

44 Jornadas Nacionales de Administración Financiera
Septiembre 19 y 20, 2024

Implementación de *stablecoins* en los mercados de renta fija

Un acercamiento mediante el uso de redes neuronales

Daniel Miliá

Universidad de Buenos Aires

SUMARIO

1. Introducción
2. Metodología
3. Marco teórico
4. Modelización
5. Conclusiones

Para comentarios:
daniel@economicas.uba.ar

Resumen

A medida que los mercados avanzan hacia un mayor grado de descentralización financiera, la necesidad de imprimir más velocidad, transparencia y seguridad se hace cada vez más apremiante. Tras la aparición de las criptomonedas, se planteó un debate respecto a la escala de su transaccionalidad y el grado de su adopción por parte de los agentes económicos. Los modelos capaces de explicar ello quedan desfasados para cumplimentar tabulaciones de metadatos en grandes volúmenes, obligando a la búsqueda de una mayor eficiencia en el análisis estadístico.

A partir del desarrollo de las redes neuronales se busca implementar modelos de predicción dotados de una mayor interpretabilidad y consistencia, a los que se suele condicionarlos por variables categóricas, en este caso, relacionadas a las finanzas descentralizadas. En este sentido, el presente trabajo busca realizar un modelo sintético de análisis de eficiencia de un modelo de red neuronal a partir de la adopción de una tasa cupón sobre una obligación negociable de YPF S.A. sujeta a la cotización de una stablecoin que varíe en función al precio de commodities del mercado local y de subyacentes internacionales.

Los principales resultados obtenidos revelan que la emisión de la obligación negociable ligada a una stablecoin permite evitar rezagados de la tasa cupón ocasionados por escenarios pasados más favorables. En este sentido, permite al inversor una mayor diversificación del riesgo latente del instrumento, a la vez de crear incentivos para una mayor profundidad del mercado que contribuya a una menor fluctuación en el precio y por ende a minimizar la pérdida de valor de su portfolio. Por otro lado, dota al perfil de deuda del emisor de una erogación variable que permitirá sostener el atractivo del instrumento, contener su tasa en el mercado secundario, ampliar el apetito a inversores alejados de prospectos de deuda local y favorecer futuras colocaciones a partir de una curva de rendimientos más estable.

1. Introducción

En economía, los modelos basados en neuronales se utilizan para la predicción de variables de interés que puedan optimizar la planificación, aplicación y seguimiento de la política económica. La banca tradicional se encuentra inmersa en la transformación digital de su negocio de toma y colocación de fondos como así también de la oferta de sus productos financieros.

La necesidad de la bancarización en nuestro país se ha denotado principalmente a partir de la pandemia por Covid-19 donde la restricción de circulación generó un problema en términos transaccionales con el dinero tradicional (*Informe de Inclusión Financiera*, 2021), llevando a personas con bajo grado de aprehensión tecnológica a la utilización de sistemas completamente virtuales. En tal sentido, las criptomonedas surgen como una posible solución ante las dificultades de la banca tradicional, en la medida que puedan ocupar un rol relevante en términos de transacciones libres, sin costos adicionales y proporcionando una mayor confidencialidad y seguridad a los usuarios.

Asimismo, se denota que la inducción de su uso comenzó en un primer momento con el público de bajo rango etario, focalizado en países desarrollados. No obstante, la masificación llevó a traspasar las fronteras y llegar al resto del mundo, principalmente en América Latina, donde países como El Salvador y Venezuela han establecido su uso como medio transaccional, no sin pocas críticas y debate profesional y/o académico.

La relevancia de la temática subsiste incluso en su uso puesto que los agentes económicos relacionan las criptomonedas como alternativa de inversión o bien como medio de cambio, siendo incluso las motivaciones entre ellos ciertamente contradictorias, en virtud que la volatilidad con la que a los primeros se manifiestan receptivos, contrasta con la reserva de valor que pregonan los segundos.

