




Pronóstico de la Curva de Rendimientos de Bonos del Tesoro Chileno con Machine Learning

Raúl Morales
Marcelo Villena

Diciembre 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: _____ Pronóstico de la Curva de Rendimientos de Bonos del Tesoro Chileno con Machine Learning

Nombre del candidato(a): _____ Raúl Patricio Morales Ponce

Carrera / Grado: _____ Ingeniería Comercial _____

Campus: _____ Vitacura _____ Departamento: _____ Ingeniería Comercial

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, _____ Marcelo Julián Villena Chamorro _____, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: _____ 23/01/2026

Firma: _____

Estudiante o Candidato(a):

Fecha: _____ 23/01/2026

Firma: _____

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Resumen

Un pronóstico fiel de la estructura de tasas es fundamental para instituciones financieras que manejen activos de deuda y con ello estrategias de inversión. Este estudio evalúa la eficacia de modelos de Machine Learning frente a la econometría tradicional para predecir la curva de rendimiento de los Bonos del Tesoro en Chile (BTU). Se contrasta la precisión del modelo clásico Nelson-Siegel contra algoritmos de Random Forest y una arquitectura híbrida de aprendizaje profundo (LASSO-SMLR-PCA-LSTM), incorporando variables macroeconómicas clave como el precio del cobre y las tasas del Tesoro de EE. UU. La metodología basada en ventanas móviles reveló la superioridad de la Inteligencia Artificial sobre los métodos paramétricos, con una mejor adaptación a entornos volátiles.

1 Introducción

Los Bonos del Tesoro en Chile corresponden a instrumentos financieros que representan títulos de deuda emitidos por el Estado chileno a través del Ministerio de Hacienda. El propósito fundamental de estas emisiones es otorgar un financiamiento para cubrir necesidades fiscales operativas y estructurales. Estos recursos irán dirigidos principalmente a financiar una parte significativa del presupuesto fiscal anual, logrando que el Estado sostenga sus operaciones y servicios públicos. Además, lo recaudado se usará para la reestructuración y el pago de deuda pública preexistente, otorgando la posibilidad de gestionar obligaciones de pago activamente. Por otro lado, se encontrará el respaldo para llevar a cabo proyectos de inversión pública, así como programas gubernamentales que permitan un desarrollo económico y social.

Este tipo de instrumento financiero cuenta con el respaldo y garantía del Estado chileno, asumiendo la responsabilidad completa del pago, tanto del capital como de los intereses pactados. Esta garantía soberana otorga a este tipo de bonos una característica fundamental, son clasificados y reconocidos en el mercado financiero como activos de bajo riesgo crediticio. Esta característica establece una diferencia importante con otros activos del mercado, los cuales comúnmente muestran una volatilidad en sus precios y rendimientos, a la vez que una mayor incertidumbre en cuanto a asegurar sus pagos futuros.

Los instrumentos de deuda más representativos que pone a disposición la Tesorería General de la República corresponden a dos categorías principales de bonos cada uno con diferentes especificaciones y estructura. En primer lugar, se encuentran los Bonos de la Tesorería denominados en Pesos chilenos (BTP), los cuales se caracterizan por incorporar una tasa de interés nominal fija a lo largo de toda la vida del instrumento. Por otro lado, se emiten los Bonos de la Tesorería

expresados en Unidades de Fomento (BTU), instrumentos cuya característica relevante es que su valor y rendimiento se encuentra indexado y ajustados de manera automática según las variaciones del índice de precios al consumidor. Esta particularidad de indexación a la inflación convierte a estos instrumentos en una forma efectiva de que los inversionistas se protejan, ya que mantiene el poder de compra real de su inversión, neutralizando el efecto negativo que podría tener un aumento sostenido en los niveles generales de precios de la economía nacional.

Los bonos del Tesoro pueden comprarse en fracciones ya definidas por el emisor por un valor nominal mínimo, es decir, a pesar de que los bonos poseen un valor total, en realidad es complicado que un solo inversionista pueda adquirir estos instrumentos por sí solo, es por esto que se realiza una división del bono y cada participante de la subasta oferta sobre sus capacidades e intereses propios, esto otorga cierta flexibilidad al mercado y permite que diversas entidades participen. Luego de su emisión inicial los bonos se negocian en el mercado secundario donde se transan todos los días a través de la Bolsa de Comercio de Santiago o en operaciones directas entre inversionistas denominadas over the counter (OTC) donde es posible negociar activos fuera del mercado público sin que las transacciones sean visibles.

El mercado de capitales chileno representa uno de los más desarrollados de América Latina y se caracteriza por su tamaño y diversidad de inversionistas. En el primer trimestre de 2025 el stock de títulos de deuda de emisores locales alcanzó alrededor de 116 % del PIB, en este mercado los Bonos del Tesoro funcionan como referencia de tasas de interés y como instrumento de menor riesgo que la deuda privada (Banco Central de Chile, s. f.).


El mercado de bonos chileno presenta un tamaño considerable, siendo los instrumentos de deuda soberana su principal componente. Según los últimos datos el stock de instrumentos de deuda de la Tesorería General de la República en circulación alcanza aproximadamente los 51,182 mil millones de dólares en los denominados BTP, mientras que el stock de los llamados BTU supera actualmente los 1.032 millones de UF, es decir, corresponden a aproximadamente 41,280 mil millones de dólares (Banco Central de Chile, s. f.).

Estas cifras evidencian la solidez y profundidad del mercado de renta fija local. Esto muestra por qué actúan como referente en el tema de precios para el resto de las emisiones corporativas de la economía. El elevado volumen de deuda soberana que existe en circulación indica la capacidad de endeudamiento que posee el Estado chileno, además, se trata de un pilar esencial para que se desarrolle el ecosistema de renta fija nacional.

La curva de rendimiento (yield curve) de los Bonos de la Tesorería representa gráficamente la relación que tienen los diferentes plazos de vencimiento de los instrumentos de deuda que emite el

Estado con sus respectivas tasas de interés. Una de las formas típicas de esta curva es ascendente o normal, en donde los bonos de largo plazo ofrecen un rendimiento mayor que los de corto plazo, reflejando una exigencia de compensación del riesgo a cambio de mantener el dinero invertido por periodos largos de tiempo.

Figura 1: Curva de Rendimientos BTU.



Fuente: Elaboración propia con datos de Investing.com.

El eje horizontal (X) representa los plazos de vencimiento de los bonos desde 1 año hasta 30 años.

El eje vertical (Y) muestra las tasas de rendimientos o *yield*, expresadas en porcentajes anuales.

Un *commodity* clave a la hora de estudiar el mercado chileno es el cobre. La minería y la exportación de este material juegan un papel vital en la economía chilena, afectando la actividad industrial y el volumen total de exportaciones, este tiene un efecto significativo sobre las tasas de los bonos del gobierno chileno, ya que su precio influye directamente en la posición fiscal, la cuenta externa y el dinamismo macroeconómico del país, dado que constituye su principal fuente de ingresos asociados. En este marco, se ha demostrado que aumentos en el precio del cobre fortalecen las expectativas de crecimiento, mejoran la capacidad fiscal y generan presiones macroeconómicas que tienden a elevar los rendimientos soberanos, de forma que para el bono de 10 años una variación positiva en el precio del cobre se traduce en un aumento directo en el rendimiento del bono (Akram & Uddin, 2025).

Para modelar y predecir el comportamiento de estas variables financieras, tradicionalmente se han utilizado modelos econométricos clásicos, los cuales establecen relaciones estadísticas basadas en teorías económicas predefinidas. Sin embargo, el objetivo de este estudio es evaluar si la implementación de modelos de Machine Learning logra superar el desempeño de estas

metodologías tradicionales, verificando si estas nuevas herramientas tecnológicas pueden ofrecer una mayor precisión y capacidad predictiva en este contexto.

2 Revisión de Literatura

2.1 Modelos Econométricos

Dentro de la econometría una herramienta fundamental es la regresión lineal múltiple, aplicando este modelo a la econometría financiera es posible pronosticar las variaciones que tendrá una variable, en este caso se busca predecir el rendimiento de bonos a través de modelar qué variables influyen en su comportamiento. Al modelar el rendimiento de los bonos en función de las diferentes variables independientes se consigue explicar simultáneamente el efecto que tienen sobre la variable dependiente, así en lugar de analizar cada relación por separado es posible tomar en cuenta todos los factores los cuales en teoría deben influir de distinta manera sobre los bonos.

El modelo tipo tiene a los distintos factores como variables independientes x_i (tasas de interés, inflación esperada, volatilidad, etc.), los cuales según la teoría económica influirán en y , la variable dependiente, sumado a esto un término de error ε el cual representa influencias no observadas. Los coeficientes β_i son estimados con Mínimos Cuadrados Ordinarios (MCO), el cual minimiza la suma de errores al cuadrado (Fabozzi, Focardi & Rachev, 2014, Cap. 3). Su interpretación es el cambio promedio en y ante un cambio unitario en x_i manteniendo las demás constantes:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + \varepsilon.$$

Uno de los modelos clásicos en este contexto es el Nelson-Siegel, este se utiliza como partida para representar la curva de rendimientos de bonos. Hace uso de tres factores, nivel, pendiente y curvatura. Estos factores resumen la estructura de tasas de interés y agrupan la información del mercado en variables interpretables. Según el estudio de Guidolin e Ionta (2025), donde se extraen factores a partir de datos históricos (1990–2020), los consideran como predictores de los retornos de activos financieros, sosteniéndose en la hipótesis de que reflejan expectativas macroeconómicas y condiciones de liquidez.

