

Quantitative Trading Algorithm Based on Systematic Optimization of Decision Thresholds

Matías Adell¹, Javier Balda¹, Facundo Casas¹, and
Antonio Quintero-Rincón^{1,2} 

¹ Departamento de Ciencia de Datos, Laboratorio de Ciencia de Datos e Inteligencia Artificial, Universidad Católica Argentina (UCA), Buenos Aires, Argentina

² Departamento de Ingeniería Informática, Universidad Católica Argentina (UCA), Buenos Aires, Argentina
`{matiasadell,javierbalda,facundocasas,antonioquintero}@uca.edu.ar`

Resumen Analyzing financial markets such as the Nasdaq, the S&P 500, Apple stock, and Bitcoin poses significant challenges due to their high volatility and the complex interactions among these assets and various US macroeconomic indicators. This study proposes a quantitative trading algorithm that optimizes buy and sell decision thresholds in financial markets, using eight macroeconomic indicators, particularly the interest rate and inflation. To address the data's complexity and high dimensionality, five dimensionality reduction methods (PCA, t-SNE, LDA, PPCA, and VSD) were comparatively evaluated, with PCA being identified as the procedure with the highest computational efficiency and best overall performance. Subsequently, a backtracking scheme was implemented to determine the optimal buy and sell thresholds that maximize the return on investment under the market conditions considered. Applying these thresholds to various financial assets yielded outstanding results, with returns of 98.92 % for the Nasdaq, 109.44 % for the S&P 500, and 160.27 % for Apple, over an approximate four-year time horizon. However, the model showed substantially lower effectiveness for Bitcoin, a phenomenon attributed to its weak correlation with the macroeconomic indicators included in the analysis. These preliminary results indicate that the proposed algorithm robustly identifies market entry and exit points across the analyzed stocks.

Keywords: Optimization, Financial markets, Macroeconomic indicators, Dimensional reduction, Thresholds.

Algoritmo cuantitativo de trading basado en la optimización sistemática de umbrales de decisión

Resumen El análisis de los mercados financieros, tales como el Nasdaq, el S&P 500, las acciones de Apple y el Bitcoin, plantea desafíos significativos debido a su elevada volatilidad y a la compleja interacción de estos activos con diversos indicadores macroeconómicos de Estados Unidos. En el presente estudio se propone un algoritmo cuantitativo de trading que optimiza los umbrales de decisión de compra y venta en los mercados financieros, utilizando ocho indicadores macroeconómicos, en particular

la tasa de interés y la inflación. Con el propósito de abordar la complejidad y la elevada dimensionalidad de los datos, se evaluaron comparativamente cinco métodos de reducción de dimensionalidad (PCA, t-SNE, LDA, PPCA y VSD), identificándose a PCA como el procedimiento con mayor eficiencia computacional y mejor desempeño global. Posteriormente, se implementó un esquema de backtracking para determinar los umbrales óptimos de compra y venta que maximizan el rendimiento de la inversión bajo las condiciones de mercado consideradas. La aplicación de estos umbrales a los distintos activos financieros analizados generó resultados sobresalientes, con rendimientos del 98,92 % en el Nasdaq, 109,44 % en el S&P 500 y 160,27 % en Apple, en un horizonte temporal aproximado de cuatro años. Sin embargo, el modelo evidenció una eficacia sustancialmente menor en el caso de Bitcoin, fenómeno atribuible a su baja correlación con los indicadores macroeconómicos incorporados en el análisis. Estos resultados preliminares indican que el algoritmo propuesto presenta una capacidad sólida para identificar puntos de entrada y salida del mercado en las acciones analizadas.

Keywords: Optimización, Mercados financieros, Indicadores macroeconómicos, Reducción de dimensionalidad, Umbrales.