La potencialidad para ser utilizada como instrumento de inversión o financiación obliga a analizar el rol de las criptomonedas en el desarrollo del mercado de capitales local. En los últimos veinte años el ratio del volumen operado con relación al PIB representa poco menos de 6 %, hecho que se complementa con la masividad de instrumentos de renta fija (principalmente bonos públicos) en desmedro de la renta variable e instrumentos derivados. Paralelamente, existe una cantidad de cuentas comitentes que están concentradas en pocos agentes de liquidación y compensación, lo que redundo en mayor costo en la transaccionalidad de valores negociables. A su vez, la falta de desarrollo no solo obedece a cuestiones de tamaño del mercado local o a los elevados aranceles en relación con los países desarrollados, sino a la inestabilidad macroeconómica junto con las restricciones al libre movimiento de capitales, condicionando las tasas de referencia en el mercado primario y secundario y creando un clima de alta volatilidad en el precio de los activos.

En este sentido, las criptomonedas pueden emplearse como una posible solución ante las dificultades de financiamiento del sector público y/o privado en las colocaciones de deuda local o internacional, habida de la relevancia en la adopción de un instrumento innovador que ate el pago de cupones a una stablecoin correlacionada con commodities agrícolas, potenciando el rendimiento del instrumento en caso de una buena campaña. De manera análoga, la posibilidad de un bajo rinde en la cosecha puede provocar un alivio en las cuentas públicas o en la hoja de balance de las empresas, mitigando el requerimiento de los servicios de deuda y/o de capital de trabajo. En otras palabras, se genera un instrumento híbrido de financiamiento que permite provisionar el flujo de pagos de manera anticipada, dotando de cierto grado de maniobra a la política de financiamiento en virtud de una mejor planificación de los descalces futuros.

2. Metodología

Se emplea un modelo de red neuronal donde, a través de sub-regresiones logísticas entre las capas internas e interpolaciones entre los estimadores calculados, se llega a un modelo superador que permite recolectar el aprendizaje de regresiones pasadas y computar una regresión final que sea proclive a contrastar las hipótesis planteadas.

En base a ello se utilizarán las siguientes series históricas:

- Serie de precios correspondientes a la obligación negociable de tipo step-up de Y.P.F. S.A. con vencimiento en 2026 (Ticker: YMCHO) correspondiente al periodo comprendido desde febrero de 2021 a diciembre de 2022 y obtenida de Bolsas y Mercados Argentinos
- Serie de precios de la soja, trigo y girasol correspondiente al periodo enero de 2019 a diciembre de 2022 y obtenidas del Mercado de Rosario
- Serie de precios del petróleo West de Texas Intermediate (WTI) correspondiente al periodo enero de 2019 a diciembre de 2022 y obtenida de New York Mercantile Exchange (Nymex)
- Serie de la London Interbank Offered Rate (LIBOR) correspondiente al periodo enero de 2019 a diciembre de 2022 y obtenida del Banco Central de la República Argentina.

La propuesta metodológica consiste en utilizar la modelización expuesta a los efectos de estimar la tasa cupón de la obligación negociable de Y.P.F. S.A. Dicha tasa estará en función de la rentabilidad de una stablecoin denominada Argentum, la cual fluctuará en función de los commodities anteriormente mencionados y de la tasa interbancaria londinense. Asimismo, contendrá un piso mínimo del 4,5 % y un techo del 12 %, ambas tasas expresadas en términos nominales anuales. La multiplicidad de subyacentes involucrados persigue el propósito de crear un mercado secundario para la obligación negociable que posibilite un mayor atractivo a sus tenedores en tanto asegura una mayor diversificación del riesgo.

A partir de ello, se expondrá el sendero temporal de la tasa cupón resultante respecto a la tasa original de manera de evaluar si el instrumento modificado genera una mayor cobertura para el inversor en escenarios de stress financiero o, por el contrario, induce a retornos por debajo de lo esperado.

El análisis cuantitativo se realizará mediante R y Rstudio, a partir de los paquetes:

- Tidyverse (Wickham & Grolemund, 2017)
- ReadXL
- Neuralnet (Wright, 2022)
- NeuralnetTools (Beck, 2020)
- caTools (Rokach & Maimon, 2008)
- Ggplot2

3. Marco teórico

Los modelos de predicción a través de redes neuronales son un tipo de modelo de aprendizaje automático que imita el funcionamiento del cerebro humano para realizar predicciones. Estos modelos utilizan algoritmos para procesar grandes cantidades de datos y encontrar patrones complejos que permitan hacer predicciones precisas sobre eventos futuros.