Luego los factores se pronostican utilizando modelos econométricos de series de tiempo, en particular procesos autorregresivos AR o vector autorregresivos VAR.

El AR(1) aplicado al modelo Nelson-Siegel describe la evolución temporal de los factores,

suponiendo que cada uno de ellos es altamente persistente, de manera que el valor actual de cada factor depende en gran medida de su propio valor anterior, ajustándose lentamente hacia su tendencia de largo plazo y respondiendo a nuevos *shocks*. Esta estructura capta de manera realista el movimiento de las tasas, de forma gradual y con ciclos prolongados. Al combinar esta dinámica con la representación transversal de Nelson-Siegel, se logra un modelo que ajusta bien la curva en cada momento, además de mantener un comportamiento temporal de manera coherente. Siendo X_t la variable en el tiempo t , ϕ mide cuánto influye el valor pasado, α es una constante y ε_t es un error aleatorio (Papazoglou, 2021):

$$X_t = \alpha + \phi X_{t-1} + \varepsilon_t.$$

2.2 Machine Learning

El Machine Learning (ML) es una rama de la inteligencia artificial orientada a que los computadores aprendan patrones a partir de datos recopilados y en base a estos realicen predicciones sin que necesariamente estén programados para esta tarea específica. La diferencia principal que poseen estos algoritmos es su capacidad para adaptarse a relaciones que no sean lineales o que son altamente dinámicas, esto último la convierte en una herramienta clave a la hora de estudiar variables en donde estas pueden cambiar constantemente, como puede ser la energía o los mercados financieros. Aplicado a nuestro contexto de los bonos del Tesoro, la flexibilidad que entrega es útil para reconocer interacciones difíciles de observar, como pueden ser interacciones directas entre tasas de interés, inflación y factores internacionales, entregando una predicción más acertada que los modelos únicamente econométricos (Entezari, Aslani, Zahedi & Noorollahi, 2023).

En otras industrias como la energética, la predicción ha sido uno de los principales usos del machine learning. Los investigadores han utilizado redes neuronales artificiales, máquinas de soporte vectorial y árboles de decisión para el pronóstico de la generación de energía solar y la demanda eléctrica para distintos horizontes temporales. Este tipo de modelos permite anticiparse a cambios en la oferta y demanda, de manera que se logre optimizar el uso de las plantas. Según Entezari et al. (2023), los métodos de machine learning superan a los modelos estáticos ya que tienen la capacidad de aprender de una gran cantidad de volúmenes de datos históricos, y así generar estimaciones precisas en contextos volátiles.

Trasladando a los bonos del Tesoro, de la misma manera en que en la industria energética se estiman variaciones en la producción de fuentes a partir de datos climáticos, en bonos sería capaz de pronosticar comportamientos de las tasas y precios a partir de series temporales de tasas de interés, inflación, TPM, expectativas de riesgo u otros mercados, etc. De esta forma el machine learning es útil para prever movimientos futuros de corto y mediano plazo. Para los inversionistas

esto es relevante a la hora de gestionar portafolios, definiendo una duración y convexidad óptima.

El ML comúnmente se junta con *big data* para procesar grandes volúmenes de información, el objetivo es transformar esta gran cantidad de información en conocimiento realmente útil para tomar decisiones. Entezari et al. (2023) señalan que el ML aplicado al *big data*, además de mejorar la precisión de las predicciones, permite descubrir patrones ocultos en entornos complejos.

El mercado de bonos del Tesoro genera grandes volúmenes de datos financieros y macroeconómicos, por ejemplo, precios históricos, curvas de rendimiento, volúmenes de transacción, noticias económicas o comunicados de bancos centrales. La principal idea de usar *big data* en conjunto con machine learning es extraer la señal predictiva en base a toda la información. Un ejemplo financiero puede ser cómo un algoritmo sea capaz de capturar la influencia de anuncios de cambios a la tasa de política monetaria y su relación con alguna variación en la *yield* de 10 años, lo que sería más complicado para modelos lineales clásicos. De esta forma aplicar el *big data* a la predicción de bonos del tesoro nos entrega un pronóstico más fino, ideal para gestionar riesgos.

Actualmente existen modelos de optimización que funcionan de manera híbrida, es decir, toman en cuenta técnicas econométricas y de machine learning para enfrentar los desafíos de los modelos tradicionales. Este modelo para la predicción de rendimientos del tesoro denominado LASSO-SMLR-PCA-LSTM incorpora métodos de selección de variables y *Deep learning*, permitiendo mejorar la robustez y presentando mejoras sobre modelos que se basan en la linealidad y baja volatilidad como pueden ser ARIMA, GARCH, Nelson-Siegel (Ping, Hu & Luo, 2024).

Específicamente, el modelo Long Short-Term Memory (LSTM) es un tipo especial de red neuronal recurrente que está diseñada para trabajar con series temporales. La principal ventaja de este modelo es que puede recordar información de largo plazo, al mismo tiempo que puede olvidar datos irrelevantes utilizando su estructura de compuertas. Según Ping, Hu y Luo (2024), las compuertas del modelo LSTM funcionan como filtros que regulan qué información se guarda, se olvida y se usa en cada paso de predicción.

Random Forest (Bosque Aleatorio) es un algoritmo de aprendizaje automático que se utiliza tanto para tareas de clasificación como de regresión, según Ilinca (2024) la principal característica del Random Forest es que se trata de un modelo no paramétrico. A diferencia de modelos como OLS, este algoritmo no asume que la relación entre las variables predictoras y la variable objetivo sea lineal. Es por esto que su enfoque es capturar y modelar relaciones complejas y no lineales.

El estudio *Predicting bond returns using machine learning techniques* de Ilinca (2024) destaca que la relación entre los retornos de los bonos y los indicadores macroeconómicos no es perfectamente lineal, por lo que se necesitaba un método como Random Forest que pudiera modelar

eficazmente dichas interacciones. Esta capacidad para manejar la no linealidad es lo que, según los resultados, le permitió superar a los modelos lineales en el estudio.

3 Metodología

3.1 Datasets

El conjunto de datos a utilizar corresponderá a información sobre la *yield* histórica de cada uno de los seis plazos más comunes en Bonos del Tesoro en UF, en particular los plazos de 1, 2, 5, 10, 20 y 30 años. El dato identificado se trata del valor de cierre de mes presentado en la base de datos del Banco Central de Chile. Se tomaron en cuenta los meses desde enero de 2014 hasta agosto de 2025 para las tasas, resultando en un total de 140 observaciones con el objetivo de considerar distintos periodos de contextos económicos, de igual manera este rango de observaciones coincide con las demás variables macroeconómicas incluidas en el modelo.

En las series de rendimientos correspondientes a los bonos del Tesoro en UF se detectaron valores faltantes principalmente en las maduresces de 1, 2 y 5 años, lo que podría llegar a distorsionar el análisis y la aplicación de los modelos. Para superar esto se llevó a cabo un proceso de interpolación lineal que estimó los valores faltantes de forma coherente con la tendencia temporal y la estructura previa de la curva de rendimientos. Con ello las series quedaron completas y listas para ser utilizadas en los ajustes de los modelos.

Para complementar el análisis se utilizaron variables macroeconómicas representativas del contexto económico nacional, todas con frecuencia mensual desde enero de 2014 a agosto de 2025. Se utilizó el Índice de Actividad Mensual de Comercio como indicador del nivel de gasto y dinamismo del consumo interno, reflejando la evolución de la demanda agregada. En segundo lugar, se consideró el número de cotizantes en la AFP, que permite aproximar los cambios en el mercado laboral y la masa salarial formal. Se incluyó la Balanza Comercial de Chile, con el fin de capturar los efectos de las variaciones en exportaciones e importaciones. También se incorporó el índice bursátil S&P 500 VIX que refleja la volatilidad esperada en el índice, así como expectativas de riesgo o posibles caídas de mercado.

Se incorporó la tasa de política monetaria (TPM), la que afecta directamente a las tasas de corto plazo y expectativas de inflación. Por la estrecha relación que existe con el mercado estadounidense se añadió el Treasury 10Y de EE. UU., que actúa como referente de renta fija mundial. Se consideró la inflación mensual, indicador para medir el aumento en niveles de precios ya que incide en las

tasas reales exigidas por inversionistas. Por último, se incluyó el precio del cobre, principal producto de exportación cuyo comportamiento afecta significativamente los ingresos fiscales.

