

**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)**  
**Programa de Modelación Matemática para el desarrollo de planes y**  
**proyectos de negocio**



**4J05 - Optimización de Programas de Inversión en Intermediarios**  
**Financieros**  
**Optimización Condicional de Portafolios utilizando Máquinas de Vectores**  
**Soporte**

**PRESENTAN**

Ing. Financiero Francisco Alexander Sotomayor Pineda

Ing. Financiero Sergio Renato González Mendoza

Ing. Financiero Luis Adrián López Enríquez

Lic. En Finanzas Juan Pablo Ocegüera Villarruel

Profesores PAP: Sean Nicolás González Vázquez y Luis Felipe Gómez Estrada

Tlaquepaque, Jalisco, julio 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 .....	3
1.4. Contexto.....	4
2. Desarrollo .....	5
2.1. Sustento teórico y metodológico .....	5
2.2. Planeación y seguimiento del proyecto .....	8
3. Resultados del trabajo profesional.....	12
4. Reflexiones del alumno o alumnos sobre sus aprendizajes, las implicaciones éticas y los aportes sociales del proyecto .....	19
5. Conclusiones.....	25
6. Bibliografía.....	26
Anexos .....	27

## 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

*Esta investigación propone una arquitectura de conditional portfolio optimization (CPO) basada en Support Vector Regression (SVR), utilizando el Ratio de Sortino como métrica objetivo. Se empleó un proceso metodológico en cinco fases que incluyó recolección de datos, selección y transformación de variables, entrenamiento de modelos, validación cruzada temporal y backtesting dinámico con rebalanceos semestrales y simulaciones con ventanas aleatorias. Los resultados muestran que SVR-CPO supera en rendimiento anual, CAGR y Ratio de Sortino a métodos tradicionales (mínima varianza y máximo Sharpe) y a otras técnicas basadas en aprendizaje automático como XGBoost. Se recomienda su implementación para gestores que buscan equilibrio entre rendimiento y riesgo ajustado. Entre las limitaciones destaca un rendimiento medio en Downside Risk, aunque compensa con mayor consistencia general. La contribución es original al reemplazar árboles de regresión por SVR en CPO, lo que mejora la parsimonia del modelo. En conclusión, SVR-CPO representa una alternativa flexible, robusta y adaptativa frente a metodologías tradicionales de asignación de activos.*

## 1. Introducción

### 1.1. Objetivos

El objetivo de este proyecto fue replicar la metodología de Contional Portfolio Optimization (CPO) propuesta por Chan (2023) y, sobre esa base, desarrollar mejoras técnicas que aumentaran la precisión y la robustez de la optimización de portafolios. En particular, se buscó ajustar la frecuencia de muestreo para trabajar con datos diarios, diseñar un pipeline unificado que integrara limpieza, selección de características y validación cruzada y perfeccionar la calibración de hiper-parámetros del modelo SVR. Con ello, se pretendió optimizar directamente el Ratio de Sortino para garantizar métricas con resultados positivos.

### 1.2. Justificación

La creciente complejidad y volatilidad de los mercados empujan a desarrollar herramientas de asignación de activos capaces de responder de forma dinámica a estos movimientos. Para ello, adoptamos una frecuencia diaria de muestreo, lo que permitió reflejar con mayor fidelidad las oscilaciones y transiciones de régimen. El clustering automático de regímenes mediante KMeans aporta una señal condicional más objetiva que sustituye clasificadores manuales. Para mejorar la precisión y la estabilidad del SVR, implementamos un pipeline de procesamiento y validación temporal que transformó la variable objetivo, generó nuevas características y afinó los hiperparámetros con Grid Search y TimeSeriesSplit. Finalmente, evaluamos la robustez de la estrategia con un backtesting dinámico—con rebalances semestrales y ventanas aleatorias de cinco años—asegurando resultados consistentes en distintos horizontes temporales y entornos de mercado.

### 1.3 Antecedentes

La Teoría Moderna de Portafolios (MPT) de Markowitz (1952) sentó las bases cuantitativas de la asignación eficiente de activos, minimizando la varianza para un retorno esperado y trazando la “frontera eficiente”. Modelos posteriores, como Black–Litterman, incorporaron las expectativas subjetivas del inversionista, mientras que las estrategias de Paridad de Riesgo buscaron distribuir uniformemente el riesgo entre los activos. Para enfrentar la presencia de eventos extremos y la sensibilidad a errores de estimación, surgieron enfoques de optimización robusta y de media–CVaR, que priorizan la contención de las pérdidas en la cola de la distribución. Más recientemente, Chan et al. (2023) presentaron CPO con árboles de boosting, demostrando la utilidad de condicionar las asignaciones a regímenes de mercado. En este proyecto damos un paso adicional al reemplazar el boosting por Support Vector Regression (SVR) y sustituir el Sharpe Ratio por el Sortino Ratio, optimizando así la penalización de caídas y mejorando la resistencia al ruido.