1. Introducción

El crecimiento de los grandes volúmenes de datos, junto con el avance de las técnicas estadísticas y computacionales, ha impulsado de manera significativa el análisis cuantitativo de los mercados financieros. No obstante, la elevada volatilidad y la compleja estructura de interdependencia entre los indicadores económicos continúan dificultando la predicción de rendimientos y el diseño de estrategias de inversión óptimas (Mantegna y Stanley, 1999). Dicho análisis abarca tanto activos financieros como indicadores macroeconómicos de referencia (p. ej., tasa de desempleo, índice de precios al consumidor, tipo de los fondos federales, rendimiento de los bonos del Tesoro a 10 años y producción industrial), cuya selección, ponderación y combinación constituyen el principal desafío metodológico para la construcción de modelos orientados a maximizar el retorno ajustado por riesgo (Stock y W. Watson, 2003). En este contexto, una estrategia de trading puede definirse como un conjunto sistemático y explícitamente formulado de reglas que determina el momento de ejecución y la lógica subyacente a las decisiones de compra y venta, con el objetivo de mitigar los sesgos emocionales y gestionar el riesgo de manera cuantificable (Schlotmann y Czubatinski, 2019). Se identifican diversas familias de estrategias, entre las que destacan: el seguimiento de tendencia (Covel y Ritholtz, 2017; Moskowitz et al., 2012), la reversión a la media (Brock et al., 1992; Chan, 2013), el momentum transversal (Asness et al., 2013), el trading por pares (Gatev et al., 2006; Tsay, 2011), el trading de alta frecuencia (Aldridge, 2013; Cartea et al., 2015), las estrategias de arbitraje (J. Hull, 2021; Shleifer y Vishny, 1997), las estrategias basadas en información macroeconómica (Dave y Sorge, 2025) y aquellas fundamentadas en técnicas de ML (de Prado, 2018; Gu et al., 2020). Cada una de estas categorías se caracteriza por horizontes temporales, frecuencias operativas y perfiles de riesgo.

A partir de este marco conceptual, este estudio propone un algoritmo cuantitativo de *trading* fundamentado en ocho indicadores macroeconómicos y cuatro activos financieros representativos (NASDAQ (J. C. Hull, 2023), SPY (Malkiel, 2024), Apple (Damodaran, 2025) y Bitcoin (Böhme et al., 2015)). El desarrollo metodológico se estructura en tres etapas: (1) construcción de una serie temporal homogénea que armonice los distintos calendarios de negociación entre activos financieros tradicionales y criptoactivos; (2) formulación de un modelo predictivo que incorpora técnicas de reducción de dimensionalidad y optimización de umbrales mediante *backtracking*; y (3) implementación de un algoritmo de *trading* basado en un autómata finito determinista, parametrizado mediante los umbrales óptimos de compra y venta. Este enfoque pretende ofrecer una caracterización más rigurosa de la relación entre indicadores macroeconómicos y activos financieros, así como un marco metodológico sistemático para evaluar su eficacia bajo distintos regímenes de mercado.

La organización del documento es la siguiente: en la Sección 2 se describe el método propuesto, estructurado en tres etapas: construcción de la serie temporal homogénea (Etapa 1), reducción de dimensionalidad y optimización de umbrales (Etapa 2) e implementación del algoritmo de trading (Etapa 3). En la Sección 3 se presentan y discuten los resultados, y en la Sección 4 se exponen las conclusiones.

2. Metodología

El estudio busca formalizar un algoritmo de *trading* que optimice compras y ventas mediante umbrales basados en criterios cuantitativos. La estrategia emplea ocho indicadores macroeconómicos y cuatro activos: NASDAQ, SPY, AAPL y BTC. La metodología consta de tres etapas: homogeneización de la serie temporal, diseño de un modelo predictivo (reducción de dimensionalidad y optimización de umbrales) e implementación del algoritmo, validado con datos fuera de muestra (véase Fig. 1).

2.1. Conjunto de datos

Se analiza la relación entre el entorno macroeconómico de Estados Unidos y el rendimiento de activos seleccionados, usando ocho indicadores mensuales obtenidos vía la API de FRED (“FRED API”, 2025) y precios diarios de activos de la API de Yahoo Finance (“Yahoo! Finance’s API”, 2025), con 5519 observaciones de NDAQ, 7879 de SPY, 8641 de AAPL y 2470 de BTC (véase Cuadro 1).

Cuadro 1: Indicadores económicos estadounidenses seleccionados.

