

Departamento de Economía

Tipo de documento: Tesis de maestría



Maestría en Econometría

Asignación estratégica de activos de reservas internacionales: Un enfoque comparado entre el modelo de Nelson-Siegel y Redes Neuronales Artificiales

Autoría: Matarrita Valverde, Alejandro

Fecha: 2025

¿Cómo citar este trabajo?

Matarrita Valverde, A. (2025). Asignación estratégica de activos de reservas internacionales: Un enfoque comparado entre el modelo de Nelson-Siegel y Redes Neuronales Artificiales. [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella

<https://repositorio.utdt.edu/handle/20.500.13098/13552>

El presente documento se encuentra alojado en el Repositorio Digital de la **Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional
Dirección: <https://repositorio.utdt.edu>



**UNIVERSIDAD
TORCUATO DI TELLA**

Asignación estratégica de activos de reservas
internacionales: Un enfoque comparado entre el
modelo de Nelson-Siegel y Redes Neuronales
Artificiales

Alejandro Matarrita Valverde

Legajo: 23M1832

Tutora: Daniela Rodríguez

UNIVERSIDAD TORCUATO DI TELLA

DEPARTAMENTO DE ECONOMÍA

MAESTRÍA EN ECONOMETRÍA

15 de junio de 2025

Índice general

1. Introducción	6
1.1. Introducción	6
1.2. Justificación	7
1.3. Conceptos Fundamentales	7
1.3.1. Gestión de Reservas Internacionales	7
1.3.2. Modelos para la Asignación Estratégica	7
Modelo de Nelson-Siegel y su extensión dinámica	7
Redes Neuronales Artificiales (ANN)	8
1.3.3. Criterios de Evaluación de Riesgo	8
Valor en Riesgo (VaR)	8
1.3.4. Fundamentos de Teoría Moderna de Portafolios	8
Frontera Eficiente y Modelo Media-Varianza	8
Riesgo de Cola	8
2. Datos	9
3. Metodología	11
3.1. Estado de la Cuestión	11
3.1.1. Evolución de la Asignación Estratégica de Reservas	11
3.1.2. Modelos Paramétricos: Nelson-Siegel y su Extensión Dinámica	11
3.1.3. Redes Neuronales en Finanzas Cuantitativas	12
3.1.4. Desafíos Teóricos y Vacíos en la Literatura	12
4. Resultados	16
4.1. Comparación de Modelos de Asignación Estratégica	16
4.1.1. Resultados de la Optimización	16
4.2. Evaluación del Desempeño del Modelo ANN por Activo	17
4.3. Proyecciones Pasadas del Modelo ANN	17
4.4. Evaluación Agregada de Retornos Proyectados	18
5. Conclusiones	19
A. Anexos	20
Bibliografía	27

Índice de figuras

A.1. Estadísticas descriptivas de bonos con vencimientos 1–5 años (2005–2023)	20
A.2. Retornos interanuales de bonos con vencimientos 1–5 años (2005–2023)	21
A.3. Matriz de correlación de retornos interanuales (2005–2023)	21
A.4. Comparación de asignación estratégica: ANN vs. BAAM	22
A.5. Rendimiento Real vs Predicho – Bonos de Agencias (Agen)	22
A.6. Rendimiento Real vs Predicho – Bonos de Australia (AUS)	23
A.7. Rendimiento Real vs Predicho – Bonos de Canadá (CAN)	23
A.8. Rendimiento Real vs Predicho – Bonos Corporativos (Corp)	24
A.9. Rendimiento Real vs Predicho – Bonos de Japón (JPN)	24
A.10. Rendimiento Real vs Predicho – Bonos de Corto Plazo	25
A.11. Rendimiento Real vs Predicho – Bonos del Tesoro de EE.UU. (TRE)	25
A.12. Retorno en exceso por modelo	26

Índice de cuadros

3.1. Evolución de la literatura en modelos para asignación estratégica de activos	14
3.2. Comparación entre el Modelo de Nelson-Siegel y Redes Neuronales en la Asignación Estratégica de Activos	15

Resumen

La presente tesis analiza y compara dos enfoques metodológicos para la asignación estratégica de activos en el contexto de la gestión de reservas internacionales. El primer enfoque se basa en el modelo de Nelson-Siegel con rotación de factores y tasas sombra, ampliamente utilizado por bancos centrales para modelar la curva de rendimientos soberanos. El segundo enfoque emplea redes neuronales recurrentes (RNN) para predecir retornos financieros a partir de variables macroeconómicas y de mercado. Utilizando datos de bonos soberanos, corporativos y de agencias de diversas jurisdicciones para el período 2005–2023, se estima y evalúa la efectividad de cada modelo en términos de retorno ajustado por riesgo (índice de Sharpe), Valor en Riesgo (VaR) y proyecciones fuera de muestra. Se incorporan medidas de optimización del portafolio bajo restricciones operativas reales, y se evalúa la robustez de los resultados ante cambios en la dinámica de mercado. Los hallazgos sugieren que, bajo ciertas condiciones, los modelos basados en inteligencia artificial pueden superar en desempeño a los enfoques estructurales tradicionales, contribuyendo con evidencia empírica al debate sobre la modernización de herramientas para la gestión oficial de reservas.

Palabras clave

Asignación estratégica de activos; Reservas internacionales; Modelo de Nelson-Siegel; Redes neuronales artificiales.

Capítulo 1

Introducción

1.1. Introducción

La gestión de reservas internacionales constituye uno de los pilares fundamentales de la estabilidad macroeconómica y financiera de los países. Estas reservas —compuestas por activos líquidos y seguros, como bonos soberanos, divisas extranjeras y oro monetario— no sólo respaldan la moneda nacional y garantizan la solvencia externa, sino que también deben ser administradas estratégicamente bajo principios de seguridad, liquidez y rentabilidad [3, 4]. En este contexto, la asignación estratégica de activos adquiere una importancia creciente para bancos centrales y autoridades monetarias, especialmente ante un entorno global caracterizado por la volatilidad de los mercados financieros, tasas de interés bajas o negativas, y una mayor interdependencia económica internacional.

Históricamente, la asignación de reservas ha estado guiada por modelos estructurados de optimización que presuponen relaciones lineales o paramétricas entre variables financieras clave. Uno de los enfoques más utilizados en este ámbito es el modelo de Nelson-Siegel y su versión dinámica, el Dynamic Nelson-Siegel (DNS), ampliamente implementado por bancos centrales para modelar la curva de rendimientos soberanos [2]. Sin embargo, este tipo de modelos enfrenta limitaciones importantes en su capacidad para adaptarse a entornos no lineales, cambios estructurales y dinámicas de mercado no estacionarias. Estas debilidades se han vuelto más evidentes en contextos de tasas de interés cercanas a cero, lo que ha motivado extensiones del modelo, como la incorporación de tasas sombra [8, 12].