Las redes neuronales consisten en capas de nodos interconectados que implican: la recepción de datos por parte de una capa de entrada, el procesamiento de datos a partir de capas ocultas y la predicción de resultados mediante una capa de salida. Durante este procedimiento,

se somete a entrenamiento a la red donde se ajustan los pesos de las conexiones entre los nodos para minimizar el error de estimación (Russell, 2018).

En el caso de aplicaciones a criptomonedas, la literatura es escasa y la evidencia sugiere que los modelos de predicción a través de redes neuronales se utilizaron para estimar la tasa de retorno de las criptomonedas a partir de sus series históricas, volumen transaccional, tipos de cambio y retornos de activos de renta variable o commodities como el oro (Blockchain, bitcoin y criptomonedas, 2018).

En el caso específico de las obligaciones negociables Hull (2009) estima una tasa variable a pagar en los cupones de deuda ajustada por la probabilidad de alza o caída de otro activo subyacente correlacionado, conservando un umbral mínimo de rentabilidad a obtener para el inversor. Siguiendo este criterio, un modelo de predicción a través de redes neuronales puede emplearse en la estimación de la tasa de retorno de un instrumento a los efectos de pronosticar fluctuaciones de precio y en consecuencia diagramar estrategias de cobertura o rotación de portafolios.

Incluso la modelización vía red neuronal podría incluir un mecanismo de *stop-loss* para los inversores utilizando datos históricos para que, en caso de una perspectiva bajista, se genere un aprendizaje de la red que permita tomar nuevos posicionamientos en el portfolio. A su vez, se puede emplear un mecanismo de bandas sobre el servicio de renta de manera de asegurar un piso mínimo de rentabilidad al inversor y evitar un pago por encima de lo esperado al deudor.

En síntesis, los modelos de predicción a través de redes neuronales son herramientas que pueden ser utilizadas en una amplia gama de aplicaciones en la economía y las finanzas. En el caso específico de los servicios de renta de las obligaciones negociables, estos modelos pueden colaborar en la toma de decisiones respecto al lanzamiento de prospectos, la gestión del riesgo y la maximización de la rentabilidad.

Función de regresión logística. La regresión logística es un tipo de análisis de regresión utilizado para predecir el resultado de una variable categórica en función de un conjunto de variables independientes o predictoras. A partir de ello, las probabilidades binomiales desconocidas se modelan como una función lineal de cada variable independiente, tal que:

$$\text{Logit}(P_i) = \ln\left(\frac{P_i}{1 - P_i}\right)$$

Es decir:

$$\text{Logit}(P_i) = B_0 + X_1B_1 + X_2B_2 + \dots + X_nB_n + \hat{u}$$

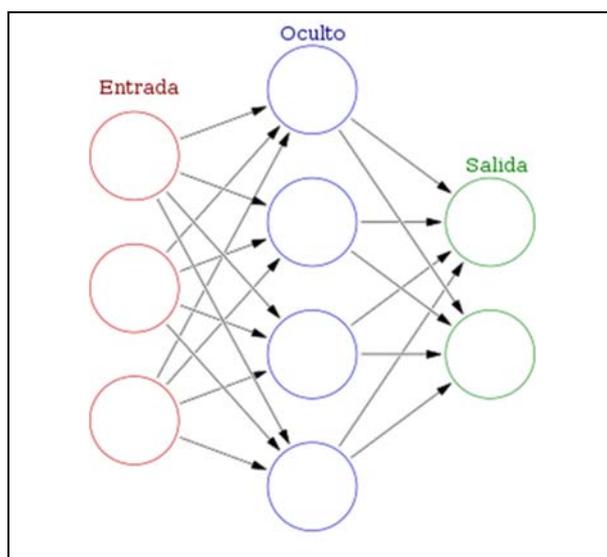
La optimización se realiza mediante el método de máxima verosimilitud con el fin de estimar los coeficientes de las variables independientes, mientras que la interpretación de los datos se encuentra representada por la estimación de los ratios de odds con el objetivo de evaluar una comparación del peso relativo entre variables dependientes del mismo conjunto pero diferenciados en alguna característica observable.