No.	Indicador	Descripción
1	Tasa de Desempleo	Nivel de salud económica y empleo
2	Índice de Precios al Consumidor	Inflación y poder adquisitivo
3	Tasa de Fondos Federales	Expectativas de tipos de interés
4	Tasa del Tesoro a 10 años	Expectativas de crecimiento
5	Producción Industrial	Nivel de actividad industrial
6	Consumo Personal	Gasto de los consumidores
7	Tasa de Interés	Costo del dinero a corto plazo
8	Inflación	Cambio en el nivel de precios




Figura 1: Esquema del enfoque propuesto en tres etapas. La etapa 1 (azul) genera una serie temporal homogeneizada a partir de los datos disponibles. En la etapa 2 (púrpura) se aplica una técnica de reducción de dimensionalidad y se optimizan los umbrales de decisión mediante *backtracking*. En la etapa 3 (rojo) se implementa el algoritmo cuantitativo de trading para decidir las operaciones de compra/venta en el mercado.

2.2. Etapa 1

Interpolación por replicación: Dado que los activos financieros tradicionales cotizan únicamente en días hábiles bursátiles, mientras que BTC opera de manera continua, se construye una serie temporal homogénea mediante interpolación por replicación (*forward fill* / *LOCF*) (Oppenheim y Schafer, 2014), que asigna a cada día no hábil el último valor observado. El procedimiento consta de cuatro etapas: (i) definición de una malla diaria basada en días hábiles; (ii) cálculo de los rendimientos logarítmicos de los activos; (iii) prolongación hacia adelante del último valor disponible de cada indicador macroeconómico; y (iv) construcción, para cada día, del vector conjunto de variables explicativas. El conjunto de datos resultante se particiona en subconjuntos de entrenamiento y de prueba.

La interpolación por replicación, también denominada *forward fill*, *step interpolation* o *Last Observation Carried Forward (LOCF)*, consiste en replicar el último valor observado hasta el momento en que se dispone de una nueva observación efectiva. Sea $P_a(t)$ el precio de cierre del activo a en el instante t ; la serie

diaria completa $\tilde{P}_a(t)$ se define, por tanto, como:

$$\tilde{P}_a(t) = \begin{cases} P_a(t), & \text{si existe cotización en } t, \\ \tilde{P}_a(t^-), & \text{si } t \text{ corresponde a un día no hábil,} \end{cases} \quad (1)$$

donde t^- es el último día anterior con una observación válida.

Serie temporal: El problema a resolver consiste en la construcción de una serie temporal multivariada homogénea de la forma:

$$X_t = [P_t^{(1)}, \dots, P_t^{(N)}, M_t^{(1)}, \dots, M_t^{(K)}], \quad (2)$$

donde $P_t^{(i)}$ denota los precios o rendimientos de un conjunto de activos financieros observados con frecuencia diaria y $M_t^{(k)}$ representa indicadores macroeconómicos registrados con menor frecuencia, típicamente mensuales o trimestrales. Para obtener una representación conjunta diaria, se sigue este procedimiento:

1. Se define una malla temporal diaria común $\tau = \{t_1, t_2, \dots, t_T\}$, formada solo por días hábiles de negociación.
2. Se alinean las series de precios de los activos con τ , de modo que $P_t^{(i)}$ quede definido para todo $t \in \tau$. Luego se calculan los rendimientos logarítmicos:

$$r_t^{(i)} = \log P_t^{(i)} - \log P_{t-1}^{(i)}.$$

3. Se homogeneizan los indicadores macroeconómicos de baja frecuencia mediante extensión hacia adelante de su último valor disponible. Para cada indicador $M^{(k)}$ se define:

$$\widetilde{M}_t^{(k)} = M_{t_j}^{(k)},$$

donde

$$t_j = \max\{s \leq t : M_s^{(k)} \text{ dato observado}\},$$

es el último instante $s \leq t$ con una observación efectiva de $M^{(k)}$. La serie temporal multivariada resultante es:

$$X_t = [r_t^{(1)}, \dots, r_t^{(N)}, \widetilde{M}_t^{(1)}, \dots, \widetilde{M}_t^{(K)}], \quad (3)$$

donde K es el número total de indicadores macroeconómicos considerados.

Conjuntos de datos de entrenamiento y prueba: El conjunto de datos homogéneo X_t (Eq. (3)) se particiona en una matriz de entrenamiento y una de prueba, empleadas respectivamente para el ajuste y la validación del modelo.

