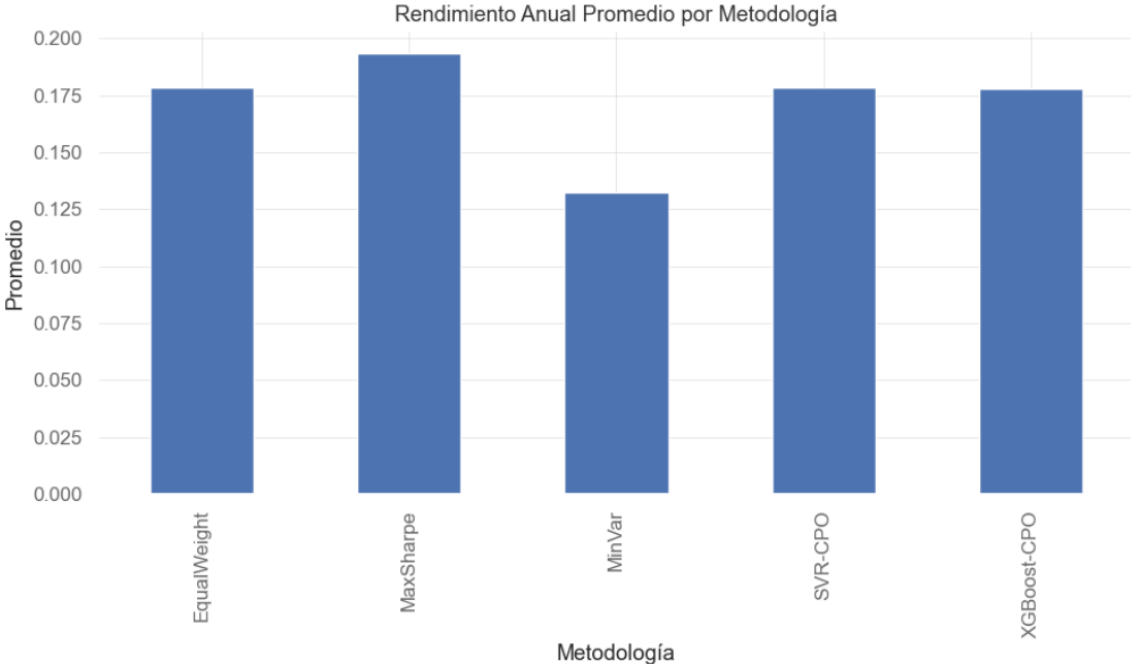
Uno de los indicadores más relevantes para evaluar eficiencia ajustada por riesgo fue el **Sortino Ratio**, en el cual el SVR-CPO alcanzó un valor de **1.2442**. Aunque dicho valor fue ligeramente inferior al de la estrategia Equal Weighting (**1.2939**), el modelo SVR-CPO operó con un **Downside Risk** más elevado (**11.06%** frente a **10.60%**), lo que sugiere que el ratio obtenido refleja una relación riesgo-retorno más realista y menos influida por distorsiones provocadas por riesgos cercanos a cero.








Al comparar el SVR-CPO con el **modelo CPO original** basado en XGBoost, se evidencian resultados similares en rentabilidad (**17.84% vs. 17.82%**) y en rendimiento efectivo (**515.45% vs. 518.78%**). No obstante, la versión con SVR mostró una **desviación estándar inferior** y un **Sortino Ratio más alto**, lo cual sugiere una mayor estabilidad y una menor dispersión en las simulaciones.



En contraste, la estrategia de **Máximo Sharpe**, si bien encabezó el ranking en cuanto a retorno (**19.36%** anual y **714.85%** efectivo), fue también la que presentó la **mayor volatilidad (17.56%)** y un **downside risk considerable (10.82%)**. Esto implica que su ratio de Sortino más alto (**1.4017**) no necesariamente traduce una ventaja absoluta, ya que el comportamiento de su distribución fue marcadamente más disperso e inestable a lo largo del tiempo.



En el otro extremo, el **benchmark del S&P 500** mostró el desempeño más limitado entre todas las metodologías evaluadas. Con un rendimiento anual promedio de **13.65%**, un CAGR de **12.46%**, y un Sortino Ratio de apenas **1.0120**, quedó claro que las estrategias pasivas y no optimizadas continúan ofreciendo una relación riesgo-retorno menos eficiente frente a enfoques sistemáticos y adaptativos.