Paralelamente, el avance en técnicas de inteligencia artificial ha abierto nuevas posibilidades para abordar problemas financieros complejos mediante algoritmos capaces de aprender directamente de los datos. En particular, las redes neuronales artificiales (ANN), y más específicamente las redes neuronales recurrentes (RNN), han demostrado un alto potencial en la predicción de series temporales financieras y la optimización de portafolios dinámicos [5, 1, 6]. No obstante, su aplicación al ámbito específico de las reservas internacionales sigue siendo incipiente, y pocos estudios han comparado su desempeño con modelos estructurales tradicionales en condiciones reales de gestión institucional.

En este contexto, la presente investigación propone una evaluación comparativa entre el modelo de Nelson-Siegel (y su versión extendida con tasas sombra) y un modelo de redes neuronales recurrentes (RNN), aplicado al problema de la asignación estratégica de activos dentro de un portafolio de reservas internacionales. A diferencia de trabajos previos que aplican modelos econométricos clásicos o técnicas de machine learning de forma aislada, esta investigación integra ambos enfoques en un marco experimental controlado que permite contrastar sus resultados bajo métricas comunes de retorno y riesgo, como el índice de Sharpe y el Valor en Riesgo (VaR).

El aporte principal de este trabajo radica en su carácter metodológicamente comparativo y aplicado: por un lado, se busca validar el uso de modelos neuronales en una función típicamente reservada a métodos estructurados; por otro, se pretende evidenciar las condiciones bajo las cuales dichos modelos podrían superar en desempeño a las alternativas tradicionales, tanto en términos de predicción como de estabilidad operativa. Así, se espera contribuir tanto al debate académico sobre la integración de técnicas

de inteligencia artificial en las finanzas públicas, como a la generación de evidencia empírica útil para los responsables de política monetaria y reservas soberanas.

1.2. Justificación

El objetivo general de esta investigación es explorar e incorporar modelos de inteligencia artificial, particularmente redes neuronales recurrentes (RNN), en la optimización de portafolios estratégicos de reservas internacionales, con el fin de evaluar su aplicabilidad frente a enfoques econométricos estructurados. En línea con este propósito, se plantean como objetivos específicos la evaluación comparativa del desempeño predictivo y de riesgo entre el modelo de Nelson-Siegel, incluyendo su versión con rotación y tasas sombra, y modelos de redes neuronales entrenados sobre variables macroeconómicas y financieras relevantes; el diseño de un marco de pruebas empíricas para validar la consistencia y robustez de cada enfoque bajo distintas condiciones de mercado; y la identificación de las ventajas y limitaciones de cada metodología desde una perspectiva tanto cuantitativa como operativa, con el fin de ofrecer recomendaciones para su uso potencial en la gestión oficial de reservas.

1.3. Conceptos Fundamentales

Para comprender los elementos analíticos y empíricos que estructuran este trabajo, es necesario establecer un marco conceptual que sintetice los principios clave de la gestión de reservas internacionales y la asignación estratégica de activos. Esta sección introduce los modelos, herramientas cuantitativas y criterios de riesgo más relevantes que serán empleados en el análisis comparativo.

1.3.1. Gestión de Reservas Internacionales

Las reservas internacionales son activos externos bajo control de la autoridad monetaria nacional, utilizados para respaldar la moneda local, estabilizar el mercado cambiario y garantizar el cumplimiento de obligaciones internacionales. Estos activos incluyen divisas libremente convertibles, oro, Derechos Especiales de Giro (DEG) y posiciones frente al Fondo Monetario Internacional (FMI) [4].

La asignación de estos recursos se rige por tres principios jerárquicos: (i) *seguridad* del capital frente al riesgo de mercado y crédito, (ii) *liquidez* para atender obligaciones inmediatas, y (iii) *rentabilidad*, siempre que no comprometa los anteriores [3].

1.3.2. Modelos para la Asignación Estratégica

Modelo de Nelson-Siegel y su extensión dinámica

El modelo de Nelson-Siegel [10] permite representar la estructura temporal de tasas de interés con tres factores latentes:

$$y_t(\tau) = \beta_{1t} + \beta_{2t} \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + \beta_{3t} \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \quad (1.1)$$

- β_{1t} : componente de *nivel* (largo plazo)
- β_{2t} : *pendiente* (diferencia corto-largo plazo)
- β_{3t} : *curvatura* (forma intermedia de la curva)
- λ : parámetro de ajuste de carga exponencial

Diebold y Li [2] extienden el modelo a su forma dinámica (DNS), incorporando un sistema autorregresivo para modelar la evolución estocástica de los factores. En contextos de tasas cercanas a cero, se han desarrollado variantes con tasas sombra [8, 12], que permiten capturar políticas monetarias no convencionales.

Redes Neuronales Artificiales (ANN)

Las ANN son modelos computacionales inspirados en el cerebro humano, formados por capas interconectadas de nodos (neuronas), capaces de aprender funciones complejas directamente desde los datos [5]. En el ámbito financiero, se han utilizado para clasificación, predicción y asignación dinámica de activos.

En el contexto de portafolios, las ANN buscan aprender una función $\Lambda(z_t)$ que relacione un conjunto de variables de estado observadas (z_t) con una distribución óptima de activos para el siguiente período:

$$x_{t+1} = \Lambda(z_t) \quad (1.2)$$

Las redes recurrentes (RNN), incluyendo variantes como LSTM y GRU, han demostrado capacidades superiores para capturar dependencias temporales en series financieras [1, 6].

1.3.3. Criterios de Evaluación de Riesgo

Valor en Riesgo (VaR)

El VaR es una métrica ampliamente utilizada para estimar la pérdida máxima esperada de un portafolio en un horizonte dado con un nivel de confianza α :

$$VaR_\alpha = \inf \{l \in R : P(L \leq l) \geq \alpha\} \quad (1.3)$$

Puede estimarse mediante métodos paramétricos, simulación histórica o simulaciones de Monte Carlo [7].

$$ES_\alpha = E[L | L > VaR_\alpha] \quad (1.4)$$

1.3.4. Fundamentos de Teoría Moderna de Portafolios

Frontera Eficiente y Modelo Media-Varianza

Según la teoría de Markowitz [9], la asignación óptima de activos se basa en la relación entre riesgo y retorno. El conjunto de combinaciones eficientes forma la Frontera Eficiente.