2.3. Etapa 2

Reducción de dimensionalidad (RD): Estas técnicas reducen la dimensionalidad del espacio de variables preservando la información estadísticamente más relevante y mejorando la interpretabilidad y la eficiencia computacional. En este trabajo se consideran cinco enfoques: **PCA** (Abdi y Williams, 2010; Ghogh et al., 2023), que proyecta los datos sobre las direcciones de máxima varianza; **LDA** (Fisher, 1936; Fukunaga, 1990), que calcula proyecciones lineales que maximizan la separabilidad entre clases; **t-SNE** (Hinton y Roweis, 2002; van der

Maaten y Hinton, 2008), que preserva la estructura de vecindad local minimizando la divergencia de Kullback–Leibler entre distribuciones de similitud en los espacios original y embebido; **PPCA** (Bishop, 2006), una formulación probabilística generativa del PCA cuyos parámetros se estiman mediante el algoritmo de maximización de la esperanza (EM); y **GSVD** (Golub y Van Loan, 2013; Van Loan, 1976), que generaliza la descomposición en valores singulares (SVD) a la descomposición simultánea de dos matrices. Solo los métodos basados explícitamente en la varianza, como PCA, proporcionan una noción rigurosa y cuantificable de varianza explicada.

Regla de decisión Para identificar la técnica de reducción de dimensionalidad que mejor preserve la estructura de los datos se emplean dos criterios complementarios. El primero es la correlación de Pearson entre las distancias euclidianas por pares en el espacio original y en el reducido (van der Maaten et al., 2008):

$$\rho = \text{corr} \left(\left\{ d_{ij}^{(\text{original})} \right\}_{i < j}, \left\{ d_{ij}^{(\text{reducido})} \right\}_{i < j} \right), \quad (4)$$

Valores cercanos a 1 indican alta preservación de las relaciones de proximidad. El segundo es el error de reconstrucción $\mathcal{E}$, definido como la norma de Frobenius de la diferencia entre la matriz de datos original estandarizada X y su matriz de reconstrucción $\hat{X}$:

$$\mathcal{E} = \|E\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^p (x_{ij} - \hat{x}_{ij})^2}; \quad (5)$$

valores bajos de $\mathcal{E}$ indican alta fidelidad de la representación reducida frente a los datos originales.

2.4. Etapa 3

Optimización de umbrales usando la técnica de *Backtracking*: Para determinar los umbrales óptimos de compra y venta que maximizan el retorno de la inversión, se implementó un esquema de *backtracking* (Cormen et al., 2022; Rossi et al., 2006), que recorre el espacio de soluciones construyendo recursivamente candidatos parciales y descartándolos en cuanto vulneran las restricciones. El vector de puntuaciones de las dos primeras componentes principales en el instante t se define como:

$$pc(t) = (pc1(t), pc2(t)) \in \mathbb{R}^2. \quad (6)$$

Al definir $\theta_c = (\theta_{c,1}, \theta_{c,2})$ y $\theta_v = (\theta_{v,1}, \theta_{v,2})$ como los umbrales de compra y venta, respectivamente, obtenidos empíricamente mediante *backtracking*, se introducen la función de compra f_c y la función de venta f_v :

$$f_c(pc(t), \theta_c) = \begin{cases} 1 & \text{si } pc1(t) \geq \theta_{c,1} \wedge pc2(t) \geq \theta_{c,2}, \\ 0 & \text{en otro caso,} \end{cases} \quad (7)$$

$$f_v(pc(t), \theta_v) = \begin{cases} 1 & \text{si } pc1(t) \leq \theta_{v,1} \wedge pc2(t) \leq \theta_{v,2}, \\ 0 & \text{en otro caso.} \end{cases} \quad (8)$$

El signo de PC2 no tiene una interpretación económica fija entre activos, porque la dirección de los autovectores en PCA es arbitraria (puede invertirse sin cambiar la varianza explicada). Por tanto, la orientación de la región de compra/venta sobre PC2 se define empíricamente para cada activo mediante *backtracking* y no debe verse como un signo universal de tendencia.