$$P_i = \frac{1}{1 + e^{-\text{Logit}(P_i)}}$$

Esta forma funcional es comúnmente identificada como un *perceptrón* simple o red neuronal artificial de una sola capa, donde se realiza un acercamiento a la predicción de la probabilidad de ocurrencia del evento dado un conjunto de valores independientes dentro de la primera capa. Por tanto, el resultado obtenido se guarda como un aprendizaje para las siguientes, permitiendo la estimación probabilística a partir de factores independientes de la variable explicada dentro de la misma sub-regresión. De esta forma, el aprendizaje generado por los resultados del sub-modelo anterior, alimenta las capas superiores evitando hacer nuevos cálculos que afecten las estimaciones previas e imprimiéndole más eficiencia al proceso.

Red neuronal. Una red neuronal artificial (RNA o ANR, por sus siglas en inglés) es un modelo computacional inspirado en la estructura y función del cerebro humano. Las redes neuronales consisten en capas de nodos interconectados los cuales, a partir de una capa de entrada que recibe los datos, una o más capas ocultas que realizan diversos procedimientos algebraicos y una capa de salida que produce la predicción final, generan un proceso de entrenamiento donde se ajustan los pesos de las conexiones intra-nodos con el objetivo de minimizar el error de predicción.

Ilustración 1: Composición de una red neuronal artificial de 2 capas



Proceso de conformación de una red neuronal

1. *Entrada (Input Layer).* La red neuronal toma datos de entrada, los cuales agrupa en conjuntos a los efectos de realizar sub-regresiones e interpolar los estimadores entre sí.
2. *Procesamiento (Hidden Layers).* A partir de los datos de entrada, se generan nuevas sub-regresiones a través de las capas ocultas, donde cada neurona es una combinación lineal de las entradas ponderadas por el peso de sus variables. Posteriormente, se aplica una función de activación a esta combinación lineal para introducir no linealidades en el modelo, permitiendo que la red aprenda patrones complejos.

3. *Salida (output layer)*. La información procesada se propaga a la capa de salida, que produce la predicción o resultado final. La cantidad de neuronas en la capa de salida depende del tipo de problema (clasificación, regresión, entre otros).
4. *Aprendizaje (backpropagation)*. La red ajusta sus pesos durante el entrenamiento mediante un proceso llamado “retropropagación” (*backpropagation*). Se compara la salida estimada con la salida deseada y se calcula un error. Luego, éste se propaga en sentido inverso (hacia atrás) a través de la red, ajustando los pesos y minimizando el error medio mediante técnicas de optimización tales como el descenso del gradiente.

La relación entre las redes neuronales artificiales y las regresiones logísticas se puede entender considerando que esta última es un tipo específico de red neuronal con una sola capa. En este caso, la función de activación es la función logística (también denominada sigmoide) y la red se utiliza principalmente para problemas de clasificación binaria.

A medida que se aumenta la complejidad y se agregan capas ocultas, la red neuronal generaliza mejor y es capaz de manejar problemas más complejos, incluyendo clasificación multi-clase y tareas de regresión. Los árboles de decisión son claves en el desarrollo de los nodos entre las neuronas, puesto que al realizar las sub-regresiones de cada modelo interno entre las capas de entrada y ocultas, permite la toma de decisión en forma binaria de manera automática y óptima.

Dentro del ámbito de redes neuronales, cada árbol de decisión simplifica de manera binaria las trayectorias que un algoritmo debe seguir. Corolario a los modelos bayesianos, estos consolidan la ruta de cada variable, ajustando cada paso de manera matemática hasta alcanzar la conclusión en su capa.

4. Modelización

Se parte del cómputo de la serie histórica de precios de la soja, trigo y girasol obtenida de la Bolsa de Rosario, de la serie del Petróleo WTI a partir de la Bolsa de Materias de Nueva York (Nymex) y de la serie de la tasa LIBOR extraída de las estadísticas monetarias y financieras del B.C.R.A., todas ellas correspondientes al periodo comprendido entre enero 2019 y diciembre 2022.