El modelo media-varianza resuelve el siguiente problema:

$$\max_w \left[\mu_p - \frac{\lambda}{2} w' \Sigma w \right] \quad (1.5)$$

donde w son los pesos del portafolio, μ_p el vector de retornos esperados, Σ la matriz de varianzas-covarianzas y λ un parámetro de aversión al riesgo.

Riesgo de Cola

Se refiere a la probabilidad de ocurrencia de pérdidas extremas en la distribución de retornos, más allá del VaR, especialmente relevante en escenarios financieros con colas pesadas.

Capítulo 2

Datos

Se utiliza una base de datos mensual compuesta por retornos de índices de bonos con vencimientos que oscilan entre 1 y 5 años y un índice de corto plazo, cubriendo el período comprendido entre el 31 de enero de 2005 y el 30 de septiembre de 2023. La frecuencia mensual garantiza una resolución temporal adecuada para capturar dinámicas relevantes en los mercados de renta fija sin incurrir en ruido excesivo que suele afectar datos diarios. En total, el conjunto abarca 225 observaciones mensuales por serie.

Los datos provienen de Bloomberg y otras fuentes internacionales para la construcción de los índices de referencia como ICE. La estructura de los datos incluye retornos interanuales expresados en porcentaje, ajustados mensualmente con base en precios de mercado. Para esta tesis, se ha decidido restringir el universo de análisis exclusivamente a los bonos con vencimientos de 1 a 5 años, tanto soberanos como corporativos y de agencias, pertenecientes a las siguientes jurisdicciones y segmentos:

- Estados Unidos: L4US, TRE 1-5
- Australia: AUS 1-5
- Canadá: CAN 1-5
- Singapur: SGP 1-5
- Noruega: NOR 1-5
- Japón: JPN 1-5
- Reino Unido: GBR 1-5
- Francia: FRA 1-5
- Bonos Corporativos: Corp 1-5
- Bonos de Agencias: Agen 1-5

Estos índices incluyen información detallada sobre los siguientes atributos: retorno promedio, retorno mínimo y máximo, retorno acumulado, desviación estándar, razón retorno/riesgo, razón de Sharpe, duración promedio al cierre de septiembre 2023, calificación crediticia soberana, relación deuda/PIB, valor de mercado relativo a reservas internacionales, número de emisiones y bid-ask spread promedio en dólares estadounidenses.

El análisis de las estadísticas descriptivas de los bonos con vencimientos entre 1 y 5 años, presentadas en la Figura A.1, permite identificar diferencias significativas en los perfiles de retorno, riesgo y liquidez entre los activos soberanos, corporativos y de agencias. Los bonos corporativos (Corp 1-5) destacan por registrar el mayor retorno promedio (2,9%) y acumulado (68,4%), aunque a costa de una desviación estándar también elevada (3,9%) y un spread bid-ask relativamente alto (0,102), lo que evidencia su menor liquidez comparativa. En contraste, instrumentos como los bonos del Tesoro de Estados Unidos (TRE 1-5) ofrecen retornos más moderados (2,1%) pero con menor volatilidad (3,0%) y spreads más estrechos (0,050), siendo típicamente utilizados como referencia de bajo riesgo.

Asimismo, se observa que los bonos de agencias (Agen 1-5) presentan características intermedias, con retornos competitivos (2,1%) y menor desviación estándar (2,7%) frente a los corporativos, aunque con una calificación crediticia ligeramente inferior. Este balance entre retorno y riesgo se refleja también en la razón de Sharpe, donde activos como JPN 1-5 y FRA 1-5 muestran valores cercanos a 0,5, indicando una eficiencia superior en términos de retorno ajustado por volatilidad. Finalmente, las métricas de duración,

calificación y liquidez complementan la caracterización de cada instrumento, brindando información clave para la construcción de portafolios diversificados.

Como parte del análisis exploratorio, se graficaron las trayectorias de los retornos interanuales para los distintos índices seleccionados. La Figura A.2 muestra la evolución temporal de estos rendimientos. Se observa una marcada volatilidad en el período 2008–2009, seguida de una relativa estabilidad entre 2012 y 2019, con nuevos aumentos en la volatilidad durante 2020 y 2022. Entre los activos con mayor variabilidad se encuentran los bonos corporativos y de agencias, mientras que los soberanos presentan trayectorias más acotadas.

Adicionalmente, se construyó una matriz de correlación para los retornos interanuales, con el fin de evaluar la dependencia lineal entre activos. Como se observa en la Figura A.3, los bonos soberanos tienden a presentar altas correlaciones entre sí (mayores a 0.8 en muchos casos), lo cual sugiere que comparten exposiciones comunes a factores globales. En contraste, los bonos corporativos y de agencias exhiben correlaciones más débiles, lo que sugiere un mayor potencial para diversificación dentro del portafolio de reservas internacionales.

A partir de los resultados observados, se identificó que los bonos corporativos presentan retornos acumulados significativamente mayores, aunque acompañados de mayor volatilidad y menor liquidez, como lo evidencia el bid-ask spread más elevado. Este equilibrio entre rentabilidad y riesgo será un aspecto clave en la evaluación comparativa entre modelos de asignación, ya que la presencia de activos menos correlacionados con mayor retorno puede representar oportunidades estratégicas, siempre que se gestione adecuadamente su riesgo asociado.

Los datos no están actualmente disponibles en un repositorio público, ya que corresponden a bases internas del Banco Central de Costa Rica, utilizadas bajo acuerdo institucional para fines académicos.

Capítulo 3

Metodología

3.1. Estado de la Cuestión

El presente apartado examina de forma crítica y estructurada el desarrollo académico y aplicado de las metodologías relevantes para la asignación estratégica de activos, particularmente en el contexto de reservas internacionales. Se abordan los enfoques tradicionales basados en modelos estructurales de curvas de rendimiento, así como las propuestas contemporáneas basadas en aprendizaje automático. La revisión se organiza en torno a cuatro grandes líneas: evolución histórica de la asignación de reservas, modelos paramétricos de estructura temporal de tasas, redes neuronales aplicadas a finanzas, y desafíos abiertos en la literatura.

3.1.1. Evolución de la Asignación Estratégica de Reservas

La gestión de reservas internacionales se ha consolidado como una práctica técnica y estratégica dentro de la política macroeconómica moderna. Su objetivo ya no se limita a la estabilización cambiaria, sino que incorpora decisiones estructuradas de inversión que maximizan el retorno ajustado por riesgo bajo fuertes restricciones de liquidez y seguridad [3, 4].

En los marcos iniciales, la asignación estratégica de reservas se basaba en la regla de tres objetivos jerárquicos: seguridad, liquidez y rentabilidad. Sin embargo, con la diversificación de monedas de reserva y la aparición de nuevos instrumentos financieros, se hizo necesaria la incorporación de modelos cuantitativos para respaldar las decisiones estratégicas. Esta evolución dio lugar al uso de modelos como media-varianza de Markowitz, simulaciones estocásticas de escenarios y estructuras de tasas forward.