Algoritmo cuantitativo de *trading* El comportamiento del sistema se representa mediante un autómata finito determinista (AFD) $A = (Q, \Sigma, \delta, q_0, F)$, donde $Q = \{q_0, q_1, q_{-1}\}$ corresponde a los estados posibles (mantención de la posición, compra y venta, respectivamente) y el alfabeto de entrada está dado por $\Sigma = \{C, V, N\}$. En este contexto, $C \Leftrightarrow f_c = 1$, $V \Leftrightarrow f_v = 1$ y N indica la ausencia simultánea de ambas condiciones. La función y el diagrama de transición δ se detallan en el Cuadro 2 y la Fig. 2.

Cuadro 2: Tabla de transición del AFD de trading.

Estado actual	Entrada	Estado siguiente
$\rightarrow q_0$	C (Condición de compra satisfecha.)	q_1
q_0	N (Ausencia de condiciones satisfechas.)	q_0
q_1	V (Condición de venta satisfecha.)	q_{-1}
q_1	N	q_1
q_{-1}	N	q_0

Cabe señalar que, para ciertos umbrales, f_c y f_v pueden ser simultáneamente verdaderas (por ejemplo, si $\theta_{c,k} < \theta_{v,k}$); sin embargo, esto no genera ambigüedad, ya que δ solo evalúa f_c en q_0 y f_v en q_1 (véase Cuadro 2), determinando de forma unívoca la condición relevante en cada instante t .




Figura 2: Diagrama de transición del AFD de trading.

El Algoritmo 1 presenta una complejidad temporal de orden lineal, específicamente $O(n)$, así como una complejidad espacial también de orden lineal, $O(n)$, donde n denota el número de registros históricos de retornos financieros considerados en el procesamiento.

3. Resultados y discusión

Esta sección presenta los resultados de la evaluación del Algoritmo de *trading* para las series financieras (véase la Fig. 3), propuesto en el Algoritmo 1, siguiendo las tres etapas de la Sección 2.

Algorithm 1: Algoritmo de trading basado en PCA

Input: Puntajes PCA: pca_scores , Retornos: $returns$, Umbral: $umbral$

Output: Cambio de capital: $capital_change$, Historial de posiciones:

```
     $position\_history$ 
1  $capital \leftarrow 100$ ;
2  $position \leftarrow 0$  // Mantener
3  $position\_history \leftarrow \emptyset$ ;
4  $capital\_history \leftarrow \emptyset$ ;
5  $flag\_compra \leftarrow false$ ;
6 for  $i \leftarrow 1$  to  $|returns|$  do
7    $pc1 \leftarrow pca\_scores(i, 1)$ ;
8    $pc2 \leftarrow pca\_scores(i, 2)$ ;
9   /* Cambio de estados */
10  if  $(position = 0 \wedge condicion\_compra = true)$  then
11     $position \leftarrow 1$ ;
12     $flag\_compra \leftarrow true$ ;
13  else if  $(position = 1 \wedge condicion\_venta = true)$  then
14     $position \leftarrow -1$ ;
15     $flag\_compra \leftarrow false$ ;
16  else if  $position = -1$  then
17     $position \leftarrow 0$ ;
18  /* Cálculo del retorno */
19  if  $position \neq 0$  then
20     $capital \leftarrow capital \times (1 + returns(i))$ ;
21     $capital\_history(i) \leftarrow capital$ ;
22     $position\_history(i) \leftarrow position$ ;
23  $capital\_change \leftarrow capital - 100$ ;
24 return  $capital\_change, position\_history$ 
```

El Cuadro 3 muestra los resultados de aplicar la regla de decisión basada en el coeficiente de correlación de Pearson, calculado a partir de las distancias euclidianas entre observaciones (véase Sección 2.3). Esta regla identificó cuál de las cinco técnicas de RD preserva mejor la estructura intrínseca de los datos. Los resultados muestran que PCA, PPCA y GSVD alcanzan coeficientes de




Figura 3: Serie de tiempo homogénea de los activos financieros.

correlación cercanos a 1, lo que refleja una alta capacidad para conservar las relaciones de distancia entre los espacios original y reducido. En contraste, LDA presenta un coeficiente de correlación moderado y t-SNE un desempeño deficiente en esta preservación.