3.2 Rolling Windows

Según Bloznelis (2018), el uso de ventanas móviles (*Rolling Windows*) representa el núcleo de la metodología aplicada al pronóstico del precio *spot* del salmón. Con este enfoque lo que se busca es replicar de manera realista el proceso de predicción que enfrentaría un analista en tiempo real, actualizando constantemente la información disponible a medida que se va obteniendo. Con este procedimiento se garantiza que los modelos se ajusten exclusivamente a la información histórica, evitando la filtración de datos futuros al modelo, lo que afectaría negativamente ya que el modelo estaría observando lo que sucederá más adelante, siendo capaz de aprender de datos que en la práctica no estarían disponibles, con esto se logra evaluar efectivamente la capacidad predictiva de cada técnica empleada.

Según el estudio de Yang (2020), la elección del tamaño de la ventana en los modelos de regresión móvil es fundamental para mejorar la capacidad predictiva de la curva de rendimiento. El autor enfatiza en que no existe un único tamaño óptimo universal, dado que la efectividad varía con el horizonte de pronóstico. Para horizontes cortos pueden ser útiles ventanas algo más reducidas que prioricen la información más reciente y sean capaces de adaptarse a cambios en el entorno, mientras que para horizontes largos conviene mantener un historial más extenso de manera que entreguen estimaciones más estables y precisas captando patrones de largo plazo.

En el contexto de los bonos de la Tesorería aplicar la metodología de las *Rolling Windows* permite evaluar rigurosamente su capacidad predictiva sobre las *yields* de los bonos del tesoro chileno a diferentes horizontes temporales. En esta implementación se definió una historia total de once años de datos mensuales. Se utilizaron 92 ventanas móviles de 48 meses cada una, donde cada bloque de tiempo se utiliza como muestra de entrenamiento (*in sample*), de manera que el mes siguiente representa la muestra de prueba (*out of sample*), siendo la parte en donde se evalúa la precisión. Una vez terminado, la ventana se desplaza un mes hacia adelante, eliminando la primera observación y agregando la siguiente disponible, luego el proceso vuelve a repetirse. Al finalizar todas las repeticiones, se obtiene una colección de errores de pronóstico del modelo específico.

3.3 Test ADF

Se realizó un análisis de estacionariedad sobre las series utilizadas con el objetivo de verificar si presentaban raíces unitarias o tendencias que pudieran afectar la validez de los modelos en el tiempo. Para esto se aplicó el test de Dickey–Fuller Aumentado (ADF), contrastando la hipótesis nula de no estacionariedad. Así como también se aplica un test de autocorrelación con el objetivo de determinar si el modelo autorregresivo es aplicable en el modelo, ya que una alta correlación indicaría que un modelo basado en valores anteriores sería en principio ideal (Diebold & Li, 2006).

3.4 Nelson-Siegel

El modelo ARIMA (*Autoregressive Integrated Moving Average*) se utiliza como referente económico para pronosticar la curva de rendimientos, permitiendo capturar la estructura lineal y la dependencia temporal propia de la serie. Este modelo combina tres componentes: un término autorregresivo que refleja la influencia de los valores pasados sobre el presente, un término de integración que elimina las tendencias mediante diferenciación y un componente de media móvil que modela los efectos de los errores pasados sobre el valor actual. Su incorporación busca establecer una base comparativa tradicional frente a enfoques más flexibles de machine learning y observar cuáles son sus principales diferencias (González Casimiro, s. f.).

El modelo AR (autorregresivo) es un caso particular de ARIMA. El modelo $ARIMA(p, d, q)$ combina tres componentes: una parte autorregresiva (AR) que explica el valor actual de la serie en función de sus valores pasados, una parte de diferenciación (I) y una parte de media móvil (MA) que incorpora efectos de los errores pasados. Cuando no se requiere diferenciación ($d = 0$) ni términos de media móvil ($q = 0$), el modelo se reduce a un $AR(p)$, donde el valor presente depende únicamente de p valores anteriores (González Casimiro, s. f.).

Por otro lado, al aplicar el modelo Nelson-Siegel con dinámica $AR(1)$ se combina la estructura de la curva de rendimientos propuesta por Nelson y Siegel (1987) con una modelación temporal autorregresiva de primer orden. En la primera etapa, el modelo Nelson-Siegel representa la estructura temporal de las tasas de interés mediante tres factores: nivel (β_0), pendiente (β_1) y curvatura (β_2), los cuales determinan la forma de la curva a través de su ecuación (Papazoglou, 2021):

$$y_t(m) = \beta_{0,t} + \beta_{1,t} \left(\frac{1 - e^{-m/\tau}}{m/\tau} \right) + \beta_{2,t} \left(\frac{1 - e^{-m/\tau}}{m/\tau} - e^{-m/\tau} \right).$$

Siendo m la madurez y τ un parámetro de decaimiento que controla la posición del máximo de

la curvatura, de esta manera el modelo es capaz de captar tanto el nivel general de las tasas como su inclinación y convexidad a lo largo de la curva.

Una vez se han estimado los factores $\beta_{0,t}$, $\beta_{1,t}$ y $\beta_{2,t}$ para cada periodo se modela su evolución temporal utilizando un proceso autorregresivo AR(1), asumiendo que cada factor sigue una dinámica de la siguiente forma:

$$\beta_{i,t} = c_i + \phi_i \beta_{i,t-1} + \varepsilon_{i,t},$$

en donde c_i es una constante, ϕ_i es el coeficiente autorregresivo y $\varepsilon_{i,t}$ un término de error blanco. Significa que el valor futuro de cada factor depende linealmente de su valor pasado (Papazoglou, 2021).

Estudios anteriores muestran un poder predictivo significativo en retornos de bonos del Tesoro en horizontes cortos, especialmente a un mes, contando con mayor efectividad en bonos de corto plazo con vencimientos de 3 y 6 meses. Al extender el horizonte a 12 meses la ventaja de los modelos basados en factores se reduce notablemente, llegando en muchos casos a no superar *benchmarks* simples como el promedio histórico o el *random walk*, confirmando que la utilidad está en la predicción de corto plazo (Guidolin & Ionta, 2025).

3.5 Random Forest

Se define como un método de ensamble, lo que significa que combina múltiples métodos, el caso a evaluar será el de múltiples árboles de decisión para intentar aumentar la precisión general del modelo. Funciona construyendo gran cantidad de árboles de decisión individuales durante la fase de entrenamiento, cada árbol se entrena utilizando diferentes subconjuntos aleatorios del set de datos original. Al momento de predecir, el modelo combina los resultados de todos los árboles individuales, de manera que promedia sus predicciones para obtener un resultado final único, siendo generalmente más preciso que el de un solo árbol (Goehry et al., 2023).

Cada árbol comienza en un nodo raíz, continúa con varios nodos internos que separan los datos en subconjuntos más homogéneos y finaliza en nodos hoja, que entregan las predicciones. A diferencia de otros modelos, Random Forest selecciona los puntos de corte de forma óptima en cada nodo, reduciendo la varianza sin introducir un exceso de aleatoriedad, lo que permite lograr alta precisión y menor sobreajuste (Luque Raya & Luque Raya, 2024).

Antes del entrenamiento del modelo, se aplica un análisis de componentes principales (PCA) a la estructura de la curva de rendimientos con el fin de reducir la dimensionalidad y capturar los factores que explican la mayor parte de la variabilidad de las tasas. Los primeros componentes,

nivel, pendiente y curvatura representan el nivel general de tasas. Estos componentes, junto a las variables macroeconómicas incluidas, conforman las *features* de entrada del modelo (Ilinca, 2024).

Adicionalmente, se estimó un modelo Random Forest utilizando exclusivamente la estructura de la curva de rendimientos como conjunto de entrada, sin utilizar las variables macroeconómicas. Este enfoque permite evaluar la capacidad predictiva perteneciente a la información contenida en las propias tasas, explotando patrones entre sus distintos tramos. Con esto el modelo solo posee la información del análisis de componentes principales (PCA).

El modelo utiliza 100 árboles de decisión, una cantidad que equilibra adecuadamente la precisión predictiva y el costo computacional. Según Breiman (2001), el error de generalización del Random Forest tiende a estabilizarse al aumentar el número de árboles, ya que cada árbol contribuye con una estimación independiente y el promedio de todas ellas suaviza los errores individuales. Sin embargo, más árboles también implican un mayor tiempo de entrenamiento y procesamiento, especialmente si consideramos un *Rolling Windows* mensual.

Cuadro 1: Arquitectura Random Forest

Arquitectura Random Forest	
Entradas	Curva BTU Historica Actividad Comercio Cotizantes AFP Balanza Comercial SP 500 VIX Precio Cobre Bono 10 años EEUU Inflación TPM
Salidas	y1, y2, y5, y10, y20, y30
Horizonte Pronostico	1, 3, 6 meses
Ventana Entrenamiento	48 meses

3.6 LASSO-SMLR-PCA-LSTM

A) LASSO

LASSO (*Least Absolute Shrinkage and Selection Operator*) corresponde a una técnica de regresión, esta agrega una penalización L1 a los coeficientes de un modelo lineal. Esta penalización

hace que los coeficientes sean más pequeños, solo en el caso de las variables que no son relevantes llegando incluso hasta cero, de forma que determinadas variables serán incluso excluidas automáticamente del modelo (Ping, Hu & Luo, 2024). En términos generales:

$$\hat{\beta}^{lasso} = \arg \min_{\beta} \left(\|Y - X\beta\|^2 + \lambda \sum_{j=1}^d |\beta_j| \right),$$

donde Y es la variable dependiente, X la matriz de variables independientes, β los coeficientes y λ el coeficiente de penalización.