En una segunda instancia se computa la serie histórica de rendimientos de la obligación negociable de YPF con vencimiento en 2026 (YMCHO), comprendida desde el 12/02/2021 hasta 31/12/2022 inclusive.

A continuación se expone el modelo de prospecto de la obligación negociable YMCHO Clase I DUAL, cuyo servicio de renta está enlazado a la variación de la stablecoin ARGENTUM.

Sociedad	YPF S.A.
Nombre	YPF - GARANTIZADAS CLASE XVI
Ticker	YMCHO
Tipo	Obligación Negociable
Tasa	Step-Up
Inicio	12/2/2021
Vencimiento	12/2/2026
Valor tasa	4 % desde la Fecha de Emisión y Liquidación hasta e incluyendo el 31 de diciembre de 2022 y posteriormente devengarán intereses a una tasa fija de 9,000 % nominal anual hasta la Fecha de Vencimiento de las Obligaciones Negociables Clase XVI

Fuente: Bolsas y Mercados Argentinos (BYMA)

Sociedad	YPF S.A.
Nombre	YPF - GARANTIZADAS CLASE I DUAL
Ticker	YMCHO - Dual
Tipo	Obligación Negociable
Tasa	Dual tasa variable
Inicio	12/2/2021
Vencimiento	12/2/2026
Valor tasa	Devengará una tasa nominal anual hasta la fecha de vencimiento de las obligaciones negociables Clase I DUAL equivalente a la variación de la criptomoneda Argentum con las siguientes bandas: banda inferior 4,5 % y máxima 12 %. A los efectos del cálculo, se tomará el valor publicado 10 días hábiles antes del vencimiento de cada servicio de renta

Ilustración 2: Logo criptomoneda Argentum



La autoridad de emisión, administración y contralor de la *stablecoin* será el Banco Central de la República Argentina el cual será el encargado de evitar fluctuaciones que afecten severamente su valor, pudiendo establecer rangos de tolerancia a partir de los cuales implementar estrategias de stop loss o take profit con el propósito de mantener una paridad con el dólar y en línea con la moneda original de pago de la obligación negociable.

En la persecución de ese objetivo, la autoridad monetaria empleará derivados tales como futuros de la soja, petróleo, girasol, entre otros, en pos de sostener la cotización de la criptomoneda estable y fomentar su uso de manera transable para el pago de cupones y amortizaciones de deuda sin la afectación a las reservas internacionales.

La *stablecoin* propuesta tendrá la siguiente composición de subyacentes:

Subyacente	% Part
Soja	50 %
Trigo	25 %
Girasol	10 %
Petróleo	10 %
Libor	5 %
<i>Total</i>	<i>100 %</i>

Una vez realizados estos pasos se procedió a ejecutar el algoritmo de redes neuronales en Rstudio mediante la utilización de los paquetes Neuralnet y Neuralnetools. A partir de ello, se realiza la parametrización de las variables del algoritmo a entrenar:

```
#Muestra, entrenamiento y testeo
sample <- sample.split(dataset_prueba$INDICE_CIERRE, splitratio = 0.7) #variable a pronosticar
train <- subset(dataset_prueba, sample == TRUE) #Datos a entrenar
test <- subset(dataset_prueba, sample == FALSE) #Datos a Testear
```

Usualmente los modelos de redes neuronales utilizan el 70 % de los datos para entrenamiento a los fines de recolectar el mayor grado de experiencia posible, dejando el 30 % para pronóstico. La siguiente tabla contempla los betas calculados para cada submodelo de entrada en base a la fecha de cada iteración. La misma gestiona los valores de cada sub-regresión lineal calculando los índices pertinentes de cada variable independiente.