El Cuadro 3 reporta los errores de reconstrucción, donde PCA, PPCA y GSVD logran los mejores valores. Errores bajos indican mayor fidelidad en la representación de los datos, mientras que errores altos reflejan una pérdida importante de información. Con base en este análisis, se determinó que PCA es la técnica de RD más adecuada para el conjunto de datos, por lo que los resultados presentados a continuación se obtienen empleándola como método principal.

Cuadro 3: Cálculo del coeficiente de correlación de Pearson entre las distancias euclidianas en el espacio reducido y en el original, y estimación cuantitativa del error de reconstrucción.


Técnica	Correlación con la distancia original	Error de reconstrucción
PCA	0.9965	4.8545e-12
t-SNE	0.0788	-
LDA	0.4205	-
PPCA	0.9941	54.5243
SVD	0.9965	34.9648

Las Fig. 4a a 4d muestran la configuración espacial de los umbrales optimizados para los tres estados, proyectados sobre los dos primeros componentes principales (PC1 y PC2). Las zonas en rojo delimitan las subregiones donde se activa la estrategia de venta, las zonas en verde las asociadas a la estrategia de compra y la región en blanco entre los umbrales de decisión representa el estado neutral vinculado a mantener la posición. En estas figuras, PC1 muestra variaciones suaves y persistentes, con raros cruces de umbral pero de larga duración. Esto indica que PC1 captura la dinámica estructural dominante del mercado, vinculada a cambios de régimen de carácter secular o de horizonte extendido. En particular, los intervalos en que PC1 se mantiene de forma sostenida por encima (o por debajo) de los umbrales se corresponden con fases alcistas (*Bull Market*) o bajistas (*Bear Market*) prolongadas en los precios de los activos subyacentes. En contraste, PC2 muestra una dinámica oscilatoria de mayor frecuencia, con cruces recurrentes de los umbrales superior e inferior. Esto sugiere que PC2 se asocia a fluctuaciones transitorias, posiblemente ligadas a correcciones técnicas, rebotes y episodios de volatilidad de corto o mediano plazo. El Cuadro 4 sintetiza el comportamiento conjunto de los umbrales asociados a ambos componentes principales.


Cuadro 4: Comportamiento conjunto de los umbrales.

PC1	PC2	Comportamiento
PC1 > umbral alto	PC2 > 0	Tendencia alcista fuerte
PC1 > umbral alto	PC2 < umbral bajo	Corrección dentro de tendencia
PC1 < umbral bajo	PC2 < 0	Tendencia bajista consolidada
PC1 < umbral bajo	PC2 > umbral alto	Rebote técnico


La variación porcentual acumulada de la rentabilidad de los activos financieros con la estrategia de *trading* propuesta (Algoritmo 1) fueron de: Nasdaq 98,92 %, S&P 500 109,44 %, Apple 160,27 % y BTC 0 %.




(a) NDAQ



(b) SPY



(c) AAPL



(d) BTC

Figura 4: Umbrales optimizados en el plano de los dos primeros componentes principales (PC1 y PC2) de cada activo. La región roja indica la estrategia de venta, la verde la de compra y la blanca la de mantener la posición (neutral).

Adicionalmente, el Cuadro 5 presenta los valores umbral cuantitativos óptimos de los dos primeros componentes principales del conjunto de datos, que pueden emplearse como criterio formal para formular reglas de decisión en la compra y venta de activos. Estos umbrales se estimaron y calibraron con información histórica y se mantuvieron constantes durante la fase de evaluación. Para estas

Cuadro 5: Umbrales cuantitativos de los componentes principales.