El incluir variables innecesarias puede resultar negativo a raíz de los problemas de multicolinealidad y redundancia, sobrecargando el modelo de información innecesaria y produciendo sobreajuste. Para resolver este problema los autores realizan un proceso de depuración. Para esto se aplica *LASSO regression*, que “reduce la dimensionalidad de las variables eliminando aquellas con coeficientes cercanos a cero y resolviendo problemas de multicolinealidad” (Ping et al., 2024, p. 194523). Gracias a esto se logra elegir solo las variables que aportan valor explicativo.

B) Stepwise Regression (SMLR)

El siguiente paso es aplicar Stepwise Regression (SMLR), un método que selecciona iterando las variables más significativas, descartando aquellas que no poseen correlación relevante con la *yield*. En cada iteración calcula el modelo y se evalúa cada variable para entrar o salir del modelo, con un criterio objetivo, por ejemplo, *p-values* de *t*, mejora de R^2 ajustado, reducción del error de validación. El proceso se detiene cuando ninguna adición o eliminación mejora el criterio fijado. El resultado de este paso en el artículo de Ping, Hu y Luo (2024) fue un conjunto de variables estadísticamente relevantes. De forma que esta regresión funciona como un filtro intermedio garantizando la existencia de variables con poder explicativo.

C) PCA

En la tercera etapa, se aplicó el análisis de componentes principales (PCA), técnica estadística que transforma un conjunto de variables correlacionadas en un nuevo conjunto más pequeño denominado componentes principales. Acá cada componente es una combinación lineal de las variables originales, resultando en que el primer componente captura la mayor parte de la varianza de los datos, el segundo captura la mayor parte de la varianza restante, de la misma forma sucesivamente. Con esto se logra reducir la dimensionalidad, eliminando redundancia, perdiendo la menor cantidad

de información posible. En el contexto financiero es útil ya que suele existir alta colinealidad entre variables macroeconómicas, lo que complica el entrenamiento de modelos de machine learning. En el artículo, el resultado fue la extracción de seis componentes principales, que explicaban más del 85 % de la varianza acumulada de los datos. Estos componentes fueron los que se usaron como *inputs* en el modelo LSTM (Ping, Hu & Luo, 2024).

D) LSTM

El modelo LSTM (Long Short-Term Memory), según Ping, Hu y Luo (2024), representa una evolución del modelo recurrente tradicional (RNN) diseñada para resolver los problemas de gradiente explosivo y desaparición de gradiente, comunes en series de tiempo financieras caracterizadas por alta volatilidad. Su arquitectura incorpora un componente central denominado *Cell State* o Estado de Celda, que actúa como una memoria de largo plazo capaz de transportar información relevante a lo largo del tiempo sin degradarse. Esta capacidad le permite mantener dependencias temporales extensas, aspecto fundamental cuando se quiere predecir rendimientos influidos por patrones de largo plazo.

En general el LSTM se compone de cuatro factores esenciales: la celda de memoria (*Cell*) y tres compuertas principales (entrada, olvido y salida), que regulan el flujo de información dentro del modelo. La celda se actualiza a través de operaciones que combinan las entradas actuales, las salidas previas y el estado anterior, a la vez que las compuertas regulan qué información es retenida, descartada o transmitida. Este proceso se realiza mediante funciones de activación no lineales, otorgando al modelo la capacidad de no depender de supuestos de estacionariedad o linealidad (Ping, Hu & Luo, 2024).

La ecuación general para la celda de memoria puede representarse como:

$$a_t^c = \sum_{i=1}^I \omega_i^c x_{i,t-1} + \sum_{h=1}^H \omega_h^c b_{h,t-1} + \sum_{c=1}^C \omega_c^c s_{c,t-1}, \quad b_t^c = f(a_t^c),$$

donde cada sumatoria representa cómo la red LSTM integra información nueva y pasada para actualizar su estado interno. La sumatoria sobre x_i corresponde a la influencia de las variables externas, por ejemplo, variables macroeconómicas, la siguiente sobre b_h incorpora la salida previa, añadiendo la información procesada en el paso anterior, y la última sobre s_c actualiza la memoria sobre el estado anterior, determinando cuánta de la memoria de largo plazo se conserva en el nuevo estado. De tal manera que se traslada la información y las relaciones que el modelo aprende hacia la memoria almacenada total mediante las sumatorias. Mientras que la función de activación

transforma el resultado de la suma ponderada en una escala útil y estable para la red, evitando saturaciones numéricas al momento de aprender relaciones no lineales.

La arquitectura del modelo se configuró con 100 unidades de memoria, esto determina su capacidad para recordar patrones complejos, y una tasa de aprendizaje de 0,005, que regula la magnitud de las correcciones matemáticas que el modelo aplica a sus propios parámetros cada vez que detecta un error. El sistema funciona mirando los últimos 21 días (*lookback*) para entender la tendencia reciente, mientras se apoya en el conocimiento de 1460 días de ventana de entrenamiento, equivalente a 48 meses. A partir de esto el modelo proyecta a distintos horizontes, para luego calcular el error de sus pronósticos.

En el entrenamiento igualmente se utiliza una estrategia dinámica, específicamente se avanza en la serie con desplazamientos de 20 días (*step size*), procesando la información en bloques de 256 datos (*batch size*) para aprovechar la potencia de la GPU. El aprendizaje consta de dos fases, una inicial intensiva de 15 rondas (*epochs*) para ajustar los parámetros generales, seguida de actualizaciones rápidas de una sola ronda cada vez que avanza la ventana, permitiendo incorporar datos más recientes sin olvidar la estructura aprendida.

Dada la alta densidad computacional requerida por la arquitectura LSTM y el esquema de validación de ventana móvil, la cual implica reentrenamientos secuenciales, la ejecución se realizó en una GPU NVIDIA A100. Este *hardware* está optimizado para funcionar en servidores de alto rendimiento. En términos de capacidad de procesamiento para inteligencia artificial, su rendimiento equivale a tener un *cluster* de varias tarjetas gráficas de alta gama trabajando en simultáneo, esto permitió reducir drásticamente los tiempos de cálculo.

En el preprocesamiento de los datos de entrada se aplicó una normalización Z-Score a las 8 variables macroeconómicas seleccionadas. Dado que estas series temporales se presentan en diferentes unidades, fue necesario estandarizarlas para evitar sesgos numéricos durante el entrenamiento. La transformación realizada fue de la forma:

$$Z = \frac{X - \mu}{\sigma}.$$

Se reescaló cada variable para que posea una media 0 y una desviación estándar de 1. Este procedimiento es fundamental para optimizar el rendimiento de la red neuronal LSTM, ya que facilita la convergencia del algoritmo de descenso de gradiente y evita que las variables con escalas absolutas mayores dominen la función de pérdida, asegurando una ponderación equilibrada de todos los factores macroeconómicos en la predicción (Ping, Hu & Luo, 2024).

3.7 Métricas

Para la evaluación de los modelos predictivos, el análisis se fundamenta en cuatro estadísticas clave: el Error Cuadrático Medio (MSE), la Raíz del Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Coeficiente de Determinación (R^2). En términos de escala, el MSE, RMSE y MAE oscilan en un rango de 0 a infinito, donde valores más cercanos a cero indican una mayor precisión. Específicamente, el MSE mide la varianza del error penalizando drásticamente las grandes desviaciones, el RMSE ofrece una interpretación en las mismas unidades que la variable objetivo, facilitando comparabilidad, y el MAE cuantifica la magnitud promedio de los errores de forma lineal y menos sensible a valores atípicos. Por el contrario, el R^2 se encuentra habitualmente en la escala de 0 a 1, midiendo la proporción de la varianza de los datos que es explicada por el modelo, donde un valor de 1 representa un ajuste perfecto.

$$\begin{aligned} \text{MSE} &= \frac{1}{n} \sum (Y_i - \hat{Y}_i)^2, \\ \text{RMSE} &= \sqrt{\frac{1}{n} \sum (Y_i - \hat{Y}_i)^2}, \\ \text{MAE} &= \frac{1}{n} \sum |Y_i - \hat{Y}_i|, \\ R^2 &= 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}, \end{aligned}$$

donde Y_i representa el valor observado de la tasa, $\hat{Y}_i$ representa el valor predicho de la tasa, $\bar{Y}$ representa el valor medio de las tasas y n el número de observaciones.