Entonces, podemos decir que los resultados obtenidos en el proceso de backtesting validan que el modelo SVR-CPO, es capaz de capturar relaciones no lineales en los datos financieros y adaptarse eficazmente a distintos contextos de mercado. Su diseño permite una asignación de activos más estable, con menor dispersión en sus resultados y un control del riesgo más consistente frente a estrategias tradicionales.

4. Reflexiones del alumno o alumnos sobre sus aprendizajes, las implicaciones éticas y los aportes sociales del proyecto

Aprendizajes profesionales

Durante la vida de este proyecto se desarrollaron muchas habilidades y se reforzaron las ya adquiridas a lo largo de la carrera universitaria. Es bastante valioso todo lo que obtuvimos en la ejecución del proyecto, ya que abordó un problema real.

Este proyecto ha ayudado a reforzar los conocimientos que se adquirieron en el campo de estudio de la ingeniería financiera, lo cual ha contribuido a desarrollar competencias profesionales, como el diseño, creación y ejecución de una nueva estrategia de inversión. Esto representa un gran desarrollo profesional, considerando todo lo que involucra este proyecto. Desde la comprensión del artículo en el que nos basamos para crear nuestra estrategia, que ha ayudado a establecer la base de la estrategia, continuamos con la creación de una nueva estrategia.

Esto implicó desarrollar y utilizar los conocimientos adquiridos a lo largo de la carrera en colaboración con un equipo de trabajo, donde cada uno desempeñó diferentes actividades, tales como: comprensión y creación del diagrama de flujo del proyecto, búsqueda y descarga de los datos para la estrategia, creación de las bases de datos, ejecución con modelos de machine learning y redes neuronales, y la implementación de backtesting y comparación con diferentes estrategias. Además, se han desarrollado competencias que no necesariamente están directamente relacionadas con el campo de estudio en cuestión, como la redacción del informe y el trabajo colaborativo, entre otros.

Aprendizajes sociales

La creación de este proyecto tiene el potencial de generar un impacto social muy positivo, ya que propone una estrategia innovadora de inversión que puede contribuir a mejorar la cultura financiera en México, un país donde este tema aún está poco desarrollado. Este enfoque puede ser especialmente útil para nuevos inversores, al brindarles herramientas modernas y efectivas para gestionar su capital. De esta manera, el proyecto se alinea con la importancia de la educación financiera y su capacidad para transformar positivamente la vida de las personas.

A través del desarrollo de esta iniciativa, se comprendió el profundo impacto social que puede tener el diseño de herramientas tecnológicas bien estructuradas en el ámbito financiero. No solo facilitan el acceso a información compleja para individuos y pequeños inversores, sino que también les otorgan el poder de tomar decisiones financieras más estructuradas. La posibilidad de tener estrategias de vanguardia y gestionar sus inversiones de forma accesible tiene un efecto significativo en la calidad de vida de las personas.

Esta experiencia permitió reconocer la importancia de mantener el proyecto en constante actualización.

Asimismo, amplió la visión sobre el papel fundamental de la educación financiera y la necesidad de difundirla de forma clara y accesible, de modo que más personas puedan beneficiarse. Todo ello refuerza la convicción de que la tecnología puede ser una herramienta poderosa para la inclusión financiera, permitiendo a más individuos tomar el control de sus finanzas como nunca.

Aprendizajes éticos

Durante el desarrollo del proyecto se consideró seriamente la importancia de la ética en el ámbito de las inversiones. Desde el inicio se optó por un enfoque responsable y transparente. Estas decisiones estuvieron influenciadas por un compromiso firme hacia la

integridad profesional y por entender el impacto que una herramienta técnica pueda hacer sobre las decisiones de inversión de los demás.

La ética se mantuvo como un principio fundamental durante todo el proceso en cuestión. La selección meticulosa de estrategias transparentes y responsables no solo tuvo como objetivo principal mejorar los resultados financieros, sino también asegurar la equidad y la accesibilidad en las soluciones financieras, con una atención especial en los segmentos históricamente marginados del sistema financiero. Este enfoque fortaleció la convicción de practicar la Ingeniería Financiera desde una profunda responsabilidad social, fomentando prácticas equitativas, sostenibles y centradas en el beneficio colectivo.