3.1.2. Modelos Paramétricos: Nelson-Siegel y su Extensión Dinámica

Entre los modelos más influyentes para la representación de la curva de rendimiento se encuentra el modelo de Nelson y Siegel [10]. Su propuesta permite ajustar la curva de tasas de interés mediante tres factores latentes: nivel (β_1), pendiente (β_2) y curvatura (β_3), controlados por un parámetro de decaimiento λ . La expresión canónica del modelo es:

$$y_t(\tau) = \beta_{1t} + \beta_{2t} \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + \beta_{3t} \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \quad (3.1)$$

El modelo fue extendido a una versión dinámica por Diebold and Li [2], integrando una estructura autorregresiva para los factores latentes, y ha sido ampliamente adoptado por bancos centrales, como el BCE, la Fed y el Banco de Inglaterra.

No obstante, el modelo tradicional asume implícitamente que las tasas de interés tienen un límite inferior estrictamente positivo, lo cual se volvió problemático tras las políticas monetarias expansivas del período post-2008. Para abordar esta limitación, diversos autores han introducido versiones de tasas

sombra (shadow rates) [8, 13], en las que la dinámica del modelo permite la existencia de tasas latentes negativas, mientras las tasas observables se limitan al cero. Esta innovación permitió preservar la coherencia estructural del modelo incluso en entornos no convencionales como los observados en Japón, Europa y EE.UU. en la última década.

3.1.3. Redes Neuronales en Finanzas Cuantitativas

En paralelo, los modelos de inteligencia artificial han comenzado a ocupar un espacio creciente en la toma de decisiones financieras, especialmente en contextos donde la estructura funcional subyacente es difícil de especificar. Las redes neuronales artificiales (ANN) se caracterizan por su capacidad para aproximar funciones no lineales complejas, lo cual las hace aptas para modelar relaciones entre variables financieras, económicas y de mercado [5].

En el contexto de asignación de activos, Bradrania and Peiris [1] proponen una arquitectura que mapea directamente las variables de estado del entorno económico (como tasas, inflación, volatilidad implícita, etc.) en los pesos óptimos de una cartera, sin necesidad de especificar una función de utilidad o asumir distribución de retornos. Su modelo aprende directamente una función $x_{t+1} = \Lambda(z_t)$, optimizando así la asignación bajo criterios históricos de desempeño.

La investigación ha avanzado hacia arquitecturas más sofisticadas como las redes neuronales recurrentes (RNN) y sus variantes modernas (LSTM, GRU), que son particularmente eficaces en el tratamiento de series temporales financieras. Estudios recientes [6] han demostrado que estos modelos superan en capacidad predictiva a los modelos clásicos bajo condiciones de alta volatilidad o cambio estructural.

3.1.4. Desafíos Teóricos y Vacíos en la Literatura

Pese al progreso, persisten importantes desafíos conceptuales y empíricos. En primer lugar, los modelos basados en redes neuronales suelen presentar problemas de interpretabilidad, lo cual limita su adopción por parte de entidades como bancos centrales que requieren trazabilidad normativa. Además, estos modelos tienden a requerir grandes cantidades de datos históricos de alta calidad, lo cual no siempre está disponible para activos reservados.

Desde el punto de vista empírico, la comparación rigurosa entre modelos estructurales (como Nelson-Siegel y sus variantes) y enfoques de aprendizaje automático aún es limitada en el dominio específico de la gestión de reservas internacionales. La mayoría de los estudios existentes se enfocan en aplicaciones a renta variable o gestión de fondos privados, lo cual deja una brecha relevante en la literatura aplicada a instituciones públicas y soberanas.

Asimismo, hay escasa investigación sobre la integración de métricas avanzadas de riesgo (como el Valor en Riesgo condicional o Expected Shortfall) en modelos neuronales para la asignación de reservas, lo cual representa un espacio fértil para investigación metodológica aplicada.

Las Tablas 3.1 y 3.2 permiten visualizar, desde una perspectiva histórica y metodológica, la evolución de los enfoques aplicados a la asignación estratégica de activos. La primera tabla sintetiza los hitos conceptuales y aplicaciones más relevantes, desde la formulación original del modelo de Nelson-Siegel en 1987 hasta las implementaciones más recientes de redes neuronales recurrentes en contextos de asignación dinámica. Se observa una transición clara desde modelos estructurados, altamente interpretables y parsimoniosos, hacia métodos más flexibles y no paramétricos, motivados por los avances en capacidad computacional y disponibilidad de datos.

Por su parte, la Tabla 3.2 expone de forma sistemática las principales diferencias entre el modelo de Nelson-Siegel con rotación de factores y precios sombra, y las redes neuronales artificiales. La comparación revela que, si bien el modelo estructural goza de mayor aceptabilidad institucional y claridad interpretativa, su capacidad de adaptación frente a no linealidades y regímenes cambiantes es limitada. En contraste, las redes neuronales muestran un gran potencial en términos de capacidad predictiva y adaptabilidad a entornos complejos, aunque presentan desafíos técnicos y operativos considerables, como su menor interpretabilidad y la necesidad de contar con bases de datos robustas y limpias.

Estas diferencias no sólo ilustran una dicotomía metodológica, sino que reflejan también una oportunidad de investigación aplicada: integrar la robustez institucional de los modelos estructurales con la flexibilidad predictiva de los enfoques de inteligencia artificial, específicamente en el contexto aún poco explorado de la gestión de reservas internacionales.

Cuadro 3.1: Evolución de la literatura en modelos para asignación estratégica de activos

Año	Autor(es)	Modelo / Metodología	Contribución Principal	Aplicación Específica
1987	Nelson & Siegel [10]	Modelo paramétrico de curva de rendimientos	Introducen una especificación parsimoniosa para curvas de tasas basada en tres factores: nivel, pendiente y curvatura	Construcción y modelado de curvas de tasas
2006	Diebold & Li [2]	Modelo dinámico Nelson-Siegel (DNS)	Añaden dinámica temporal a los factores latentes del modelo original para análisis predictivo	Forecasting de tasas soberanas y gestión de deuda pública
2013	Krippner [8]	Tasas sombra	Propone una extensión del modelo DNS que permite valores negativos latentes de tasas, útil en ZLB	Política monetaria no convencional
2022	Opschoor & Strasser [12]	Shadow rates tractables	Desarrollo de una versión tractable de modelos de tasas sombra en contextos macrofinancieros reales	Estimación eficiente bajo límites inferiores
2016	Goodfellow et al. [5]	Redes neuronales profundas (Deep Learning)	Compilación de arquitectura y teoría de redes neuronales, incluyendo RNN y LSTM	Fundamentos aplicados en series temporales
2022	Bradrania & Peiris [1]	ANN con régimen cambiante	Proponen un modelo basado en ANN que asigna portafolios en función de señales macroeconómicas, sin necesidad de distribución de retornos	Asignación dinámica de activos y mejora de portafolios
2024	Huang & He [6]	Redes neuronales recurrentes (RNN)	Aplicación de modelos RNN a series financieras para ajustar portafolios ante cambios estructurales del mercado	Predicción de retornos y optimización dinámica
2024	Ochoa Luzuriaga [11]	ANN en mercado ecuatoriano	Implementación de redes neuronales para modelar portafolios en la Bolsa de Valores de Quito	Contexto emergente; validación local del modelo ANN