4 Resultados

4.1 Nelson-Siegel

La siguiente tabla resume para cada factor del modelo Nelson-Siegel las estadísticas descriptivas básicas, junto al test de Dickey–Fuller aumentado (ADF). Las medias y rangos muestran que los factores varían de forma importante en el tiempo, el factor de nivel (β_0) promedia 2 con baja dispersión relativa, pendiente (β_1) es en promedio negativo y más volátil, y el factor de curvatura (β_2) presenta la mayor variabilidad. Esto indica que la forma de la curva de rendimientos ha sufrido cambios relevantes en el periodo muestral.

Las columnas que recopilan las autocorrelaciones muestrales a 1, 12, 30 periodos revelan que la autocorrelación de primer orden es muy alta, indicando una persistencia temporal fuerte, es decir, los valores actuales efectivamente están en gran medida relacionados con los del periodo anterior. En cambio, las autocorrelaciones de 12 y 30 periodos son pequeñas o incluso negativas, esto sugiere que, a pesar de existir una fuerte dependencia de corto plazo, los *shocks* tienden a disiparse gradualmente a horizontes más largos.


Cuadro 2: Estadística descriptiva de factores Nelson-Siegel

Factor	Media	Desv. Std	Min	Max	$\hat{\rho}(1)$	$\hat{\rho}(12)$	$\hat{\rho}(30)$	ADF
$\hat{\beta}_0$	2.0163	0.5564	0.5051	3.6237	0.8842	0.0091	-0.0997	-2.7933
$\hat{\beta}_1$	-1.7433	1.5437	-6.6189	0.9604	0.8217	0.1269	0.1269	-2.4924
$\hat{\beta}_2$	-0.9986	3.9161	-9.2708	12.4618	0.8922	0.0156	0.0156	-1.6352

Nota. Elaboración propia

El análisis de la distribución del error cuadrático medio (MSE) para el modelo Nelson-Siegel + AR(1) revela un desempeño preciso a través de las estructuras temporales. Como se observa en el gráfico de cajas, la magnitud de los errores es consistentemente baja, con medianas situadas próximas a cero y rangos intercuartílicos estrechos, especialmente en las maduresces de largo plazo, indicando una alta estabilidad en las predicciones. Debido a esta capacidad para minimizar el error de ajuste y su robustez estructural, este modelo tradicional fue seleccionado como el *benchmark* de referencia para contrastar y validar la eficacia de los modelos alternativos de machine learning propuestos.

Figura 2: Error Cuadrático Medio modelo Nelson-Siegel AR(1)




Nota. Elaboración propia

Al representar el desempeño del modelo Nelson-Siegel en el objetivo de pronosticar la curva de rendimientos en las seis madureces distintas, comparando los datos reales con las predicciones del modelo, en general las curvas muestran que el modelo captura con éxito la tendencia direccional y los principales ciclos de las tasas de interés, respaldado por coeficientes de determinación sólidos. Aun así, existe un ligero desfase en los puntos de inflexión abruptos y una tendencia a suavizar la volatilidad extrema, lo cual es consistente con la naturaleza paramétrica de este modelo, que prioriza una estructura de curva suave y persistente sobre el ajuste perfecto al ruido de corto plazo.

Se observa un desfase temporal evidente en las predicciones, los pronósticos tienden a replicar el movimiento de la serie real con un periodo de retraso. Se trata de un comportamiento clásico en modelos de fuerte componente autorregresivo, donde la mejor predicción para el siguiente periodo será en gran medida el valor del periodo anterior, limitando su capacidad para anticipar cambios.

Figura 3: Curva de rendimientos pronosticada y real a diferentes plazos modelo Nelson-Siegel



Nota. Elaboración propia


4.2 Random Forest

El modelo Random Forest con la inclusión de variables demuestra su capacidad para capturar la dirección de las tasas en todos los plazos, las predicciones (línea punteada rosa) replican fielmente los cambios de régimen, identificando correctamente la caída de tasas en el periodo 2019–2020, y el posterior ciclo alcista. Sin embargo, se observa un efecto de inercia, en el cual la predicción tiende a reaccionar un periodo tarde ante puntos de inflexión agudos, ya que, a pesar de incluir variables, sigue dependiendo en gran medida de la autorregresión. Aun con la inclusión de las 8 variables, el modelo tiende a subestimar la magnitud de movimientos extremos en episodios de alta volatilidad, sugiriendo que el algoritmo es conservador y que no logra anticipar la agresividad del choque monetario de ese periodo.

En ambos modelos Random Forest, tanto el que solo incluye la estructura de tasas como el que incluye las variables macroeconómicas, se supera al Nelson-Siegel en prácticamente todos los tramos de la curva, logrando una reducción generalizada del error. La incorporación del modelo Random Forest significa un avance en la capacidad predictiva, superando las limitaciones estructurales del enfoque paramétrico. Prescindiendo de una forma funcional predefinida, el algoritmo de aprendizaje automático captura las no linealidades y volatilidad de las tasas de rendimiento. Se destaca una eficacia superior en tramos cortos de la curva, en donde las fluctuaciones del mercado suelen ser más abruptas y difíciles de modelar mediante ecuaciones.

Existe un deterioro en el ajuste en el tramo largo de la curva, los movimientos erráticos del mercado en el largo plazo no son totalmente capturados, funcionando con heterogeneidad para las distintas madureces, ya que donde obtiene menores errores y una bondad de ajuste más alta es en tramos intermedios de 5 y 10 años.

Figura 4: Curva de rendimientos pronosticada y real a diferentes plazos modelo Random Forest + Variables



Nota. Elaboración propia

4.3 SMLR

Al aplicar la regresión Stepwise para el modelo híbrido se determina que presenta un ajuste robusto para todas las tasas de hasta 30 años. Al observar específicamente para la madurez de 10 años, se encuentra que le otorga a todas las variables una significancia estadística superior al 99 %. Destaca la alta dependencia al contexto externo, siendo el bono de Estados Unidos el determinante principal, con un coeficiente de 0.50, el más alto en esta *yield*, esto implica que la mitad de los movimientos de la tasa internacional se traspasan directamente al costo de financiamiento local en el plazo de 10 años, superando incluso a las variables domésticas estudiadas.

El análisis completo muestra que los bonos se comportan de forma muy distinta según el plazo. En el corto plazo el aspecto más importante es la tasa de política monetaria (TPM) junto con el cobre, el cual ayuda a bajar las tasas ya que trae dólares al mercado. Sin embargo, en el largo plazo a los inversores deja de interesarles la TPM y se guían más por el mercado extranjero. El factor que mueve todo es la tasa de Estados Unidos, que afecta a todos los plazos, sobre todo al bono de 2 años. Un detalle a considerar es que el cobre cambia de rol, si bien hoy ayuda a bajar las tasas exigiendo menos rendimientos cuando tiene un aumento, a largo plazo y desde el bono de 10 años en adelante ocurre lo contrario, empujando las tasas hacia arriba, ya que un cobre al alza suele significar una economía con mayor inflación a causa del aumento del consumo ocasionado por la nueva entrada de dólares. Además, mayores ingresos provenientes del cobre mejoran las expectativas de crecimiento económico y, por ende, aumentan las expectativas de utilidades futuras.

Por otro lado, se observa una clara disminución en la capacidad de predicción a medida que aumenta el plazo de los bonos, de tal manera que las variables explican en gran medida el clima actual

de las tasas cortas, las que son afectadas casi inmediatamente según lo que ocurra en el contexto económico, a diferencia de los bonos con tasas más largas en donde al modelo naturalmente le cuesta más predecir lo que ocurrirá en el largo plazo.

Cuadro 3: Regresión por pasos (Stepwise regression)

Yield	Variable	Beta	T-Value	P-Value	Sig	R2_Adj_Modelo
y10	Bono_EEUU_10Y	0.50	41.73	0.000	***	0.70
y10	Balanza_Comercial	0.12	14.36	1.1E-45	***	
y10	TPM	0.11	9.50	3.6E-21	***	
y10	Precio_Cobre	0.10	7.37	2.0E-13	***	
y10	Inflacion	0.07	8.79	2.1E-18	***	
y10	SP500_VIX	-0.06	-7.66	2.3E-14	***	
y10	Actividad_Comercio	-0.05	-5.10	3.6E-07	***	
y10	Cotizantes	-0.05	-5.66	1.7E-08	***	

Nota. Elaboración propia

***, **, * representan niveles de significancia al 1 %, 5 % y 10 % respectivamente

4.4 LSTM

La implementación del modelo LSTM utiliza una frecuencia de observaciones diaria para maximizar la eficacia de su arquitectura recurrente diseñada para aprender patrones secuenciales complejos mediante la actualización constante de sus estados de memoria. Con el fin de mantener una comparación directa con los modelos de referencia estimados mensualmente, el horizonte de pronóstico se fijó en 20 días hábiles, lo que constituye el equivalente a un mes calendario en los mercados financieros.


El modelo LSTM se posiciona claramente como el modelo superior entre los analizados, logra un equilibrio entre la flexibilidad del Random Forest y la suavidad estructural clásica. Mientras que Random Forest muestra un deterioro en la capacidad predictiva de plazos largos, el LSTM destaca en ellos. El Random Forest trata cada punto aisladamente, diferencia importante con el LSTM, en donde debido a la memoria entiende que la tasa de hoy depende de la secuencia de días anteriores, permitiendo modelar mucho mejor la inercia en tasas de largo plazo, las cuales no suelen cambiar bruscamente.