El proyecto enseñó que el desarrollo de herramientas tecnológicas en el ámbito financiero implica una gran responsabilidad ética y moral. Durante la creación y validación del sistema se tomaron decisiones guiadas por valores éticos conscientes de que incluso las pequeñas elecciones de diseño pueden tener un impacto considerable en la vida de las personas. Se comprendió que el código no es solo una entidad técnica, sino también un reflejo de valores que debe priorizar el bienestar y la inclusión financiera.

Al fin y al cabo, esta experiencia fortaleció el enfoque profesional no solo hacia el crecimiento personal sino también hacia la responsabilidad social. A partir de ahora, podemos concebir este tipo de trabajos como una oportunidad para desarrollar soluciones financieras que no solo sean eficientes, sino que también promuevan un enfoque socialmente responsable.

Aprendizajes en lo personal

Francisco Alexander Sotomayor Pineda

¿El PAP qué me dio para conocerme a mí?

Me hizo darme cuenta de habilidades organizativas y de liderazgo que no sabía que tenía, así como habilidades duras en áreas como programación y finanzas que no había aplicado plenamente durante mi tiempo estudiando en la institución y que pensaba que sería difícil aplicarlas todas en un solo proyecto.

¿El PAP qué me dio para conocer y reconocer a la sociedad y a los otros?

Me ayudó a reconocer una falta de educación y de cultura financiera en la sociedad mexicana. Uno de los objetivos de este PAP justamente trata de eliminar y/o reducir estas carencias. Considero que esta falta de educación y cultura se debe en gran medida a la falta de recursos y materiales de investigación en habla hispana, ya que la mayoría de estos se encuentran en inglés y muy pocas veces se encuentra una traducción fiel en español, lo que limita el acceso a muchos mexicanos que pueden hacer buen uso de este tipo de materiales.

¿Cómo me ayudó el PAP para aprender a convivir en la pluralidad y para la diversidad?

Al trabajar con compañeros con diferentes metodologías de trabajo, diferentes conocimientos y habilidades, distintos trabajos y diferentes trasfondos, todo esto me permitió adaptarme y aprender de los demás con el fin de cumplir los objetivos de este proyecto y realizar el mejor trabajo posible.

¿Qué aprendí para mi proyecto de vida?

A trabajar con personas que, aunque tienen la misma educación en el ámbito financiero que yo, trabajan de manera distinta, tienen conocimientos distintos que tal vez yo no tengo tan desarrollados pero que al fin todos aportan para la realización de un proyecto con objetivos en común.

También aprendí a realizar investigación por mi cuenta y encontrar las respuestas a mis propias preguntas con el fin de cumplir los objetivos y las expectativas del proyecto sin la ayuda de un profesor que me diga la respuesta o que me diga donde encontrar la respuesta, ya que así es como usualmente funciona el mercado laboral.

Luis Adrián López Enríquez

¿El PAP qué me dio para conocerme a mí?

Me permitió identificar la forma en la que estructuro mis responsabilidades dentro de un equipo, así como entender mejor cómo gestiono mi tiempo frente a múltiples entregas. A

lo largo del proyecto, descubrí que tengo una capacidad natural para organizar tareas colectivas, distribuir cargas de trabajo y mantener el ritmo del equipo sin perder de vista mis propios avances. Esto no solo reforzó mi criterio organizativo, sino que también me ayudó a desarrollar una mayor conciencia sobre mis procesos personales de planeación y ejecución.

¿El PAP qué me dio para conocer y reconocer a la sociedad y a los otros?

Me permitió entender que muchas veces el problema no es la falta de herramientas financieras, sino la dificultad para hacerlas accesibles. Reconocí la importancia de traducir soluciones técnicas en recursos comprensibles y útiles para quienes no tienen formación especializada, y el valor de trabajar en equipo para lograrlo.

¿Cómo me ayudó el PAP para aprender a convivir en la pluralidad y para la diversidad?

Me ayudó a valorar todas las ideas que surgen cuando se trabaja con personas con distintos enfoques y formas de pensar. Fue interesante ver cómo cada integrante del equipo proponía soluciones diferentes, y cómo, a través del diálogo, logramos tomar decisiones y avanzar en conjunto. También aprendí mucho observando las fortalezas de mis compañeros y cómo cada uno aportó algo único al desarrollo del proyecto.