Tabla 1: Estimación de submodelos

Head Dataset						
FECHA	INDICE_PETROL EO	INDICE_SOJA	INDICE_TRIGO	INDICE_GIRASOL	INDICE_YMCHO	INDICE_LIBOR
3/10/2022	-0,019005	0,283165	0,172384	0,039677	-0,027803	0,036583
4/10/2022	0,317064	0,280086	0,169305	0,039369	-0,027477	0,034783
5/10/2022	-0,002784	0,278873	0,168092	0,039248	-0,026187	0,028783
6/10/2022	-0,002875	-0,102315	0,005845	-0,003423	0,001944	0,026983
7/10/2022	0,032097	-0,074013	-0,028564	-0,002975	0,000515	0,020983
10/10/2022	0,024398	-0,343360	0,202733	-0,041816	-0,003283	0,019183
11/10/2022	0,333157	0,276825	0,166043	0,039043	-0,026187	0,029283
12/10/2022	0,321380	0,251264	0,161075	0,038546	-0,028129	0,027483

Cada índice ha sido calculado a partir de las sub-regresiones del modelo de manera interna, a los fines de retroalimentar la regresión logística del modelo general y compactar las capas anidadas. Una vez determinado los índices, se ejecuta la matriz de la red neuronal, aplicando hasta 5 elementos de entrada, 5 capas ocultas y un máximo de 100.000.000 de pasos, a partir de regresiones logísticas en cada sub-modelo para luego interpolar en una regresión final.

A partir de la codificación expuesta, el output resultante es el siguiente:

Tabla 2: Regresión logística

OUTPUT	OUTPUT	VALUES
error	FINAL MODEL	0.053474025
reached.threshold	FINAL MODEL	0.008433788
steps	FINAL MODEL	100.000.000
HIDE 1	B1	-0.683147519
HIDE 1	I1	-0.516194953
HIDE 1	I2	0.444362735
HIDE 1	I3	0.222652213
HIDE 1	I4	0.763762271
HIDE 1	I5	0.410907205
HIDE 2	B1	-0.532293914
HIDE 2	I1	-0.353300087
HIDE 2	I2	0.614641934
HIDE 2	I3	-0.026232739
HIDE 2	I4	0.288124054
HIDE 2	I5	0.447334178
HIDE 3	B1	0.903112930
HIDE 3	I1	0.333228818
HIDE 3	I2	-0.129922445
HIDE 3	I3	-0.629453110
HIDE 3	I4	-1.025.724.168
HIDE 3	I5	-0.435776935
HIDE 4	B1	1.375.043.756
HIDE 4	I1	0.609419966
HIDE 4	I2	-0.554189757
HIDE 4	I3	-0.150555101
HIDE 4	I4	-0.726650599
HIDE 4	I5	-0.092565974
HIDE 5	B1	-2.066.731.074
HIDE 5	I1	0.283940169
HIDE 5	I2	-0.217020091
HIDE 5	I3	1.441.804.961
HIDE 5	I4	1.341.790.436
HIDE 5	I5	0.279230240
FINAL_MODEL	B1	0.623211631
FINAL_MODEL	I1	-0.739845022
FINAL_MODEL	I2	0.271978168
FINAL_MODEL	I3	-0.467286052
FINAL_MODEL	I4	-0.163055924
FINAL_MODEL	I5	-0.122860543

La red neuronal ha ejecutado hasta 100.000.000 pasos, dada la magnitud de combinaciones a realizar. De la tabla expuesta anteriormente, se obtienen los siguientes elementos:

- B: Ordenada al origen de cada sub-regresión y de la regresión final
- I1: Índice de Rentabilidad de Petróleo WTI de cada sub-regresión y de la regresión final

- I2: Índice de Rentabilidad de Soja de cada sub-regresión y de la regresión final
- I3: Índice de Rentabilidad del Trigo de cada sub-regresión y de la regresión final
- I4: Índice de Rentabilidad del Girasol de cada sub-regresión y de la regresión final
- I5: Índice de Rentabilidad de la Tasa Libor de cada sub-regresión y de la regresión final

El error del modelo general se encuentra dentro del 5,3474 %, por lo que el factor de precisión se encuentra cercano al 95 %.