Ante escenarios de crisis financiera caracterizados por alta volatilidad e incertidumbre, el comportamiento de los modelos es sustancialmente distinto según su estructura. Mientras que

Nelson-Siegel refleja una rigidez paramétrica que tiende a seguir los choques extremos sin considerar la magnitud, el Random Forest subestima estas fluctuaciones debido a su estructura en donde los valores extremos se suavizan, porque la mayoría de los árboles optará por ello. Considerando lo anterior, el LSTM demuestra una robustez en estos periodos críticos, gracias a sus celdas de memoria y capacidad para procesar secuencias, logra adaptarse dinámicamente a los nuevos acontecimientos del mercado, identificando tendencias con precisión.

La red recurrente demuestra una notable sensibilidad para replicar la alta volatilidad sin sufrir del sesgo de suavizado en datos extremos. El uso de la frecuencia diaria se convierte en un factor determinante en este comportamiento, cuyo detalle temporal permite al modelo capturar la estructura del mercado e incorporar nueva información rápidamente. Esta alta frecuencia combinada con la memoria de la red facilita una reacción ágil ante los cambios de tendencia, superando a la inercia que acompaña a modelos con datos mensuales. Esto conlleva un incremento sustancial en el costo computacional respecto a los modelos de referencia, debido a la naturaleza secuencial del algoritmo y al crecimiento exponencial del volumen de datos a procesar. La red LSTM requiere procesos intensivos de optimización iterativa y el uso de GPU para gestionar la alta dimensionalidad de los tensores temporales.

Figura 5: Curva de rendimientos pronosticada y real a diferentes plazos modelo LSTM



Nota. Elaboración propia

4.5 Comparativa

El modelo Nelson-Siegel demostró un rendimiento menor frente a las metodologías de aprendizaje automático, evidenciando las limitaciones correspondientes a su estructura paramétrica, manteniendo un coeficiente de determinación de 0.63 y los niveles de error más elevados del análisis. Esta brecha en los resultados revela que la rigidez de la forma funcional que impone Nelson-Siegel restringe su capacidad para capturar patrones complejos de la curva de rendimientos.

El desempeño de las distintas estrategias de modelamiento evidencia una clara preferencia en la capacidad predictiva, en donde la complejidad del modelo se correlaciona positivamente con la precisión. Mientras que el *benchmark* muestra un ajuste moderado, los modelos de machine learning logran un salto significativo al reducir el error. La arquitectura híbrida propuesta se consolida como el modelo superior, alcanzando un coeficiente de determinación de 0.88 y disminuyendo el error a 38 puntos base en promedio, de forma que integrar técnicas avanzadas en selección de variables, reducción de dimensionalidad y redes neuronales recurrentes logra capturar la dinámica de las tasas de interés de mejor manera.

Cuadro 4: Comparación resultados de modelos

Categoría	Modelo	R^2	MSE	RMSE	MAE
AR (1)	Nelson-Siegel	0.63	0.29	0.54	0.41
	Random Forest (PCA)	0.82	0.21	0.45	0.33
ML	Random Forest + V Macro	0.81	0.2	0.44	0.33
	LASSO-SMLR-PCA-LSTM*	0.88*	0.16*	0.38*	0.27*

Nota. Elaboración propia

Al contrastar los distintos resultados del algoritmo Random Forest, se evidencia que la incorporación de variables macroeconómicas, por lo menos en este modelo, no aporta una ganancia sustancial en el poder predictivo respecto al modelo basado exclusivamente en la estructura de tasas (PCA). De hecho, la simplicidad de este algoritmo logra superar marginalmente a la versión ampliada en términos de bondad de ajuste y mantiene un desempeño similar en cuanto a los errores. Este comportamiento sugiere que los factores latentes extraídos de la propia curva de rendimientos ya capturan la mayor parte de la información relevante, impidiendo que la adición de variables macroeconómicas ayude significativamente a los resultados.

El análisis detallado por madurez revela que el modelo base Nelson-Siegel presenta las métricas de error más elevadas en todas las madureces, demostrando una dificultad particular para ajustar el tramo corto de la curva, el cual suele ser el más variable, con un RMSE máximo de 0.73 en el plazo de 1 año. Al contrastar las especificaciones de Random Forest, un aspecto relevante es la utilidad de la información exógena, la inclusión de variables macroeconómicas logra mejorar la precisión en el corto plazo, reduciendo el error a 1 año de 0.65 a 0.56 al pasar de un Random Forest dependiente solo de la estructura de tasas a un Random Forest con diferentes variables, indicando que la coyuntura en noticias económicas posee mayor poder explicativo en los rendimientos cercanos, incluso este modelo es el mejor de los cuatro prediciendo el bono de 2 años. A pesar de lo anterior, esta ventaja comparativa desaparece en el tramo largo de 20 y 30 años, de forma que al agregar variables

macroeconómicas posiblemente el modelo está tomando información repetida que ya se encuentra implícitamente en las tasas, esto lleva a que aprenda “ruido”, mientras que el modelo básico se centra solo en la dinámica de tasas. Aun así, como se observó anteriormente, el modelo que incluye variables macroeconómicas en general supera ligeramente al modelo básico de Random Forest.

Por otra parte, la arquitectura híbrida del modelo LSTM consolida una superioridad indiscutible a lo largo de toda la estructura temporal, minimizando sistemáticamente el error de predicción frente a todas las alternativas. En el extremo de la curva su desempeño resulta especialmente robusto, alcanzando un RMSE de 0.28, representando una mejora del error significativa frente al *benchmark* paramétrico para los mismos plazos. La tendencia generalizada a la baja del RMSE a medida que aumenta la madurez confirma una mayor predictibilidad en los rendimientos de largo plazo para todos los modelos.

Cuadro 5: Comparación resultados RMSE de modelos por madurez

Modelo	Madurez	RMSE h1
Nelson-Siegel + AR (1)	yield 1 año	0.73
	yield 2 años	0.66
	yield 5 años	0.51
	yield 10 años	0.43
	yield 20 años	0.41
	yield 30 años	0.40
Random Forest (PCA)	yield 1 año	0.65
	yield 2 años	0.55
	yield 5 años	0.38
	yield 10 años	0.36
	yield 20 años	0.34
	yield 30 años	0.35
Random Forest + V Macro	yield 1 año	0.56
	yield 2 años	0.54*
	yield 5 años	0.40
	yield 10 años	0.36
	yield 20 años	0.37
	yield 30 años	0.38
LASSO-SMLR-PCA-LSTM	yield 1 año	0.53*
	yield 2 años	0.56
	yield 5 años	0.33*
	yield 10 años	0.30*
	yield 20 años	0.26*
	yield 30 años	0.28*

Nota. Elaboración propia


4.6 Horizontes

El análisis se profundiza evaluando la robustez de los modelos ante la incertidumbre temporal, extendiendo el horizonte de pronóstico de 1 a 3 y 6 meses.

En la proyección a 3 meses, el gráfico ya revela una tendencia en la fiabilidad de los modelos paramétricos frente a los de machine learning, mientras que el gráfico de Nelson-Siegel comienza a estirarse verticalmente y su tercer cuartil ya supera el nivel de error 1.2, implicando que el 25 % de sus peores predicciones ya tiene errores considerablemente más altos que en el horizonte de 1 mes. A pesar de esto, los demás modelos logran contener la subida del error, aumentando sus cajas pero manteniéndose en mayor medida comprimidas, en donde la mayoría de sus predicciones siguen siendo precisas a pesar del mayor plazo.

Los resultados evidencian que, si bien la dificultad de predicción aumenta naturalmente con el plazo, la degradación del desempeño es desigual entre las metodologías. El modelo Nelson-Siegel muestra una sensibilidad crítica al horizonte, con un MSE que se expande rápidamente a los 6 meses, indicando una pérdida en la confiabilidad. En contraste, los modelos de aprendizaje automático exhiben una estabilidad superior, destacando el Random Forest junto a variables, el cual mantiene una distribución de errores compacta incluso en horizontes más lejanos, confirmando su capacidad para tomar en cuenta la tendencia del mercado gracias a las variables macroeconómicas.

Figura 6: Comparación resultados MSE por Horizonte



Nota. Elaboración propia

4.7 Test Diebold–Mariano (DM)

Los resultados del test de Diebold-Mariano demuestran indiscutiblemente la superioridad del modelo LSTM sobre el benchmark Nelson-Siegel AR(1) y las variantes de Random Forest, consolidándose como la arquitectura más robusta al ser la única capaz de superar significativamente al benchmark en toda la curva de rendimientos desde el horizonte más inmediato ($h = 1$), un escenario donde los modelos de árboles muestran debilidades claras al no lograr batir al benchmark en los tramos largos.