¿Qué aprendí para mi proyecto de vida?

Aprendí que el trabajo en equipo, como ya antes mencionado, funciona cuando existe una comunicación constante, clara y honesta. A lo largo del proyecto pude captar que no se trata solo de repartir tareas, sino de mantenerse alineado con los demás y adaptarse al ritmo del grupo.

Sergio Renato González Mendoza

¿El PAP qué me dio para conocerme a mí?

Me impulsó a ser una persona más organizada y responsable en cuanto a un trabajo en equipo, la manera en que administro y dirijo mis tiempos para poder cumplir con mis

responsabilidades y actividades diarias llevado a la par de un trabajo complejo que requiere de no solo mi participación sino también de la de otros, además me ayudó a identificar las falencias que tengo en cuanto a otros aspectos personales que requieren que trabaje en ello pero definitivamente me ha impulsado a ser un mejor profesionalista.

¿El PAP qué me dio para conocer y reconocer a la sociedad y a los otros?

Me dio a conocer a personas con las que no tenía mucha relación en la carrera y a poder entender la forma en que trabajan ellos y en el cómo me impulsaron a trabajar a un ritmo distinto, además de poder aprender distintas cosas de cada uno, de su forma de pensar y de lo que ellos aportan para mejorar como persona y como compañero de trabajo.

¿Cómo me ayudó el PAP para aprender a convivir en la pluralidad y para la diversidad?

Me ayudó a entender las diferencias y similitudes que tenemos como compañeros de trabajo y como personas, las formas de pensar y de trabajar de mis compañeros que tienen una vida diferente o parecida en ciertos aspectos a la mía. También, aprendí que la comunicación y el entendimiento mutuo es el factor más importante para que un equipo de trabajo llegue a un fin esperado y que la colaboración de todos impulse a nuestro equipo a el desarrollo individual.

¿Qué aprendí para mi proyecto de vida?

Aprendí la manera en que un equipo de trabajo te impulsa a mejorar en habilidades y conocimientos que a lo mejor no sabía que tenía o que podían aportar a un equipo de trabajo efectivo en el cual los aportes de cada persona fuera de que podrían ser buenos o malos, siempre hay que tenerlos en cuenta y en base a esto tomarlo como oportunidades de mejora.

Samuel Alejandro Pérez Avalos

¿El PAP qué me dio para conocerme a mí?

Trabajando en este PAP me he dado cuenta lo importante que es la colaboración en equipos para mantener a flote este tipo de proyectos en donde se combinan las habilidades de todos los desarrolladores para poder llegar al objetivo y, precisamente el que cada uno haya tenido que encargarse de algún rubro en específico me voy satisfecho con lo que he aportado en este trabajo porque he aportado una parte importante para el objetivo del proyecto, así como todos mis compañeros.

¿El PAP qué me dio para conocer y reconocer a la sociedad y a los otros?

El PAP nos ha abierto la puerta a un nuevo modelo financiero de vanguardia, lo cual me hace pensar en que existen muchísimas posibilidades e innovaciones en este campo y podemos crear estrategias de inversión con distintos paradigmas permitiéndonos de esta manera crear nuevas soluciones en este campo.

¿Cómo me ayudó el PAP para aprender a convivir en la pluralidad y para la diversidad?

Al colaborar con mis compañeros del proyecto en donde si bien, todos tenemos el mismo perfil en cuanto a carrera, cada uno tiene su manera de trabajar y pensar, lo cual es de suma importancia en un proyecto como este porque todos hemos podido proponer ideas y posibles soluciones a los problemas que hemos tenido durante la vida de este proyecto.

¿Qué aprendí para mi proyecto de vida?

El proyecto me ha dejado en claro la importancia de trabajo en equipo y el apoyo que este nos brinda para la solución de problemas como en este el Proyecto de Aplicación Profesional, asimismo, me queda claro que no es de gran importancia ser el mejor en todo ya que, en un trabajo cada colaborador se dedica en una parte en específico para el desarrollo de este.

Rania Paola Aguirre Rodríguez

¿El PAP qué me dio para conocerme a mí?