### 1.4. Contexto

El proyecto se desarrolla con datos del mercado de renta variable de Estados Unidos durante el periodo del 1 de enero de 2010 al 1 de enero de 2025, un lapso que abarca la recuperación tras la crisis financiera global, la pandemia de COVID-19, ciclos de ajuste de tasas y tendencias de elevada volatilidad. Para capturar esta dinámica, se obtuvieron precios diarios de 425 activos del S&P 500 y se combinaron con indicadores macroeconómicos y de sentimiento procedentes de Yahoo Finance, FRED y Bloomberg; estos datos se limpiaron y se homogeneizaron en frecuencia diaria.

La identificación de regímenes de mercado se realizó con clustering (KMeans) y la asignación de activos se optimizó mediante un modelo de SVR orientado al Ratio de Sortino. La robustez de la estrategia se comprobó con un backtesting dinámico de rebalanceos semestrales y ventanas aleatorias de cinco años, sin ventas en corto ni comisiones, lo que permitió evaluar su consistencia bajo distintos escenarios de mercado.

## 2. Desarrollo

### 2.1. Sustento teórico y metodológico

#### **Estado del Arte**

El CPO 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 (Rossi, 2024), 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 (Ganti, A. 2022).

El CPO busca optimizar una función objetivo (usualmente alguna métrica de desempeño) por medio de variables de decisión, en este caso los pesos de cada activo  $w$ , para proponer un portafolio óptimo bajo la situación actual del mercado (Chan et al., 2023).

El modelo incorpora información condicional mediante una función de predicción de retornos ajustada a las condiciones del mercado y el riesgo condicional se modela a través de la matriz de covarianza condicional, que puede ser estimada mediante métodos como Shrinkage Estimators o GARCH (Hossain & Ghahramani, 2016).

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

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

Donde  $\lambda$  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

- **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 SVR, 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. 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. 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 los 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.

- **Periodicidad diaria**

La nueva propuesta contempla aumentar la frecuencia de los datos de precios de mensual la cual utilizamos con anterioridad a diaria. Al utilizar retornos diarios como insumo, el modelo captura con mayor detalle las dinámicas de los distintos regímenes de mercado y reduce el sesgo introducido por la agregación temporal. En nuestro backtesting dinámico, calculamos todas las métricas de desempeño —incluyendo Rendimiento anual promedio, Downside Risk y Ratio de Sortino— a partir de retornos diarios, lo que demuestra la solvencia y consistencia de las asignaciones generadas. Esta granularidad adicional permite una estimación más precisa de la función objetivo y una reacción más ágil ante cambios estructurales mejorando la robustez del portafolio en entornos de alta volatilidad. Asimismo, un mayor volumen de datos diarios facilita la detección de señales tempranas y refuerza la capacidad del modelo para aprender patrones no lineales sin comprometer la estabilidad

## 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 - 16 de junio de 2025**

En esta fase inicial nos centramos en la construcción de la nueva base de datos con periodicidad diaria (utilizamos mensual anteriormente). A partir de estos datos se desarrolló un clasificador de portafolios capaz de generar tres datasets distintos, entrenando un modelo SVR para cada uno y definiendo el flujo de trabajo que abarca desde la ingestión hasta el backtesting dinámico.

### **2ª Etapa - 30 de junio de 2025**

Durante esta etapa se pulieron y documentaron en detalle todos los componentes desarrollados previamente. Se profundizó en la revisión de literatura interna del IMEF para asegurar que el planteamiento metodológico cumpliera con los estándares institucionales y se establecieron los lineamientos editoriales para el documento profesional. Con ello se dejaron completamente terminados y versionados los modelos SVR, el flujo de trabajo reproducible y el repositorio de código limpio.

### **3ª Etapa - 14 de julio de 2025**

Se dio por concluido el documento final estructurado conforme a las guías de publicación profesional. El documento integra la metodología SVR-CPO con periodicidad diaria, la evaluación comparativa de rendimiento basada en Sortino Ratio y un análisis de sensibilidad robusto además de la implementación del backtesting dinámico.

### **4ª Etapa - 17 de julio de 2025**

Finalmente, en esta última fase se llevó a cabo la redacción del RPAP, resumiendo las principales contribuciones, hallazgos y aprendizajes del semestre. Se preparó la presentación para la exposición final, incorporando diagramas de flujo, resultados de backtesting y propuestas de mejora para la adopción de la periodicidad diaria en proyectos de optimización de portafolios.

## **Plan de trabajo**

Para lograr los objetivos del proyecto se estableció una planeación organizada en cuatro etapas con una duración aproximada de dos semanas cada una a excepción de la última que fue más corta. 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.

### **Asesorías con el profesor PAP:**

- **Frecuencia:** Dos veces por semana usualmente, los martes y sábados después de clase.
- **Contenido:** Revisión de avances, solución de dudas técnicas, retroalimentación metodológica y orientación general del proyecto.

## **Recursos necesarios**

Humanos:

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

Materiales:

- Artículos académicos, bibliografía técnica.