Cuadro 3.2: Comparación entre el Modelo de Nelson-Siegel y Redes Neuronales en la Asignación Estratégica de Activos

Dimensión	Modelo de Nelson-Siegel con rotación de factores y precios sombra	Redes Neuronales Artificiales (ANN)
Naturaleza del modelo	Paramétrico, estructural, basado en una representación económica explícita de la curva de tasas	No paramétrico, basado en aprendizaje automático; estructura de caja negra (black box)
VARIABLES PRINCIPALES	Factores latentes: nivel, pendiente, curvatura; parámetros estructurales como λ	Variables observadas de entrada (factores de mercado, tasas, indicadores macro); pesos y bias aprendidos automáticamente
Capacidad de interpretación	Alta: cada parámetro tiene un significado económico claro	Baja: difícil trazabilidad e interpretación de los pesos internos
Adaptabilidad al régimen de tasas bajas (ZLB)	Alta con tasas sombra (shadow rates) [8, 12]	Alta: flexible para aprender no linealidades, sin restricciones estructurales
Capacidad predictiva fuera de muestra	Buena en entornos estables; limitada ante cambios estructurales o no linealidades	Alta en datos complejos o no lineales; sensible a la calidad del entrenamiento
Necesidad de datos	Moderada: series temporales de curvas de tasas, ajustadas periódicamente	Alta: requiere grandes volúmenes de datos históricos y limpieza de datos
Uso institucional	Ampliamente adoptado por bancos centrales (BCE, Fed, BoE) y organismos multilaterales	Poco adoptado por entidades oficiales; más común en fondos cuantitativos y bancos de inversión
Implementación técnica	Relativamente simple; puede estimarse con mínimos cuadrados o Kalman filter	Más compleja: requiere software especializado, selección de arquitectura, y validación cruzada
Aplicación en reservas internacionales	Frecuente: modelado de curvas soberanas, estrés macroeconómico, análisis de duración	Emergente: potencial alto, pero aún no generalizado para gestión oficial de reservas

Capítulo 4

Resultados

4.1. Comparación de Modelos de Asignación Estratégica

Con el objetivo de evaluar enfoques alternativos para la asignación estratégica de activos en el contexto de la gestión de reservas internacionales, se realizaron dos ejercicios empíricos. El primero consistió en la implementación de un modelo basado en redes neuronales artificiales (ANN) utilizando el lenguaje de programación Python. El segundo se llevó a cabo con el *BIS Asset Allocation Module (BAAM)*, una herramienta desarrollada por el Banco de Pagos Internacionales (BIS) orientada a entidades oficiales, que emplea un modelo estructural de proyección basado en factores latentes estimados mediante la metodología de Nelson-Siegel con rotación y tasas sombra [3].

Ambos modelos fueron calibrados utilizando como universo de inversión una selección de instrumentos financieros de vencimiento entre 1 y 5 años, con la inclusión adicional de inversiones a corto plazo como componente esencial de liquidez. La optimización se realizó bajo el criterio del índice de Sharpe, con el objetivo de maximizar el retorno esperado ajustado por riesgo, sujeto a un conjunto de restricciones operativas impuestas exógenamente al proceso.

Estas restricciones reflejan los lineamientos estratégicos de un banco central, estableciendo, en primer lugar, que entre el 31 % y el 75 % del portafolio debe mantenerse en instrumentos de muy corto plazo, a fin de garantizar liquidez inmediata. Además, se definió un límite conjunto del 25 % para la exposición a bonos soberanos emitidos por jurisdicciones distintas a Estados Unidos (Australia, Noruega, Canadá y Japón), con el fin de mitigar riesgos asociados a eventos macroeconómicos o geopolíticos específicos. A nivel individual, las asignaciones permitidas se limitaron a rangos específicos: entre 25 % y 75 % para bonos del Tesoro de EE.UU., entre 0 % y 22 % para bonos de agencias, entre 0 % y 8 % para Australia, Noruega, Canadá y Japón, y entre 0 % y 3.5 % para bonos corporativos.

Cabe destacar que en ambos ejercicios de simulación, tanto en el modelo de redes neuronales como en el implementado mediante el módulo BAAM, se utilizaron proyecciones macroeconómicas como insumo clave para la estimación del comportamiento futuro de las curvas de rendimientos. Estas proyecciones incluyeron variables como tasas de interés de política monetaria, inflación y crecimiento del producto interno bruto (PIB) las cuales fueron integradas como determinantes de los factores latentes en el caso del modelo estructural, o bien como variables de entrada en el entrenamiento de la red neuronal. Esta integración permitió que ambas metodologías reflejaran de forma anticipada los posibles escenarios macroeconómicos futuros, fortaleciendo así la capacidad predictiva de los modelos en la asignación estratégica de activos de reservas internacionales.

4.1.1. Resultados de la Optimización

Desde el punto de vista operativo, ambos modelos generaron portafolios que cumplen con las restricciones institucionales establecidas. En particular, el modelo de redes neuronales favorece de forma clara la liquidez, destinando un 44 % del portafolio a instrumentos de muy corto plazo. Además, asigna un 25 %

a bonos del Tesoro de Estados Unidos, un 10 % a bonos emitidos por agencias gubernamentales y un 6 % a bonos soberanos japoneses. La asignación se completa con bonos australianos (5 %), noruegos (4 %), canadienses (3 %) y bonos corporativos (3 %).

Por su parte, el modelo estructural implementado mediante el módulo *BAAM* del BIS genera una distribución distinta, aunque también prioriza la liquidez. En este caso, las inversiones a corto plazo representan el 38,1 % del portafolio, seguidas por un 17,1 % en bonos del Tesoro de EE.UU. y un 17 % en bonos de agencias. Los bonos de Australia y Noruega reciben cada uno un 8 %, Japón un 6 %, los corporativos un 3,5 % y Canadá un 2 %.