Beta	Name	Output	Error
B1	Intercept	0,062321163	0,00226772
I1	Petróleo	-0,073984502	0,11964778
I2	Soja	0,027197817	0,02914756
I3	Trigo	-0,046728605	0,09526936
I4	Girasol	-0,016305592	0,06805819
I5	Libor	-0,012286054	0,06446301

A fin de realizar la contrastación del modelo, se analiza la probabilidad de ocurrencia para determinar si el modelo esté generando resultados positivos en términos de aceptación.

$$\text{Probabilidad} = \frac{1}{1 + e^{-(B_0 + B_1 X_1 + B_2 X_2 + B_3 X_3 + B_4 X_4 + B_5 X_5)}}$$

Para ello es preciso contrastar si el modelo puede ser aplicado o, en otros términos, si su grado de probabilidad de éxito se encuentra dentro de los parámetros deseados. En este caso, se contrastó a partir de la evolución del precio de YMCHO y los subyacentes involucrados desde octubre a noviembre del año 2022:

Tabla 3: Índices de capa interna

Commodities	Índices Capa Interna 30/11/2022
Petróleo	-0.68670 %
Soja	3.07281 %
Trigo	2.75493 %
Girasol	-0.65525 %
Libor	0.61060 %

Los índices de Capa Interna con fecha 30/11/2022 se establecen a partir de los submodelos lineales de las capas de entrada a partir de la experiencia de los períodos anteriores a la fecha de corte.

En función de las estimaciones realizadas a partir de la capa interna, se puede pronosticar el retorno mensual de la obligación negociable. Considerando la formalización lineal, se obtiene que:

$$Y(\text{estimated}) = 0.06231 + (-0.073985) \times (-0.68670 \%) + 0.027198 \times (3.07281 \%) + (-0.046729) \times (2.75493 \%) + (-0.016306) \times (-0.65525 \%) + (-0.012286) \times (0.61060 \%) = 0.06241$$

La estimación arroja un rendimiento mensual del 6,241 %, el cual no diverge en demasía del valor observado para YMCHO durante el periodo analizado.

Commodities	31/10/2022	30/11/2022	Renta inter-mensual
YMCHO	80,6	85,5	6,08 %

De esta manera, la discrepancia arroja un valor de 0.161 % mensual y un error relativo de pronóstico 2,65 %. Por otra parte, al determinar la aceptación/rechazo de la probabilidad de ocurrencia, resulta que:

$$P(x) = \frac{1}{1 + e^{-(0.06241)}} = 0.5156$$

En otras palabras, existe una probabilidad de éxito del 51,56 % respecto al pronóstico de la rentabilidad de la obligación negociable YMCHO, a partir de la variación del precio por las commodities y la tasa libor.

En síntesis, podemos contrastar que el modelo requiere para una buena aceptación y bajo error, una alta cantidad de pasos de experiencia, con suficiente experiencia en el tiempo y distribuidos de forma uniforme por año, se pueden lograr resultados más robustos.

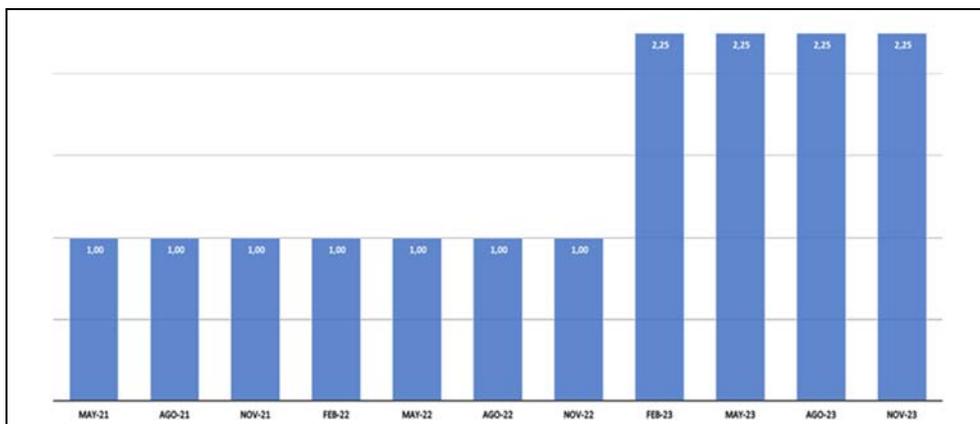
Los modelos de redes neuronales empleados en el ámbito económico requieren la determinación de su grado de error, siendo esencial mantener un margen de tolerancia para la variabilidad. Esto se debe a que factores temporales y posibles desviaciones externas pueden alterar significativamente la probabilidad de aceptación o rechazo en las predicciones relacionadas con los inputs del modelo. En este contexto, es imperativo establecer parámetros que actúen como límite de pérdida (Stop Loss) para prevenir impactos negativos en el precio de las obligaciones negociables, como así también límites de ganancia (take proof) con el fin de que el acreedor no abone un cupón que pueda alterar su real capacidad de pago.