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:

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

**Desarrollo de propuesta de mejora**

**Fecha:** 16 de junio de 2025

**Actividades realizadas:**

- Construcción de la base de datos con periodicidad diaria: obtención y clasificación de regímenes de mercado.
- Implementación del clasificador por capitalización de mercado para segmentar en tres datasets (High, Mid, Low).
- Entrenamiento de modelos SVR específicos para cada segmento ajustando los hiper parámetros.

**Fecha:** 30 de junio de 2025

**Actividades realizadas:**

- Revisión de literatura y lineamientos de publicación del IMEF para estandarizar la redacción académica.
- Finalización y validación de los modelos SVR-CPO entrenados sobre datos diarios.
- Diseño e implementación del framework de backtesting dinámico, con métricas de desempeño sobre retornos diarios.

**Fecha:** 14 de julio de 2025

**Actividades realizadas:**

- Elaboración del manuscrito académico final: integrando metodología, resultados de backtesting y análisis comparativo.

**Fecha:** 17 de julio de 2025

**Actividades realizadas:**


- Entrega final del proyecto, incluyendo código versionado, documentos finales, etc.
- Compilación y revisión de la documentación final: reporte técnico, presentación ejecutiva y cuaderno de trabajo.

### 3. Resultados del trabajo profesional

Una vez concluido el *backtesting*, se obtuvo un promedio de todas las métricas a través de las mil simulaciones realizadas, además de la generación de histogramas y diagramas de caja y bigotes por cada una de las métricas de rendimiento con la ayuda de las librerías de *seaborn* y *matplotlib.pyplot*.

Empezaremos con el análisis de los histogramas los cuales nos permitieron comprender la distribución de los datos y entender con qué frecuencia ocurrieron las siguientes métricas: rendimiento anual promedio, el Ratio de Sortino y el Downside Risk. Aunque no son todas las métricas que evaluamos durante el *backtesting*, nos ayudan a tener un panorama más amplio del comportamiento de cada metodología a través de las mil simulaciones. Cabe destacar que en este análisis no se toma en cuenta la metodología de inversión pasiva en el S&P500.

**Gráfica 1. Histograma del Rendimiento Anual Promedio.**

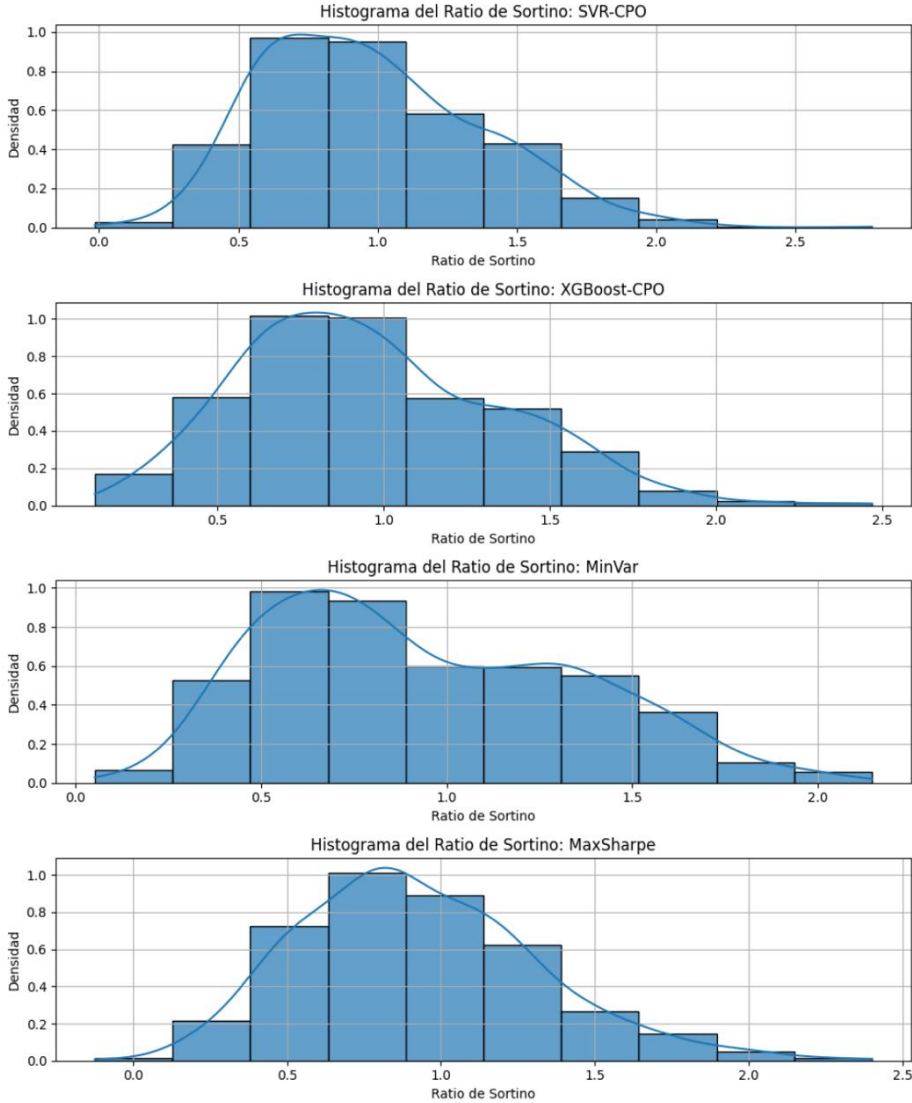


Fuente: Elaboración propia con datos de Yahoo Finance y resultados del backtesting realizado entre los años 2010 y 2025.