En cuanto a los resultados cuantitativos, estas diferencias reflejan cómo cada metodología interpreta la relación riesgo-rendimiento. El modelo neuronal, al optimizar directamente el índice de Sharpe, refuerza la exposición a activos de alta liquidez y bajo riesgo. En contraste, el enfoque estructural de *BAAM* tiende a una asignación más diversificada y equilibrada entre emisores soberanos y agencias, dentro de los límites operativos definidos exógenamente.

4.2. Evaluación del Desempeño del Modelo ANN por Activo

Como parte del proceso de validación del modelo basado en redes neuronales, se analizaron los rendimientos mensuales reales frente a los valores predichos para cada uno de los activos incluidos en el portafolio. El objetivo de este análisis fue verificar el ajuste del modelo durante la etapa de entrenamiento y evaluar su capacidad de generalización para capturar la dinámica de los retornos financieros.

Los resultados obtenidos muestran que el modelo ANN ofrece un ajuste adecuado en activos con trayectorias más estables, como los bonos de agencias, Japón y los instrumentos de corto plazo, donde la serie predicha reproduce con precisión tanto la dirección como la magnitud relativa de los retornos observados. En estos casos, el error de predicción es bajo, y el modelo logra replicar correctamente las inflexiones asociadas a cambios de régimen de tasas.

En contraste, como se puede observar en la Figura A.4, en activos con mayor volatilidad —tales como los bonos corporativos o los instrumentos soberanos de Australia—, el modelo tiende a suavizar las oscilaciones extremas. Este comportamiento es típico de redes neuronales con regularización, que buscan evitar el sobreajuste. Sin embargo, evidencia una limitación del modelo en contextos abruptamente cambiantes, lo que sugiere que su desempeño es sensible tanto al tipo de activo como al entorno macrofinanciero subyacente. Esto abre la posibilidad de mejora mediante el uso de arquitecturas más profundas o el enriquecimiento de las variables de entrada con indicadores específicos de riesgo.

Cabe mencionar que el modelo de redes neuronales ajustó sus hiperparámetros mediante un proceso de validación cruzada, utilizando como criterio de optimización el error absoluto medio (MAE), con el fin de lograr una generalización robusta y evitar el sobreajuste en los datos de entrenamiento.

Las figuras comparativas de rendimientos reales y predichos por activo se encuentran recopiladas en los anexos (Figuras A.5 a A.11), y constituyen un insumo clave para la evaluación visual del desempeño predictivo del modelo.

4.3. Proyecciones Pasadas del Modelo ANN

Como ejercicio adicional, se generaron las proyecciones pasadas de rendimientos interanuales estimadas por el modelo de redes neuronales para cada uno de los activos incluidos en el portafolio. Estas proyecciones permiten visualizar la capacidad del modelo para capturar trayectorias futuras bajo escenarios históricos, sirviendo tanto como prueba de consistencia como para validar su utilidad operativa en entornos reales de gestión.

Las series predichas reflejan adecuadamente las dinámicas observadas en activos con patrones estacionales o estabilidad estructural, como las inversiones a corto plazo, los bonos de agencias o los instrumentos

soberanos de Japón. En el caso de los bonos corporativos, Australia y Canadá, se observa una mayor dispersión, lo cual pone de manifiesto la sensibilidad del modelo ante eventos de mercado abruptos o cambios en la correlación entre factores macroeconómicos.

Las gráficas individuales con estas trayectorias estimadas se incluyen en los anexos de este documento, y complementan el análisis de ajuste realizado en la sección anterior.

4.4. Evaluación Agregada de Retornos Proyectados

El análisis gráfico de los retornos en exceso —definidos como la diferencia entre los rendimientos reales y los proyectados— permite una evaluación directa de la precisión y el sesgo de los modelos a lo largo del horizonte de simulación. La Figura A.12 muestra un gráfico de barras en el que se comparan mes a mes los retornos en exceso para el modelo de Nelson-Siegel y el modelo basado en redes neuronales artificiales (ANN). Se observa que el modelo estructural tiende a presentar menores desviaciones respecto a los valores reales, especialmente en los meses donde se registraron movimientos abruptos o reversión de tendencia.

Adicionalmente, se calculó el rendimiento en exceso acumulado absoluto (REA), como aproximación al área bajo la curva de desviaciones absolutas. Los resultados indican que el modelo Nelson-Siegel acumula una menor REA en comparación con el modelo ANN, con valores de 452.76 y 551.02 respectivamente. Esto respalda su superioridad en términos de precisión agregada. En otras palabras, el modelo estructural no solo genera predicciones más cercanas a los rendimientos observados, sino que también reduce el sesgo sistemático, logrando un mejor ajuste en contextos de alta volatilidad.

Estos resultados refuerzan la conclusión de que, para el período proyectado, el modelo de Nelson-Siegel no solo tuvo un mejor rendimiento acumulado, sino que también exhibió una mayor capacidad de replicar los patrones reales del portafolio bajo condiciones dinámicas y cambiantes del mercado.

Asimismo, se evaluaron métricas de riesgo mediante la estimación del Valor en Riesgo (VaR) y el Valor en Riesgo Condicional (CVaR) al nivel del 97.5 %. Los resultados muestran que el CVaR del modelo basado en redes neuronales fue ligeramente superior (0.027887) al del modelo de Nelson-Siegel (0.027295), lo cual implica que el modelo ANN anticipó una mayor pérdida promedio en escenarios extremos. Este resultado refuerza la robustez del modelo estructural desde una perspectiva prudencial, ya que logra limitar mejor la exposición a pérdidas severas bajo condiciones adversas de mercado.

Estos resultados refuerzan la conclusión de que, para el período proyectado, el modelo de Nelson-Siegel no solo tuvo un mejor rendimiento acumulado, sino que también exhibió una mayor capacidad de replicar los patrones reales del portafolio bajo condiciones dinámicas y cambiantes del mercado.

Capítulo 5

Conclusiones

La presente investigación tuvo como propósito central evaluar la aplicabilidad y el desempeño comparativo de modelos estructurales tradicionales y técnicas de inteligencia artificial en la asignación estratégica de activos, en el contexto de la gestión de reservas internacionales por parte de un banco central. Para ello, se implementaron dos enfoques metodológicos: por un lado, el modelo de Nelson-Siegel con rotación de factores y tasas sombra, estimado a través del módulo *BAAM* del Banco de Pagos Internacionales; por otro, una red neuronal artificial (ANN), entrenada en Python utilizando variables macroeconómicas y financieras relevantes.