Si bien la inclusión de variables macroeconómicas en el Random Forest le permite superar al Random Forest que solo usa estructura de tasas en los tramos cortos durante el primer mes, ambos modelos de Random Forest necesitan horizontes de proyección más amplios ($h = 3$ y $h = 6$) para volverse consistentemente superiores al benchmark, en cambio, el enfoque secuencial del LSTM logra tomar en cuenta las dinámicas de corto como de largo plazo desde el primer momento.

Figura 7: Test Diebold–Mariano

Pronóstico		RF PCA h1		RF PCA h3		RF PCA h6	
Tasa		DM test	p	DM test	p	DM test	p
y1		0,77	0,44	4,19	0,000***	4,23	0,000***
y2		2,70	0,006***	5,73	0,000***	5,48	0,000***
y5		2,18	0,02**	3,96	0,000***	3,56	0,000***
y10		1,63	0,10	1,97	0,04**	2,41	0,01**
y20		1,76	0,07	2,36	0,01**	2,65	0,007***
y30		1,56	0,11	2,08	0,03**	2,52	0,011**
Pronóstico		RF Var h1		RF Var h3		RF Var h6	
Tasa		DM test	p	DM test	p	DM test	p
y1		2,18	0,02**	4,32	0,000***	4,09	0,000***
y2		2,20	0,02**	6,02	0,000***	5,64	0,000***
y5		1,97	0,04**	4,18	0,000***	4,27	0,000***
y10		1,45	0,14	2,12	0,03**	3,20	0,001***
y20		0,83	0,40	2,09	0,03**	2,94	0,003***
y30		0,57	0,56	1,92	0,05*	2,71	0,006***
Pronóstico		LSTM h1		LSTM h3		LSTM h6	
Tasa		DM test	p	DM test	p	DM test	p
y1		2,04	0,04**	3,41	0,000***	4,89	0,000***
y2		1,86	0,06*	3,87	0,000***	4,89	0,000***
y5		3,49	0,000***	5,1	0,000***	5,42	0,000***
y10		4,4	0,000***	3,87	0,000***	3,87	0,000***
y20		4,32	0,000***	3,6	0,000***	3,95	0,000***
y30		3,52	0,000***	3,39	0,000***	3,52	0,000***

Nota. Elaboración propia

5 Estrategia de Inversión basada en resultados

La idea propuesta se basa en anticipar correctamente los cambios de tendencia en la tasa de interés, más que en predecir su nivel exacto. En este enfoque direccional, lo relevante es identificar si la tasa aumentará o disminuirá en el periodo siguiente, ya que esa señal permite tomar decisiones que capturen la variación del precio del bono. De este modo, la estrategia busca explotar la dirección del movimiento como principal fuente de retorno, independientemente de la magnitud precisa del cambio.

Para cuantificar la magnitud típica de los movimientos de precio en cada tramo de la curva, se utilizó una duración estimada por bono, la cual refleja la sensibilidad del precio ante cambios en la tasa de interés para cada madurez. Esta duración se combinó con la desviación estándar mensual

de las variaciones de la yield, entendida como el cambio porcentual promedio que tiene cada tasa en un mes. La desviación estándar captura la volatilidad natural del instrumento y representa el tamaño típico de una fluctuación mensual en la tasa. La variación mensual del precio se estimó como el producto entre la duración del bono y el cambio típico de la yield en el último año y medio expresado en términos decimales. Con ello fue posible obtener una medida consistente de la variación esperada del precio para cada madurez, permitiendo comparar cuantitativamente la exposición inherente de cada tramo de la curva.

$$\frac{\Delta P}{P} \approx -D \cdot \Delta y$$

Posteriormente, se evaluó la capacidad predictiva del modelo LSTM mediante la probabilidad de acierto en los cambios de tendencia, calculada como la proporción de meses en que el modelo anticipó correctamente la dirección del movimiento de la tasa, acertando cuando sigue la tendencia y fallando cuando no. Con esta probabilidad y la variación típica del precio previamente estimada, se construyó un retorno esperado direccional para cada bono. El retorno esperado se obtiene ponderando la magnitud del movimiento de precio por la probabilidad de acertar la dirección, y descontando proporcionalmente las pérdidas cuando el modelo se equivoca.

$$E[R] = p \cdot |\Delta P| - (1 - p) \cdot |\Delta P|$$

Para evaluar cada tramo de la curva, se calculó el ratio de Sharpe de forma simplificada, el cual permite medir el retorno obtenido por unidad de riesgo asumido. De esta manera, el ratio de Sharpe se obtuvo dividiendo el retorno esperado entre la volatilidad del precio, entregando una medida comparable entre tramos que incorpora tanto la sensibilidad a tasas como la capacidad predictiva del modelo.

$$Sharpe = \frac{E[R]}{\sigma_R}$$

Los resultados muestran que el bono de 20 años supera ampliamente al resto de los tramos evaluados tanto en retorno esperado mensual como en desempeño ajustado por riesgo. En particular, presenta un retorno esperado de 1,74 % mensual, significativamente mayor al observado en los bonos de menor madurez, y un ratio de Sharpe de 0,39, el más alto dentro de todos los consideradas. Este desempeño superior se explica por dos factores combinados, por un lado, la mayor sensibilidad a movimientos de tasas derivada de su elevada duración, y por otro, la mayor probabilidad de acierto del modelo LSTM al predecir correctamente la tendencia en dicho tramo, alcanzando un 69 % de precisión. La interacción entre alta sensibilidad y elevada capacidad predictiva hace que el tramo

de 20 años sea el más atractivo para implementar estrategias de inversión.

Figura 8: Comparación resultados sensibilidad

Bono	Cambio en el Precio	Bono	Duración estimada	Bono	Desviación estandar
y1	0,71%	y1	0,95	y1	0,75%
y2	1,28%	y2	1,80	y2	0,71%
y5	0,68%	y5	4,00	y5	0,17%
y10	2,00%	y10	8,00	y10	0,25%
y20	4,50%	y20	15,00	y20	0,30%
y30	6,00%	y30	20,00	y30	0,30%

Bono	Probabilidad de acierto	Bono	E(Rm)	Bono	Sharpe m
y1	60,34%	y1	0,15%	y1	0,21
y2	61,90%	y2	0,30%	y2	0,24
y5	66,67%	y5	0,23%	y5	0,33
y10	66,29%	y10	0,65%	y10	0,33
y20	69,32%	y20	1,74%*	y20	0,39*
y30	56,67%	y30	0,80%	y30	0,13

Nota. Elaboración propia

A partir de estos resultados, se propone una estrategia direccional de renta fija basada en la señal de tendencia entregada por el modelo. Cuando el LSTM predice una disminución en la tasa del bono a 20 años, lo que implica un aumento en su precio, se toma una posición larga en el bono, capturando la apreciación asociada al movimiento esperado. Por el contrario, cuando se anticipa una subida en la tasa se toma una posición en un swap UF a 20 años, pagando tasa fija y recibiendo tasa flotante (payer swap), bajo el supuesto de que el swap y el bono poseen una alta correlación en sus movimientos por reflejar ambos la tasa real de largo plazo al estar indexados a la UF y tener el mismo plazo. Esta estructura permite beneficiarse del incremento en las tasas largas, ya que el valor del swap aumenta cuando la tasa de mercado sube y cuando ello ocurra basta con cerrar la posición en el swap para capturar las ganancias. De esta forma, la estrategia combina de manera eficiente posiciones largas en bonos con posiciones en swaps, logrando retornos tanto en escenarios de alzas como de bajas en la tasa de largo plazo y consiguiendo un retorno esperado anual de un 22,98 % sobre el monto de la inversión.

$$V_{\text{swap}} = \sum_{i=1}^n P(0, t_i) (L_i - K) \Delta t_i$$

6 Conclusión

La investigación realizada permite concluir que la adopción de metodologías de Inteligencia Artificial supera significativamente a los enfoques econométricos tradicionales en la predicción de la curva de rendimientos chilena. Los resultados dan una jerarquía notoria en el desempeño, donde la complejidad del modelo va en línea con la precisión, el modelo híbrido LASSO-SMLR-PCA-LSTM se consolidó como la herramienta superior, mejorando los resultados del *benchmark* Nelson-Siegel en todas las tasas y tramos de la curva. Esto demuestra que la rigidez de las estructuras clásicas no permite captar la totalidad de la volatilidad y no linealidades del mercado de renta fija local, mientras que las estructuras de aprendizaje profundo logran modelar de mejor forma la dinámica de las tasas tanto en periodos de estabilidad como de crisis.

En cuanto al comportamiento por plazos y horizontes, se observa una divergencia notable en la robustez de las estimaciones. Mientras que el modelo Random Forest mejora en el tramo corto de la curva, su eficacia disminuyó en los plazos largos. Por el contrario, la red LSTM demostró una estabilidad estructural, manteniendo errores bajos incluso al extender el horizonte de pronóstico a 6 meses. La capacidad de las celdas de memoria para retener dependencias temporales le permitió superar a los modelos autorregresivos tradicionales y de Random Forest, almacenando solo la información relevante de manera automática.