En el primer conjunto de histogramas (Gráfica 1) podemos observar que las metodologías SVR-CPO y XGBoost-CPO son las que centran sus distribuciones en rangos de rendimientos superiores con la mayor cantidad de las simulaciones concentradas (entre 15% y 20%) de rendimiento promedio anual. Esta concentración nos da a entender que las metodologías que utilizan Machine Learning son capaces de capturar de manera más eficiente las relaciones no lineales entre los indicadores de mercados y el comportamiento de los portafolios generando así resultados más altos y consistentes en cuanto a término

estadísticos. En contraste, tenemos que los portafolios de Mínima Varianza y Máximo de Sharpe muestran resultados inferiores debido a sus metodologías más tradicionales, en cuanto a la Mínima Varianza se observa una distribución a la izquierda con valores promedio cercanos al 14% y una menor variabilidad lo que coincide con sus objetivos conservadores de baja volatilidad en donde se sacrifica el retorno potencial de la inversión. Por último, el portafolio Máximo de Sharpe cuenta con una distribución intermedia que llega a superar ligeramente a la Mínima Varianza, pero no logra alcanzar los rendimientos ni las consistencias mostradas por las metodologías basadas en Machine Learning.

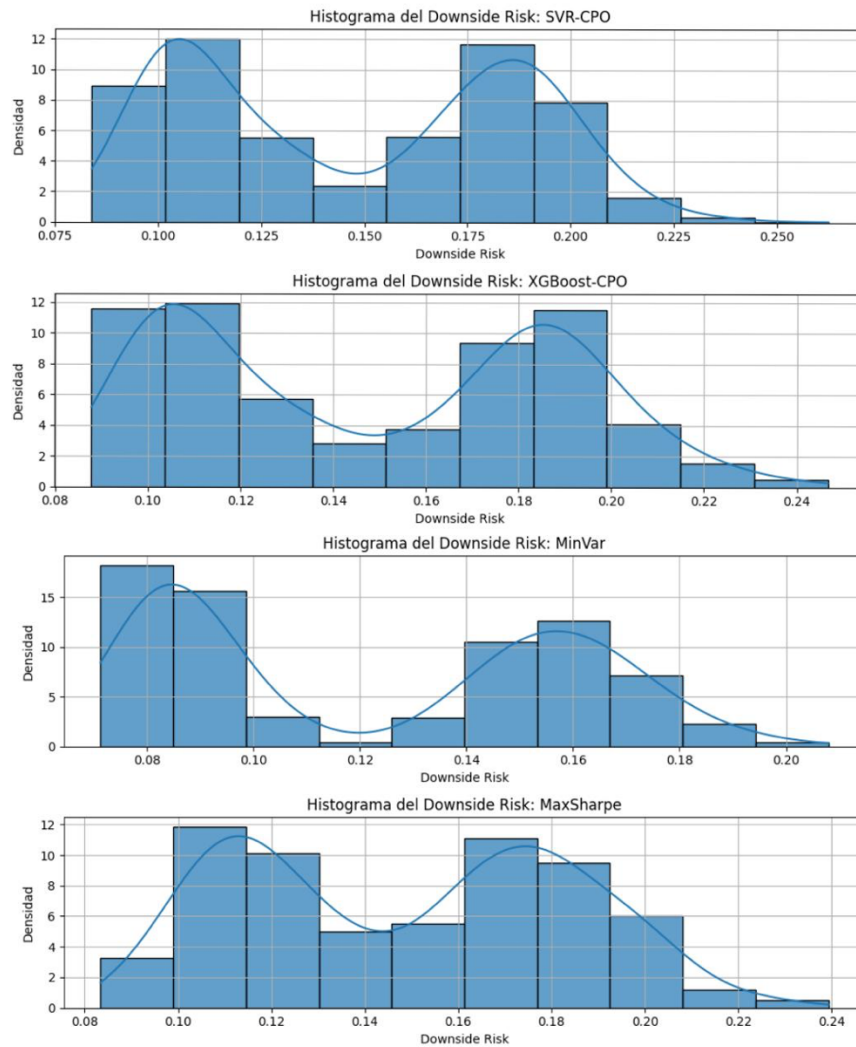
**Gráfica 2. Histograma del Ratio de Sortino.**



Fuente: Elaboración propia con datos de Yahoo Finance y resultados del backtesting realizado entre los años 2010 y 2025.