Los resultados empíricos permiten derivar una serie de conclusiones relevantes desde las dimensiones técnica e institucional:

- Ambos modelos generaron asignaciones que respetan las restricciones estratégicas definidas, destacando una elevada proporción de activos de corto plazo como mecanismo de preservación de liquidez y control de riesgo operativo.
- El modelo basado en redes neuronales tendió a favorecer activos con alta liquidez y baja volatilidad, en línea con su objetivo de maximización del índice de Sharpe. Su ajuste fue particularmente adecuado para instrumentos con trayectorias estables, como los bonos de agencias y los títulos soberanos japoneses.
- El enfoque estructural de Nelson-Siegel evidenció una mayor capacidad predictiva, tanto en términos de precisión (menor error cuadrático medio) como de retorno acumulado. Este desempeño fue especialmente notable en escenarios de alta volatilidad, donde el modelo neuronal mostró dificultades para captar variaciones abruptas.
- El análisis del rendimiento en exceso acumulado absoluto (REA) confirmó la superioridad del modelo estructural en cuanto a estabilidad y ajuste agregado. En particular, el modelo de Nelson-Siegel alcanzó un REA de 452,76, frente a 551,02 registrado por el modelo ANN.
- Ambos enfoques se beneficiaron de la incorporación de proyecciones macroeconómicas como insumo de entrada, lo que resalta la relevancia de considerar expectativas sobre política monetaria, inflación y crecimiento económico en los procesos de optimización de carteras soberanas.

Desde una perspectiva aplicada, estos hallazgos sugieren que, si bien las redes neuronales ofrecen ventajas potenciales para la gestión dinámica de portafolios, su adopción institucional requiere mejoras sustantivas en interpretabilidad, calibración específica con datos internos y validación comparativa frente a enfoques estructurados.

En suma, este trabajo aporta evidencia útil para el desarrollo de enfoques híbridos que integren la capacidad adaptativa del aprendizaje automático con la solidez interpretativa de los modelos estructurales, abriendo una línea prometedora para futuras investigaciones en la gestión pública de activos financieros internacionales.

Apéndice A

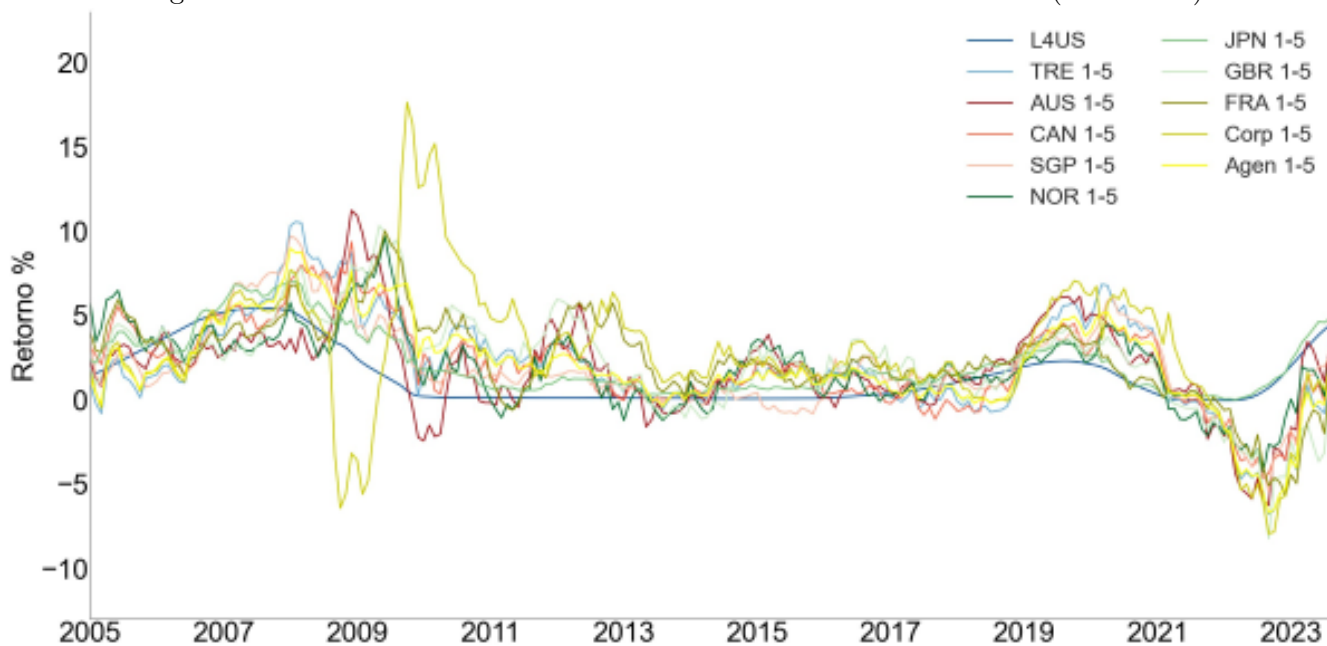
Anexos

Figura A.1: Estadísticas descriptivas de bonos con vencimientos 1–5 años (2005–2023)

	CP	TRE 1-5	AUS 1-5	CAN 1-5	SGP 1-5	NOR 1-5	JPN 1-5	GBR 1-5	FRA 1-5	Corp 1-5	Agen 1-5	
Estadísticas de retorno y riesgo de mercado 2005-2023	Retorno promedio %	1,4	2,1	1,9	2,1	2,0	1,9	2,2	2,3	2,5	2,9	2,1
	Retorno mínimo	-0,0	-6,8	-6,2	-4,6	-5,4	-4,2	0,0	-8,2	-5,7	-7,9	-6,7
	Retorno máximo	5,4	10,6	11,2	9,4	9,7	9,7	7,0	10,3	10,0	17,6	9,0
	Retorno acumulado	32,6	46,0	39,8	45,4	42,9	39,9	51,6	51,4	55,3	68,4	46,8
	Desviación Estándar %	1,7	3,0	2,7	2,6	2,6	2,3	1,8	2,9	2,5	3,9	2,7
	Razón de retorno/riesgo	0,9	0,7	0,7	0,8	0,8	0,8	1,2	0,8	1,0	0,7	0,8
	Razón de Sharpe	0,1	0,2	0,2	0,3	0,2	0,3	0,5	0,3	0,4	0,4	0,3
	Duración promedio set-23	0,04	2,5	2,6	2,2	2,6	2,6	2,7	2,4	2,7	2,5	2,0
Riesgo crediticio set-23	Rango calificación	AAA	AA+	AAA	AAA	AAA	AAA	A+	AA-	AA	A-/AAA	AA+
	Deuda/PIB		121,2	55,7	106,6	135,9	39,6	261,3	101,1	111,7		
Riesgo de liquidez set-23	Valor de mercado/Reservas		694	18	24	5	2	222	53	67	170	21
	Cantidad de emisiones		158	8	23	9	4	82	14	16	1880	397
	Bid-ask spread USD		0,029	0,050	0,022	0,084	0,142	0,031	0,086	0,048	0,102	0,039


Fuente: Elaborado con datos de ICE y Bloomberg.