No obstante, esta ganancia en precisión conlleva un costo computacional bastante elevado. A diferencia de la ejecución rápida de Nelson-Siegel o Random Forest, la implementación del modelo LSTM requirió una infraestructura de alto rendimiento para procesar la alta dimensionalidad de los tensores temporales y realizar las optimizaciones en las secuencias iterativas. La necesidad de utilizar una frecuencia de datos diaria, sumada a la validación con ventanas móviles, incrementó exponencialmente los tiempos de entrenamiento. Sin embargo, la reducción de los errores es considerable, por lo que este gasto de recursos se considera justificado para anticipar movimientos de los activos a manejar.

Los resultados indican que una estrategia direccional basada en anticipar cambios de tendencia en las tasas y ejecutada mediante posiciones largas en el bono en UF de 20 años constituye un enfoque consistente y potencialmente rentable dentro del mercado de renta fija chileno. La combinación entre una elevada sensibilidad del tramo de 20 años y una precisión predictiva del 69 % permite generar retornos esperados superiores al resto de la curva, sustentando una estrategia que no depende de estimar niveles exactos de tasas, sino únicamente de acertar en su dirección.

Por último, se confirma que la integración de técnicas de selección de variables, junto a aquellas que reducen la dimensionalidad, además de redes neuronales recurrentes, constituye el enfoque más

robusto para el mercado de deuda soberana en Chile. Se identificó que, si bien factores externos como la tasa del Tesoro de EE. UU. y el precio del cobre son determinantes críticos, la forma en que se procesa esta información es lo que define la calidad del pronóstico. El éxito del modelo híbrido sugiere una orientación necesaria de la industria hacia el uso de algoritmos adaptativos capaces de aprender de la inercia y de los choques exógenos que caracterizan a la economía nacional.

7 Bibliografía


Referencias

- [1] Base de Datos Estadísticos (BDE). (s. f.-a). URL: https://si3.bcentral.cl/Siete/ES/Siete/Cuadro/CAP_TASA_INTERES/MN_TASA_INTERES_09/TMS_16/T312
- [2] Base de Datos Estadísticos (BDE). (s. f.-b). URL: https://si3.bcentral.cl/Siete/ES/Siete/Cuadro/CAP_MERC_CAPT/MN_MERC_CAPT/EM_48At_DIARIA_2/638514615183443081
- [3] Banco Central de Chile. Gestión de operaciones Agencia Fiscal. (s.f.). URL: <https://www.bcentral.cl/areas/mercados-financieros/operaciones-de-mercado-abierto-agencia-fiscal>
- [4] Banco Central de Chile. Mercado de Valores de Renta Fija. (s.f.). URL: <https://www.bcentral.cl/areas/estadisticas/estadisticas-del-mercado-de-valores-de-renta-fija-e-intermediacion-financiera>
- [5] Investing.com. (2001). Rendimiento Bono Chile 10A. URL: <https://es.investing.com/rates-bonds/chile-10-year-bond-yield>
- [6] Akram, T., & Uddin, S. (2025). Chilean government bond yields: An econometric analysis. **Journal of Applied Economics**, 28(1).
- [7] Fabozzi, F., Focardi, S., & Rachev, S. **The Basics of Financial Econometrics**. Cap. 3.
- [8] Guidolin, M., & Ionta, S. (2025). Forecasting Asset Returns Using Nelson–Siegel Factors. **Econometrics**, 13(2), 17.
- [9] Papazoglou, I. (2021). **Economic forecast evaluation of the Nelson–Siegel model**. Erasmus School of Economics.
- [10] Entezari, A., Aslani, A., Zahedi, R., & Noorollahi, Y. (2023). Artificial intelligence and ML in energy. **Energy Strategy Reviews**, 45, 101017.
- [11] Ping, W., Hu, Y., & Luo, L. (2024). Price Forecast of Treasury Yield. **IEEE Access**, 12.
- [12] Ilinca, A.-M. (2024). **Predicting bond returns using machine learning techniques**. Master's thesis.

- [13] Diebold, F. X., & Li, C. (2006). Forecasting term structure. **Journal of Econometrics**, 130(2).
- [14] Bloznelis, D. (2018). Short-term salmon price forecasting. **Journal of Forecasting**, 37.
- [15] Yang, P. R. (2020). Using the yield curve to forecast economic growth. **Journal of Forecasting**, 39(8).
- [16] González Casimiro, M. (s.f.). **Modelos ARIMA**. Universidad del País Vasco.
- [17] Goehry, B., Yan, H., Goude, Y., Massart, P., & Poggi, J.-M. (2023). Random forests for time series. **REVSTAT**, 21(2).
- [18] Luque Raya, I. M., & Luque Raya, P. (2024). ML and liquidity estimation. **European Journal of Management and Business Economics**, 33(3).
- [19] Breiman, L. (2001). Random forests. **Machine Learning**, 45(1).


8 Anexos

Figura 9: Resultados Nelson-Siegel AR(1)




Nota. Elaboración propia

Figura 10: Resultados Random Forest Variables




Nota. Elaboración propia

Figura 11: Resultados Random Forest PCA



Nota. Elaboración propia

Figura 12: Resultados LSTM



Nota. Elaboración propia

Figura 13: Resultados ampliados Stepwise Regression

Yield	Variable	Beta	T-Value	P-Value	Sig	R2_Adj_Modelo
y1	TPM	0.75	45.20	0.000	***	0.78
y1	Bono_EEUU_10Y	0.64	36.62	3.7E-255	***	0.78
y1	Precio_Cobre	-0.35	-18.21	2.2E-71	***	0.78
y1	Actividad_Comercio	-0.21	-13.51	9.4E-41	***	0.78
y1	SP500_VIX	-0.14	-11.97	1.7E-32	***	0.78
y1	Inflacion	-0.08	-6.51	8.5E-11	***	0.78
y1	Balanza_Comercial	0.06	4.81	1.5E-06	***	0.78
y1	Cotizantes	-0.01	-1.19	2.3E-01		0.78
y2	Bono_EEUU_10Y	1.01	54.79	0.000	***	0.73
y2	Precio_Cobre	-0.32	-15.47	1.5E-52	***	0.73
y2	TPM	0.22	12.65	4.9E-36	***	0.73
y2	Balanza_Comercial	0.21	16.14	6.4E-57	***	0.73
y2	Actividad_Comercio	-0.14	-8.41	5.4E-17	***	0.73
y2	SP500_VIX	-0.11	-8.92	7.1E-19	***	0.73
y2	Cotizantes	-0.02	-1.81	7.0E-02	*	0.73
y2	Inflacion	0.00	-0.24	8.1E-01		0.73
y5	Bono_EEUU_10Y	0.55	41.80	0.000	***	0.77
y5	TPM	0.36	28.89	1.4E-167	***	0.77
y5	Balanza_Comercial	0.14	15.52	7.4E-53	***	0.77
y5	Inflacion	0.06	6.68	2.6E-11	***	0.77
y5	SP500_VIX	-0.05	-6.20	6.1E-10	***	0.77
y5	Actividad_Comercio	-0.05	-4.48	7.6E-06	***	0.77
y5	Cotizantes	-0.05	-5.19	2.2E-07	***	0.77
y5	Precio_Cobre	0.01	0.75	4.6E-01		0.77
y10	Bono_EEUU_10Y	0.50	41.73	0.000	***	0.70
y10	Balanza_Comercial	0.12	14.36	1.1E-45	***	0.70
y10	TPM	0.11	9.50	3.6E-21	***	0.70
y10	Precio_Cobre	0.10	7.37	2.0E-13	***	0.70
y10	Inflacion	0.07	8.79	2.1E-18	***	0.70
y10	SP500_VIX	-0.06	-7.66	2.3E-14	***	0.70
y10	Actividad_Comercio	-0.05	-5.10	3.6E-07	***	0.70
y10	Cotizantes	-0.05	-5.66	1.7E-08	***	0.70
y20	Bono_EEUU_10Y	0.33	41.67	0.000	***	0.59
y20	Precio_Cobre	0.17	14.06	6.8E-44	***	0.59
y20	Balanza_Comercial	0.09	12.68	3.4E-36	***	0.59
y20	SP500_VIX	-0.07	-10.00	2.8E-23	***	0.59
y20	Inflacion	0.06	8.36	8.7E-17	***	0.59
y20	Cotizantes	-0.06	-7.84	5.6E-15	***	0.59
y20	Actividad_Comercio	-0.05	-5.52	3.7E-08	***	0.59
y30	Bono_EEUU_10Y	0.31	28.14	7.5E-160	***	0.52
y30	Precio_Cobre	0.17	13.70	7.5E-42	***	0.52
y30	Balanza_Comercial	0.08	10.64	4.2E-26	***	0.52
y30	SP500_VIX	-0.07	-9.92	5.9E-23	***	0.52
y30	Cotizantes	-0.06	-8.26	1.9E-16	***	0.52
y30	Inflacion	0.06	7.72	1.4E-14	***	0.52
y30	Actividad_Comercio	-0.06	-5.60	2.3E-08	***	0.52
y30	TPM	-0.05	-4.68	3.0E-06	***	0.52

Nota. Elaboración propia