En el segundo conjunto de gráficos (Gráfica 2) enfocados en el Ratio de Sortino podemos visualizar la manera en la que se distribuyen los rendimientos ajustados al riesgo a la baja, en donde, nuevamente las metodologías de SVR-CPO y XGBoost-CPO muestran una concentración importante de los resultados en valores superiores a 0.9 con una mayor densidad en los intervalos de 0.9 a 1.5, lo que refleja que dichas metodologías no solo ofrecen un desempeño superior, sino que también lo logran hacer de manera más consistente. Específicamente con el SVR-CPO el cual presenta una curva suavizada que se desplaza a la derecha lo que proporciona un mayor grado de estabilidad. Por otro lado, tanto el portafolio de Mínima Varianza como el Máximo de Sharpe muestran una distribución más estrecha, concentrada en valores que van aproximada de entre 0.5 y 1, lo que nos indica que su capacidad para maximizar el rendimiento ajustado al riesgo negativo es inferior en comparación con las técnicas basadas en aprendizaje automático.

**Gráfica 3. Histograma del Downside Risk.**



Fuente: Elaboración propia con datos de Yahoo Finance y resultados del backtesting realizado entre los años 2010 y 2025.

La tercera serie de histogramas (Gráfica 3) enfocada el análisis del Downside Risk (la probabilidad de que el valor de una inversión disminuya o incurra a pérdidas), nos muestra que el portafolio de Mínima Varianza tiene la menor dispersión y los valores más bajos (entre 8% y 14%). Este comportamiento dentro del histograma lo posiciona como la alternativa más conservadora la cual va en base a su metodología tradicional. En segunda posición tenemos las metodologías basadas en Machine Learning (SVR-CPO y XGboost-CPO) en la que SVR-CPO destaca por tener una distribución con mayor simetría,

concentrándose en un 15%, sugiriendo una gestión del riesgo más estable. Por último, dentro del portafolio de Máximo de Sharpe podemos observar una distribución con mayor dispersión y un Downside Risk superior, confirmando su metodología con un enfoque más agresivo, orientada en la maximización del rendimiento estando dispuesto a tener una mayor exposición a la volatilidad negativa, lo cual puede implicar mayor nivel de pérdidas dentro de un mercado bajista.

En resumen, los modelos de aprendizaje automático (Machine Learning) demuestran tener un mejor balance en las métricas de rendimiento y riesgo, mientras que las estrategias tradicionales (Mínima Varianza y Máximo de Sharpe) al estar orientadas a perfiles de inversión con objetivos más específicos, reducen su flexibilidad y presentan un desempeño más desequilibrado frente a distintos escenarios de mercado.

**Tabla 1.** Resultados de métricas de las metodologías.

Metodología	Rendimiento Anual	Volatilidad	Rendimiento Efectivo	Downside Risk	CAGR	Ratio de Sortino
<b>MaxSharpe</b>	17.38%	19.60%	123.75%	14.91%	16.88%	0.928625
<b>MinVar</b>	14.44%	15.48%	96.36%	12.20%	14.22%	0.936946
<b>SVR-CPO</b>	17.53%	18.90%	124.26%	14.80%	17.15%	0.97373
<b>XGBoost-CPO</b>	17.47%	18.98%	123.40%	14.88%	17.06%	0.965764
<b>S&amp;P500</b>	12.20%	16.84%	71.79%	13.72%	11.34%	0.61024

Fuente: Elaboración propia con datos de Yahoo Finance y resultados del backtesting realizado entre los años 2010 y 2025.

La tabla 1 muestra el desempeño promedio de las cuatro estrategias de inversión propuestas previamente evaluadas mediante un *backtesting* dinámico de mil simulaciones con periodos aleatorios de 5 años entre 2010 y 2025 y con un periodo de rebalanceo semestral. Dichas estrategias fueron comparadas con el desempeño de una inversión pasiva en el índice S&P500 bajo la misma metodología del backtesting.

Los resultados indican nuestra metodología propuesta destacó por encima de las demás metodologías en cuatro importantes métricas: rendimiento anual (17.53%), rendimiento

efectivo (124.26%), CAGR (17.15%) y ratio de Sortino (0.97373). Esto nos habla de una metodología que ofrece un gran equilibrio entre riesgo y rendimiento.

Por su parte, el portafolio de Mínima Varianza ofrece una alternativa con menor volatilidad (15.48%) y riesgo a la baja (12.20%), las métricas más bajas entre todas las metodologías comparadas. Esto lo posiciona como una opción conservadora y a su vez competitiva, pues obtuvo un ratio de Sortino bastante competitivo (0.9369), muy por encima del índice de referencia (0.6102).

Un hallazgo relevante que vale la pena destacar es que las metodologías de asignación de activos basadas en Machine Learning, específicamente SVR-CPO y XGBoost-CPO, superaron en cuatro de los seis rubros a las metodologías tradicionales, los únicos rubros en los que no destacaron fueron aquellos relacionados con la volatilidad, como la desviación estándar y el Downside Risk. Este desempeño sugiere que las metodologías de asset allocation impulsadas con Machine Learning representan una gran alternativa para la gestión de portafolios, permitiendo optimizar los gestores de portafolios que solo tendrán que preocuparse por hacer una buena elección de activos y elegir que métrica de rendimiento quieren maximizar.