El Proyecto de Aplicación Profesional (PAP) me permitió identificar y fortalecer mis competencias tanto generales como específicas en Ingeniería Financiera. A través del diseño, implementación, reformulación de estrategias cuantitativas avanzadas y el uso de herramientas de programación como Python para el análisis de simulaciones, descubrí mi capacidad para abordar problemas complejos de Asset Allocation. Además, el reto de integrar conocimientos de finanzas, economía, estadística y tecnología me hizo reconocer mis habilidades para trabajar en contextos multidisciplinarios.

¿El PAP qué me dio para conocer y reconocer a la sociedad y a los otros?

Este proyecto me permitió comprender mejor la realidad financiera global y el impacto de factores económicos en la gestión de inversiones sostenibles. Reconocí la importancia de diseñar soluciones prácticas y responsables que consideren el contexto social y económico, lo cual me ayudó a ver mi profesión no solo como una actividad técnica, sino también como una herramienta para contribuir al bienestar colectivo.

¿Cómo me ayudó el PAP para aprender a convivir en la pluralidad y para la diversidad?

El PAP me enseñó a integrar perspectivas diversas provenientes de diferentes disciplinas y a valorar el enfoque colaborativo en la resolución de problemas financieros. Al trabajar en equipo y combinar conocimientos de finanzas, tecnología, estadística y economía, aprendí a respetar y valorar aportaciones de distintas áreas, fortaleciendo mi capacidad para convivir en la pluralidad.

¿Qué aprendí para mi proyecto de vida?

El proyecto me mostró que, con una perspectiva interdisciplinaria y el uso adecuado de herramientas tecnológicas, es posible abordar desafíos financieros de manera ética y sostenible. Esta experiencia reforzó mi compromiso de seguir aprendiendo y aportando soluciones innovadoras en el ámbito financiero, convencido de que puedo contribuir a transformar la realidad financiera hacia prácticas más responsables y conscientes.

5. Conclusiones

El modelo SVR-CPO demuestra un desempeño sólido y equilibrado, combinando alta rentabilidad con un riesgo moderado. Con un rendimiento anual promedio de 17.85%, un CAGR de 19.38% y un rendimiento efectivo de 5.15, se posiciona como una alternativa competitiva frente a estrategias tradicionales como EqualWeight y técnicas optimizadas como MaxSharpe. Aunque no alcanza el rendimiento máximo de este último, sí logra una menor desviación estándar (16.95%) y mantiene un riesgo a la baja (Downside Risk) controlado en 11.06%, lo que le permite obtener un Sortino ratio de 1.24, el segundo más alto entre todas las metodologías evaluadas. Este resultado indica una excelente relación retorno/riesgo ajustado por pérdidas. Además, al basarse en Support Vector Regression, el modelo es más flexible y capaz de capturar relaciones no lineales, ofreciendo una solución moderna, robusta y consistente para la asignación de activos en contextos reales.

Métrica		SVR-CPO	XGBOOST-CPO
Rendimiento Promedio	Anual	17.84%	17.82%
Desviación Estándar		16.95%	17.49%
Rendimiento Efectivo		515.45%	518.78%
Downside Risk		11.06%	11.22%
CAGR		19.37%	19.24%

Sortino Ratio	1.2442	1.2255
----------------------	---------------	---------------

Al comparar el desempeño del modelo SVR-CPO con el del XGBoost-CPO mismo que se tomó como base para el desarrollo, ambos muestran resultados similares en cuanto a rentabilidad y riesgo, lo que valida la robustez de la arquitectura basada en regímenes de mercado y aprendizaje automático para la optimización de portafolios. El SVR-CPO alcanza un rendimiento anual promedio ligeramente superior y un CAGR marginalmente mayor, mientras que también presenta una menor desviación estándar y menor Downside Risk, lo que indica un mayor rendimiento promedio por unidad de Downside Risk asumido. En términos de rendimiento efectivo, XGBoost-CPO supera por poco a SVR-CPO, sin embargo, el modelo SVR-CPO logra un Sortino ratio ligeramente más alto, lo que sugiere una mejor eficiencia en la generación de retornos ajustados al riesgo negativo. En conjunto, aunque los resultados son muy cercanos, SVR-CPO ofrece una capacidad superior para obtener rendimientos mayores con menor dispersión, lo que lo convierte en una alternativa particularmente atractiva desde una perspectiva de estabilidad y generalización.