Umbral y PC	Nasdaq	S&P 500	Apple	BTC
Compra PC1	-2.00	0.10	1.60	-1.10
Compra PC2	-0.50	0.70	-1.40	-0.80
Venta PC1	-1.70	0.40	1.90	0.10
Venta PC2	-0.20	-1.70	-1.70	-1.10

instancias se dispone de los valores de los dos primeros componentes principales, PC1 y PC2, junto con los umbrales de compra y venta optimizados que maximizan el rendimiento. Esta información forma parte de las variables explicativas de entrada del algoritmo de *trading*, que se evalúa usando el 70 % de los datos como muestra de entrenamiento y el 30 % restante como muestra de prueba (véase la Sección 2.1). La Fig. 5 muestra ejemplos representativos de los cuatro activos financieros analizados en la etapa de prueba del modelo (véase la Sección 2.2). En cada caso se ilustra la evolución temporal del precio (panel superior) y la posición discreta generada por el algoritmo de trading (panel inferior). La posición toma valores en $\{0, 1\}$, que representan los estados de mantener (neutral, (0).) y comprar (+1). El algoritmo de trading presenta las siguientes propiedades:

1. Opera con baja frecuencia, priorizando decisiones estructurales frente a ajustes tácticos de corto plazo.
2. Capta tendencias de larga duración, reduciendo la sobreoperación en entornos de alta volatilidad.
3. Mantiene un comportamiento estadísticamente consistente entre periodos de entrenamiento (*in-sample*) y prueba (*out-of-sample*).
4. Adopta una postura más conservadora en activos muy volátiles, como BTC, generando menos señales.

En general, los resultados muestran que el algoritmo propuesto identifica de forma robusta los puntos de entrada y salida del mercado para los instrumentos accionarios analizados. En particular, el modelo es altamente eficiente en la detección de puntos óptimos de compra y venta en activos de referencia como el Nasdaq y el S&P 500, lo que se refleja en las altas tasas de rentabilidad obtenidas en las pruebas experimentales. En el caso de Apple, el modelo alcanzó un rendimiento del 160,27 %. En el caso de Bitcoin, su menor rentabilidad se debe a su débil vinculación con los indicadores macroeconómicos de Estados Unidos, consecuencia de su naturaleza descentralizada.

Desde una perspectiva computacional, el algoritmo propuesto ofrece un desempeño eficiente tanto en el manejo de grandes volúmenes de datos como en operaciones en tiempo real. Además, permite determinar umbrales óptimos de compra y venta con alta flexibilidad, ya que el usuario puede ajustarlos según la dinámica de los componentes principales seleccionados.

4. Conclusión

Este estudio presenta un algoritmo cuantitativo de *trading* que optimiza sistemáticamente umbrales de decisión, formalizado mediante un autómata finito determinista, lo que permite definir de forma rigurosa y reproducible las condiciones de compra y venta. Entre cinco técnicas de reducción de dimensionalidad, el PCA fue la más adecuada según la regla de decisión propuesta. Los umbrales óptimos derivados de sus dos primeras componentes principales produjeron resultados favorables para NASDAQ, S&P 500 y Apple, mientras que la eficacia fue mucho menor para Bitcoin, atribuida a su baja correlación con los indicadores macroeconómicos analizados.




Figura 5: Resultados de la etapa de prueba del algoritmo de *trading*. El panel superior muestra el precio de mercado del activo y el inferior, la posición y rentabilidad al aplicar el Algoritmo 1, no el rendimiento pasivo del activo.

Las principales limitaciones radican en la calibración de umbrales mediante *backtracking* y en la construcción de la serie temporal homogénea, donde pueden ignorarse dinámicas intraperíodo o introducirse discontinuidades por publicaciones macroeconómicas. Los trabajos futuros se centrarán en optimizar los umbrales con técnicas alternativas, usándolos como parámetros de regularización en modelos de aprendizaje automático.