**Tabla 2.** Resultados de métricas SVR-CPO & XGBoost-CPO.

Metodología	Rendimiento Anual	Volatilidad	Rendimiento Efectivo	Downside Risk	CAGR	Ratio de Sortino
<b>SVR-CPO</b>	17.53%	18.90%	124.26%	14.80%	17.15%	0.97373
<b>XGBoost-CPO</b>	17.47%	18.98%	123.40%	14.88%	17.06%	0.965764

Fuente: Elaboración propia con datos de Yahoo Finance y resultados del backtesting realizado entre los años 2010 y 2025.

Ahora, comparando nuestra metodología propuesta utilizando Regresión con Vectores Soporte contra la de Chan et al. (2023) utilizando árboles de regresión con Boosting, obtuvimos mejores resultados en todas las métricas de rendimiento (Tabla 2). Mejores rendimientos y volatilidades más bajas, así como un riesgo ajustado a la baja más alto

colocando a nuestra metodología como una mejor alternativa para aquellos inversionistas precavidos, pero que buscan buenos rendimientos. Esto no solamente demuestra la eficacia de elegir el ratio de sortino por encima del ratio de Sharpe como métrica de rendimiento, sino que también ofrece una alternativa a los árboles de regresión con Boosting, pues el algoritmo de Regresión con Vectores Soporte (SVR) también captura relaciones no lineales y es un algoritmo muy parsimonioso.

Asimismo, puede ser una herramienta de gran utilidad para aquellos gestores de fondos que solo se tienen que preocupar por elegir los activos que van a conformar el portafolio y de correr el modelo con cierta frecuencia (3,6 o 12 meses), y el modelo se encargará de elegir aquella combinación de pesos que maximice el rendimiento ajustado al riesgo a la baja.

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

- Aprendizajes profesionales

Durante el desarrollo del proyecto, fortalecimos nuestras competencias analíticas y cuantitativas aplicadas en finanzas, en especial en el área de Asset Allocation mediante los modelos de aprendizaje automático (Machine Learning). Aprendimos a estructurar un flujo completo de trabajo desde la recolección y limpieza de bases de datos robustas, hasta la implementación de modelos predictivos y de backtesting dinámico siguiendo metodologías replicables en el ámbito profesional.

Nos enfrentamos al reto de aplicar técnicas de ingeniería financiera como la implementación de hiperparámetros, lo cual nos permitió comprender los límites y alcances reales del uso de algoritmos como SVR en contextos financieros complejos (mercados cambiantes). Además, el contraste con metodologías tradicionales (Mínima Varianza y Máximo de Sharpe) nos ayudó a visualizar las ventajas competitivas de los enfoques modernos y el potencial que tienen las nuevas metodologías enfocadas en inteligencia artificial.

Es importante mencionar que este proyecto nos ayudó a trabajar en conjunto con estudiantes de Finanzas e Ingeniería Financiera, lo cual fortaleció nuestra capacidad de trabajo en equipo y abrió nuestro panorama en cuanto a la aportación de diversas perspectivas y una toma de decisiones más eficiente y acertada.

- **Aprendizajes sociales**

El proyecto aporta a la transformación del sistema financiero tanto mexicano como mundial, debido a su versatilidad en diversos mercados globales, abriendo la puerta a soluciones más eficientes y adaptativas para la gestión de portafolios. Implementando una perspectiva más social, el proyecto ofrece una alternativa más accesible y robusta para que inversionistas pequeños y medianos puedan optimizar sus inversiones en un entorno cambiante.

Nuestro modelo reduce la necesidad de intervención humana en procesos de decisión de asignación de activos y permite la automatización de procesos de inversión, otorgando estrategias exclusivas que han sido utilizadas por fondos de inversión sofisticados. Esto puede ayudar a gestores menos experimentados a tener una mejor toma de decisiones, generando una mejor estabilidad económica en individuos, familias o cualquier cliente que requiera de servicios de inversión.

El desarrollo también fortaleció nuestras capacidades para proponer soluciones de base tecnológica orientadas al bien común, posicionándonos como agentes capaces de liderar la transformación digital del sector financiero.

- **Aprendizajes éticos**

Durante el desarrollo del proyecto, uno de los principales aprendizajes éticos fue reconocer la responsabilidad que implica desarrollar modelos que pueden llegar a influir de manera directa a personas e instituciones en cuanto a decisiones

financieras. Esto nos ayudo a priorizar la transparencia, la reproducibilidad del modelo y sobre todo la mitigación de sesgos durante el proceso.

Nos enfrentamos a decisiones críticas, como la elección de métricas de optimización como el Ratio de Sortino en lugar del Ratio de Sharpe, el cual nos refleja mejor los intereses reales de inversionistas que es la volatilidad negativa que puede llegar a tener la inversión, esto nos ayuda a tener una percepción más clara del riesgo y la relación que existe con el rendimiento.