Como áreas de mejora, en primer lugar, sería beneficioso tomar como referencia un mayor número de stocks, ya que esto permitiría enriquecer el análisis predictivo, además de tener accesos a portafolios de distintos mercados. Además, es fundamental implementar estrategias que busquen reducir la volatilidad de las predicciones, ya que este factor puede comprometer la estabilidad y confiabilidad del modelo. Para ello, se podrían incorporar técnicas de suavización o filtrado que atenúen el impacto de variaciones drásticas. Por otro lado, es importante optimizar el proceso de selección de hiperparámetros mediante algoritmos más avanzados, como la búsqueda bayesiana o el uso de técnicas de optimización evolutiva, con el fin de mejorar el ajuste del modelo. También, sería conveniente integrar métricas adicionales que permitan monitorear no solo el desempeño predictivo sino también la robustez y consistencia en diferentes escenarios de mercado. Por último, una mayor frecuencia en los precios de los activos permitiría entrenar al modelo con un mayor número de datos, cambiar la periodicidad de los precios de mensual a diaria

sería un punto muy importante a tomar en cuenta en caso de continuar con este proyecto o como referencia para otros proyectos similares.

6. Bibliografía

- Ang, A. (2014). Asset management: A systematic approach to factor investing. Oxford University Press.
- Black, F., & Litterman, R. (1992). Global portfolio optimization. *Financial Analysts Journal*, 48(5), 28-43. <https://doi.org/10.2469/faj.v48.n5.28>
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91. <https://doi.org/10.2307/2975974>
- Meucci, A. (2005). Risk and asset allocation. Springer.
- Rockafellar, R. T., & Uryasev, S. (2000). Optimization of conditional Value-at-Risk. *Journal of Risk*, 2(3), 21-41.
- Roncalli, T. (2013). Introduction to risk parity and budgeting. Chapman & Hall/CRC Financial Mathematics Series.
- Chan, E., Fan, H., Sawal, S., & Viville, Q. (2023, 28 de junio). Conditional Portfolio Optimization: Using Machine Learning to Adapt Capital Allocations to Market Regimes. SSRN.
- Chen, J. (2022, 17 de abril). What is the TED Spread? Definition, How It's Used and Calculation. Investopedia. <https://www.investopedia.com/terms/t/tedsread.asp>
- Ganti, A. (2022, 3 de junio). Market Indicators: Definition, How They're Used, and Examples. Investopedia. https://www.investopedia.com/terms/m/market_indicators.asp
- Kenton, W. (2024, 4 de abril). Sortino Ratio: Definition, Formula, Calculation, and Example. Investopedia. <https://www.investopedia.com/terms/s/sortinoratio.asp>
- Amazon Web Services. (s.f.). What is Boosting? Recuperado de <https://aws.amazon.com/es/what-is/boosting/>
- Amazon Web Services. (s.f.). What is a Neural Network? Recuperado de <https://aws.amazon.com/es/what-is/neural-network/>
- Jacobsoft. (2025). Support Vector Regression. Recuperado de https://www.jacobsoft.com.mx/es_mx/support-vector-regression/

- Interactive Chaos. (s.f.). Gradient Boosting. Recuperado de <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/gradient-boosting>
- Equipo Singular Bank. (2017, 21 de julio). Qué es y para qué sirve el ratio de Sortino. El Blog de SelfBank By Singular Bank. Recuperado de <https://blog.selfbank.es/el-ratio-de-sortino-midiendo-la-volatilidad/>
- Colaboradores de Wikipedia. (2024a, 2 de noviembre). TED spread. Wikipedia, la Enciclopedia Libre. Recuperado de https://es.wikipedia.org/wiki/TED_spread
- Colaboradores de Wikipedia. (2024b, 2 de noviembre). VIX. Wikipedia, la Enciclopedia Libre. Recuperado de <https://es.wikipedia.org/wiki/VIX>
- Índice DXY | Índice del Dólar hoy - Investing.com. (2001, 2 de octubre). Investing.com Español. Recuperado de <https://es.investing.com/currencies/us-dollar-index>
- ISM Report on Business®. (s.f.). Institute for Supply Management. Recuperado de <https://www.ismworld.org/supply-management-news-and-reports/reports/ism-report-on-business/>
- Kenneth R. French - Data Library. (s.f.). Dartmouth College. Recuperado de https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html

Anexos

Repositorio de GitHub:

https://github.com/RaniaAguirre/New_CPO.git