Referencias

- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *WIREs Computational Statistics*, 2(4), 433-459.
<https://doi.org/10.1002/wics.101>
- Aldridge, I. (2013). *High-Frequency Trading: A Practical Guide to Algorithmic Strategies and Trading Systems*. Wiley.
- Asness, C. S., Moskowitz, T. J., & Pedersen, L. H. (2013). Value and Momentum Everywhere. *The Journal of Finance*, 68(3), 929-985. <https://doi.org/10.1111/jofi.12021>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Böhme, R., Christin, N., Edelman, B., & Moore, T. (2015). Bitcoin: Economics, Technology, and Governance. *Journal of Economic Perspectives*, 29(2), 213-38.
<https://doi.org/10.1257/jep.29.2.213>
- Brock, W., Lakonishok, J., & LeBARON, B. (1992). Simple Technical Trading Rules and the Stochastic Properties of Stock Returns. *The Journal of Finance*, 47(5), 1731-1764.
<https://doi.org/10.1111/j.1540-6261.1992.tb04681.x>
- Cartea, A., Jaimungal, S., & Penalva, J. (2015). *Algorithmic and High-Frequency Trading*. Cambridge University Press.
- Chan, E. P. (2013). *Algorithmic Trading: Winning Strategies and Their Rationale*. Wiley.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., & Stein, C. (2022). *Introduction to Algorithms*. The MIT Press.
- Covel, M. W., & Ritholtz, B. (2017). *Trend Following: How to Make a Fortune in Bull, Bear, and Black Swan Markets*. Wiley.
- Damodaran, A. (2025). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*. Wiley.
- Dave, C., & Sorge, M. M. (2025). *Lectures on Dynamic Macroeconomics: Methods and Applications*. World Scientific Publishing Company.
- de Prado, M. L. (2018). *Advances in Financial Machine Learning*. Wiley.
- Fisher, R. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2), 179-188.
<https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>
- FRED API [Accessed: 2025-12-12]. (2025).
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*. Academic Press.
- Gatev, E., Goetzmann, W. N., & Rouwenhorst, K. G. (2006). Pairs Trading: Performance of a Relative-Value Arbitrage Rule. *The Review of Financial Studies*, 19(3), 797-827.
<https://doi.org/10.1093/rfs/hhj020>
- Ghojogh, B., Crowley, M., Ghodsi, A., & Karray, F. (2023). *Elements of Dimensionality Reduction and Manifold Learning*. Springer.

- Golub, G., & Van Loan, C. (2013). *Matrix Computations*. Johns Hopkins University Press.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223-2273. <https://doi.org/10.1093/rfs/hhaa009>
- Hinton, G. E., & Roweis, S. T. (2002). Stochastic Neighbor Embedding. *Neural Information Processing Systems*.
- Hull, J. (2021). *Options, Futures, and Other Derivatives*. Pearson.
- Hull, J. C. (2023). *Risk Management and Financial Institutions*. Wiley.
- Malkiel, B. G. (2024). *A Random Walk Down Wall Street: The Best Investment Guide That Money Can Buy*. W. W. Norton & Company.
- Mantegna, R. N., & Stanley, H. E. (1999). *Introduction to Econophysics: Correlations and Complexity in Finance*. Cambridge University Press.
- Moskowitz, T. J., Ooi, Y. H., & Pedersen, L. H. (2012). Time series momentum [Special Issue on Investor Sentiment]. *Journal of Financial Economics*, 104(2), 228-250. <https://doi.org/10.1016/j.jfineco.2011.11.003>
- Oppenheim, A. V., & Schafer, R. (2014). *Discrete-Time Signal Processing*. Prentice Hall.
- Rossi, F., van Beek, P., & Walsh, T. (2006). *Handbook of Constraint Programming*. Elsevier Science.
- Schlotmann, R., & Czubatinski, M. (2019). *Trading: Technical Analysis Masterclass: Master the financial markets*. Independently published.
- Shleifer, A., & Vishny, R. W. (1997). The Limits of Arbitrage. *The Journal of Finance*, 52(1), 35-55. <https://doi.org/10.1111/j.1540-6261.1997.tb03807.x>
- Stock, J. H., & Watson, M. (2003). Forecasting Output and Inflation: The Role of Asset Prices. *Journal of Economic Literature*, 41(3), 788-829. <https://doi.org/10.1257/002205103322436197>
- Tsay, R. S. (2011). *Analysis of Financial Time*. Wiley.
- van der Maaten, L., & Hinton, G. (2008). Visualizing Data using t-SNE. *Journal of Machine Learning Research*, 9(86), 2579-2605.
- van der Maaten, L., Postma, E. O., & van den Herik, J. (2008). *Dimensionality Reduction: A Comparative Review* (inf. téc. N.º TiCC-TR 2009-005). Tilburg University.
- Van Loan, C. F. (1976). Generalizing the Singular Value Decomposition. *SIAM Journal on Numerical Analysis*, 13(1), 76-83. <https://doi.org/10.1137/0713009>
- Yahoo! Finance's API [Accessed: 2025-12-12]. (2025).