A partir de este proyecto, ejerceremos nuestra profesión teniendo un enfoque no solo orientado a la rentabilidad, sino también al bienestar financiero del usuario y el contexto en el que se aplican las herramientas determinadas.

- Aprendizajes en lo personal

#### **Francisco Alexander Sotomayor Pineda**

- ¿El PAP qué me dio para conocerme a mí?

Me brindo múltiples herramientas para conocer mi potencial en distintas áreas como investigación, organización, resolución de problemas, trabajo en equipo, trabajo bajo presión, etc. Todos estos aprendizajes me los quedo para poder aplicarlos a mi vida profesional y personal.

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

Me ayudó a obtener un panorama más amplio acerca del estatus actual de la sociedad en lo que respecta a conocimientos sobre inversiones y finanzas. Es así como me di cuenta de que yo y mis compañeros, como miembros de la comunidad que muchas veces padece este problema, debemos hacer todo lo que está en nuestras manos para poder reducir el analfabetismo financiero en nuestra sociedad, siendo este uno de los pilares más importantes en la movilidad socioeconómica y en el objetivo de tener una vida digna.

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

Al trabajar con estudiantes de distintas disciplinas me ayudó a obtener un enfoque distinto respecto al trabajo realizado. Aprendí a comprender los distintos puntos de vista que pueden existir y a trabajar para poder plasmarlos en este trabajo, manteniendo la esencia que cada uno le puede brindar a un proyecto multidisciplinario.

- ¿Qué aprendí para mi proyecto de vida?

Aprendí a trabajar en equipo, a organizar equipos de trabajo, a trabajar con estudiantes de distintas disciplinas y con distintos puntos de vista, a realizar investigaciones de manera profesional, el proceso de redactar un artículo de investigación de manera profesional y a cumplir con las metas y los objetivos establecidos en tiempo y forma.

### **Juan Pablo Ocegüera Villarruel**

- ¿El PAP qué me dio para conocerme a mí?

Me ayudó a conocer mi potencial en un ambiente que tenía muy poco conocimiento pero siempre me llamó la atención que es la ingeniería financiera, conocí los métodos que usan y la manera de trabajo al momento de desarrollar un proyecto que nunca vería en mi carrera, cabe aclarar que fue desafiante entender muchos conocimientos de los cuales nunca había visto, pero fue una experiencia muy enriquecedora y me abrió mi panorama ante los diversos sectores que existen dentro del sector financiero, en especial en el sector bursátil en la parte de análisis de datos.

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

Me enseñó cómo se puede implementar la inteligencia artificial y diversos tipos de algoritmos al momento de tener toma de decisiones en cuando a inversiones, dándole una perspectiva completamente diferente a la que me han enseñado en la licenciatura. Me ayudó a expandir mis conocimientos en diversas ramas de las

finanzas y descubrí una nueva pasión por el uso de modelos matemáticos y tecnológicos al momento de hacer Asset Allocation.

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

Aprendí a convivir con personas que, a pesar de ser del mismo ramo, la implementación de las finanzas es diferentes, me motivaron a indagar un poco más en su área de conocimiento y pude absorber técnicas o conceptos que puedo llegar a usar dentro de mi campo laboral para llegar a tener una ventaja competitiva ante otros licenciados en finanzas.

- ¿Qué aprendí para mi proyecto de vida?

El PAP mejoró mi habilidad del trabajo en equipo lo que me será útil en el desarrollo de mi vida profesional ya sea trabajando para una empresa o en una propia. Me enseñó nuevas técnicas y conceptos que puedo implementar en un futuro, y por último me ayudó a describir mi potencial aún cuando mis conocimientos del tema son muy escasos.

### **Sergio Renato González Mendoza**

- ¿El PAP qué me dio para conocerme a mí?

Esta experiencia reforzó mi capacidad de organización y responsabilidad en el trabajo en equipo, pues aprendí a gestionar y priorizar mi tiempo para cumplir puntualmente con mis tareas diarias y con proyectos complejos que implican la colaboración de otros. Además, me ayudó a detectar áreas de mejora en mi desempeño personal, lo que, al trabajarlas, ha impulsado significativamente mi desarrollo profesional.

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

Me brindó la oportunidad de conectar con compañeros de la carrera conociéndolos mejor, entender sus metodologías y adaptarme a un ritmo de trabajo diferente. Además, pude absorber sus distintas perspectivas, valorar sus aportaciones y enriquecer tanto mi crecimiento personal como mi capacidad de colaboración en equipo.

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

El PAP me permitió valorar las diferencias y similitudes entre mis compañeros, tanto en sus formas de pensar como en sus métodos de trabajo independientemente de si sus trayectorias de vida son parecidas o muy distintas a las mías. Asimismo, entendí que una comunicación clara y un entendimiento mutuo son fundamentales para alcanzar las metas comunes y que la participación de cada integrante potencia el éxito colectivo y el desarrollo personal.

- ¿Qué aprendí para mi proyecto de vida?