Figura A.2: Retornos interanuales de bonos con vencimientos 1–5 años (2005–2023)



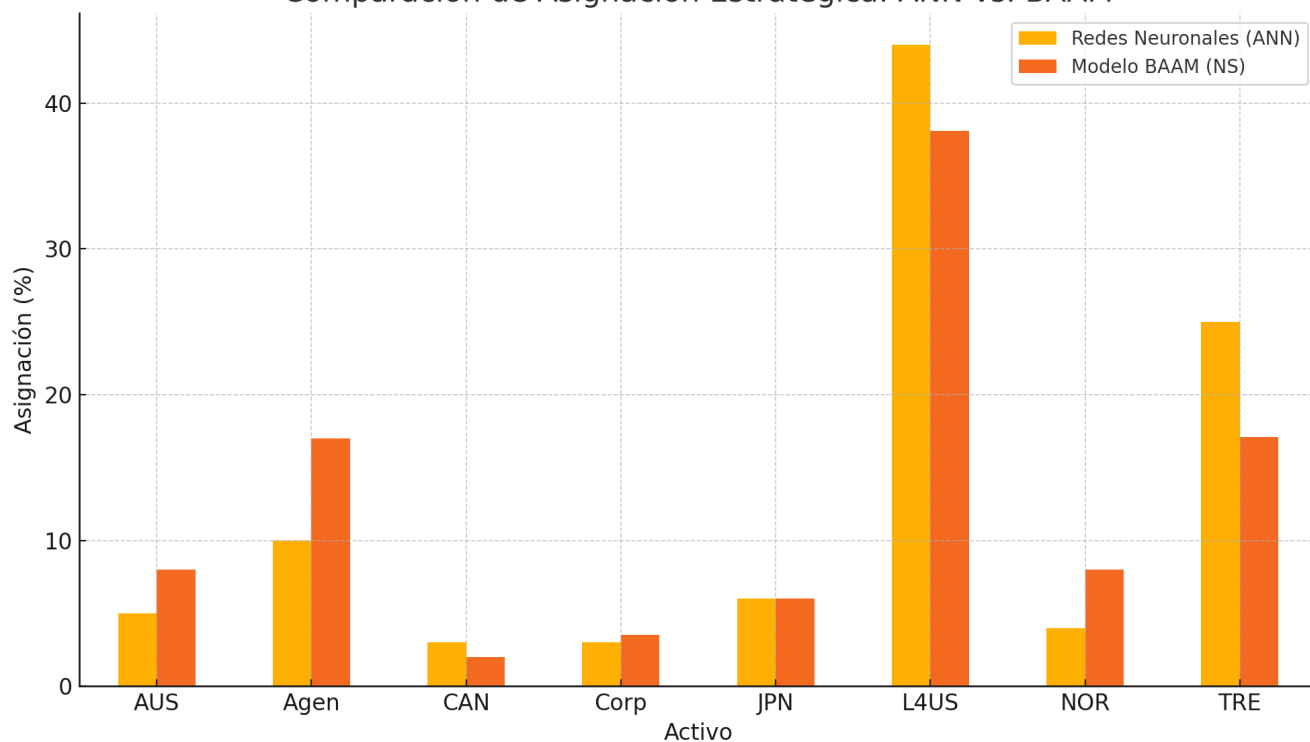
Fuente: Elaborado con datos de ICE y Bloomberg.

Figura A.3: Matriz de correlación de retornos interanuales (2005–2023)




Fuente: Elaborado con datos de ICE y Bloomberg.

Figura A.4: Comparación de asignación estratégica: ANN vs. BAAM
 Comparación de Asignación Estratégica: ANN vs. BAAM




Fuente: Elaboración propia con resultados del modelo ANN y Nelson-Siegel.

Figura A.5: Rendimiento Real vs Predicho – Bonos de Agencias (Agen)




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.6: Rendimiento Real vs Predicho – Bonos de Australia (AUS)




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.7: Rendimiento Real vs Predicho – Bonos de Canadá (CAN)




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.8: Rendimiento Real vs Predicho – Bonos Corporativos (Corp)




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.9: Rendimiento Real vs Predicho – Bonos de Japón (JPN)




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.10: Rendimiento Real vs Predicho – Bonos de Corto Plazo




Fuente: Elaboración propia con resultados del modelo ANN

Figura A.11: Rendimiento Real vs Predicho – Bonos del Tesoro de EE.UU. (TRE)



Fuente: Elaboración propia con resultados del modelo ANN

Figura A.12: Retorno en exceso por modelo
 Comparación de Retornos en Exceso (Real - Proyectado)



Fuente: Elaboración propia

Bibliografía

- [1] Bradrania, R. and Peiris, S. (2022). Asset allocation using machine learning. *The European Journal of Finance*.
- [2] Diebold, F. X. and Li, C. (2006). Forecasting the term structure of government bond yields. *Journal of Econometrics*, 130(2):337–364.
- [3] for International Settlements, B. (2013). *Guidelines for Foreign Exchange Reserve Management*. BIS, Basel.
- [4] Fund, I. M. (2022). Annual report on exchange arrangements and exchange restrictions. Technical report, IMF.
- [5] Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- [6] Huang, Y. and He, X. (2024). Dynamic asset allocation using recurrent neural networks. *Journal of Forecasting*.
- [7] Jorion, P. (2006). *Value at Risk: The New Benchmark for Managing Financial Risk*. McGraw-Hill, 3rd edition.
- [8] Krippner, L. (2013). Measuring the stance of monetary policy in zero lower bound environments. *Economics Letters*, 118(1):135–138.
- [9] Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1):77–91.
- [10] Nelson, C. R. and Siegel, A. F. (1987). Parsimonious modeling of yield curves. *The Journal of Business*, 60(4):473–489.
- [11] Ochoa Luzuriaga, J. J. (2024). Optimización de portafolios de inversión en la bolsa de valores de quito, ecuador utilizando redes neuronales artificiales.
- [12] Opschoor, A. and Strasser, G. (2022). Shadow rates in a tractable yield curve model. *Journal of Business & Economic Statistics*.
- [13] Wu, J. C. and Xia, F. D. (2016). Measuring the macroeconomic impact of monetary policy at the zero lower bound. *Journal of Money, Credit and Banking*, 48(2-3):253–291.