Esta experiencia me mostró cómo el trabajo en equipo potencia nuestras fortalezas y revela habilidades ocultas, permitiéndome aprovechar cada contribución de manera positiva o con áreas de mejora como oportunidades de crecimiento personal y profesional, y reforzó mi compromiso de valorar y desarrollar el talento de quienes me rodean.

### **Luis Adrián López Enríquez**

- ¿El PAP qué me dio para conocerme a mí?

Me hizo ver que, bajo presión, disfruto investigar que otras aportaciones puedo proponer, pero también descubro que tiendo a posponer tareas si no marco plazos claros. Aprendí a planear mejor mi tiempo y a disfrutar el reto de resolver problemas complejos en equipo.

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

El darme cuenta de que la mayoría de las personas vive con miedo o desconfianza hacia las finanzas porque no tienen un punto de partida claro. Al colaborar con mi equipo y compartir hallazgos, entendí que podemos empoderar a otros brindándoles herramientas sencillas prácticas para tomar decisiones de inversión informadas.

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

Al colaborar con compañeros de distintas carreras y estilos de trabajo, aprendí a escuchar y combinar ideas muy diferentes. Esa pluralidad de enfoques enriqueció el proyecto y me enseñó a adaptarme a dinámicas variadas de grupo.

- ¿Qué aprendí para mi proyecto de vida?

Descubrí la importancia de estructurar tareas, usar herramientas tecnológicas de forma eficiente y comunicarme con claridad. El proyecto reforzó mi capacidad de trabajo en equipo y me dio confianza para asumir futuros retos.

## 5. Conclusiones

A lo largo del PAP, pudimos validar una metodología innovadora de optimización condicional de portafolios (CPO), basadas en el algoritmo Support Vector Regression (SVR), utilizando el Ratio de Sortino como métrica de desempeño. Tras realizar mil simulaciones en un esquema de backtesting dinámico, comprobamos que SVR-CPO logra superar en métricas clave como rendimiento anual, CAGR y Ratio de Sortino, superando así métodos tradicionales como Mínima Varianza y Máximo de Sharpe, así como modelos de Machine Learning como XGboost-CPO. Para nosotros, fue relevante evidenciar que los modelos de Machine Learning pueden ofrecer soluciones más eficientes y adaptativas frente a la volatilidad del mercado, destacando el Ratio de Sortino, que se enfoca en la volatilidad negativa, lo que lo hace más alineado con los intereses de los inversionistas.

Sin embargo, identificamos que el modelo cuenta con ciertas limitantes. Aunque SVR-CPO mostró un buen desempeño en términos de rendimiento y estabilidad, este cuenta con niveles de Downside Risk intermedios, lo que nos demuestra que no es la mejor opción ante perfiles muy conservadores. Además, es fundamental contar con datos de alta calidad y habilidades técnicas avanzadas para su correcta implementación. En cuanto a futuros desarrollos del proyecto, consideramos interesante explorar modelos híbridos que integren SVR con técnicas de reducción de riesgo, así como su implementación en otro tipo de mercados como el de las criptomonedas.

En resumen, el proyecto cumplió con los objetivos propuestos, validó una metodología moderna para la asignación dinámica de activos y aporta una base sólida para futuras investigaciones y aplicaciones en el ámbito financiero.

## 6. Bibliografía

1. Black, F., & Litterman, R. (1992). Global portfolio optimization. *Financial Analysts Journal*, 48(5), 28–43. <https://doi.org/10.2469/faj.v48.n5.28>
2. 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. <https://doi.org/10.2139/ssrn.4383184>
3. Jacobsoft. (2025). Support Vector Regression. Recuperado de [https://www.jacobsoft.com.mx/es\\_mx/support-vector-regression/](https://www.jacobsoft.com.mx/es_mx/support-vector-regression/)
4. Kenton, W. (2024, 4 de abril). Sortino Ratio: Definition, Formula, Calculation, and Example. Investopedia. <https://www.investopedia.com/terms/s/sortinoratio.asp>
5. Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91. <https://doi.org/10.2307/2975974>
6. Rockafellar, R. T., & Uryasev, S. (2000). Optimization of conditional Value-at-Risk. *Journal of Risk*, 2(3), 21–41.
7. Rossi, J. P. (2024, agosto 21). *La rentabilidad esperada y el riesgo: Una introducción a su análisis*. LinkedIn. <https://www.linkedin.com/pulse/la-rentabilidad-esperada-y-el-riesgo-una-introducci%C3%B3n-rossi-mbelf/>
8. Ganti, A. (2022, julio 21). *Market regime*. Investopedia. <https://www.investopedia.com/terms/m/market-regime.asp>
9. Hossain, S., & Ghahramani, M. (2016). *Shrinkage estimation of linear regression models with GARCH errors*. *Journal of Statistical Theory and Applications*, 15(4), 405–419. <https://doi.org/10.2991/jsta.2016.15.4.8>

Anexos

Repositorio de GitHub: [https://github.com/RaniaAguirre/New\\_CPO.git](https://github.com/RaniaAguirre/New_CPO.git)