En pos de analizar esta cuestión, se reporta el cash flow de YMCHO para el periodo 2021-2023 (ilustración 3).

El valor del cupón por cada 100 nominales de YMCHO varía de USD 1,00 para cupones vencidos hasta diciembre del año 2022 a USD 2,25 para aquellos que venzan a continuación. Al 04 de febrero de 2024 se encuentran en circulación un total de 716.124.622 de nominales, por lo que la suma abonada desde su emisión a la fecha en concepto de cupones asciende a USD 114.579.939,52.

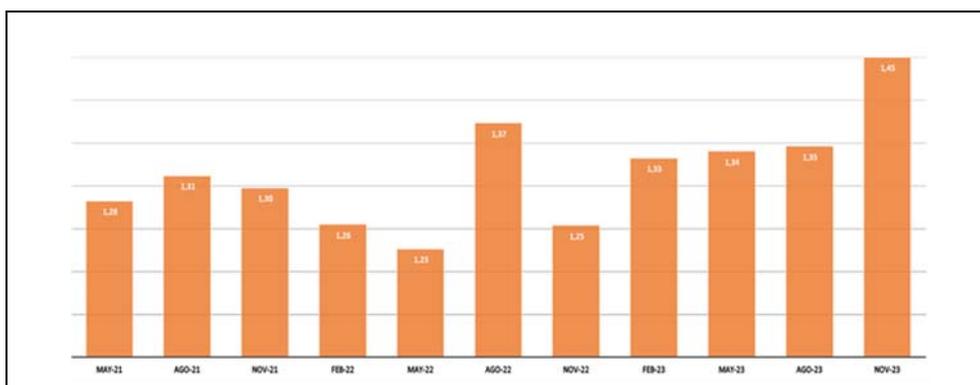
Asimismo, al realizar la ejecución del modelo, aplicando la variación de la cotización de la criptomoneda, se obtiene el resultado del pago de la rentabilidad de YMCHO Dual respecto del YMCHO original (ilustración 4).

Ilustración 3: Flujo de cupones YMCHO



Fuente: Elaboración propia en base a BYMA

Ilustración 4: Flujo de cupones YMCHO Dual



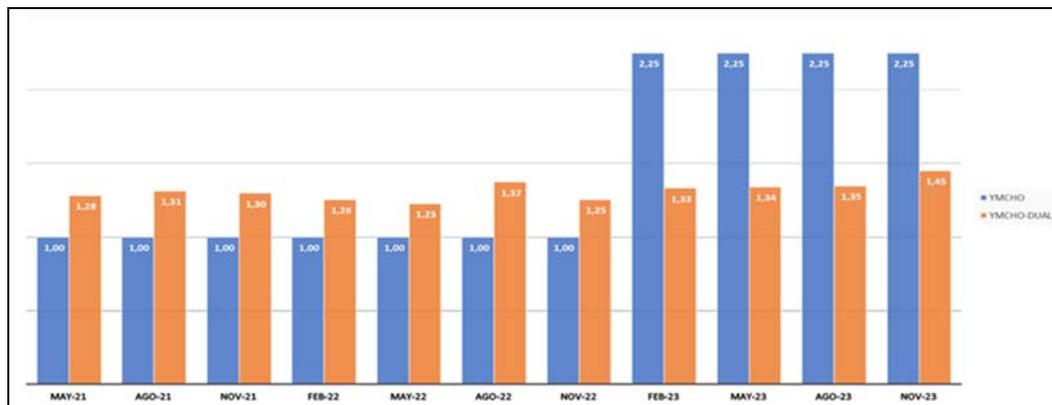
Fuente: Elaboración propia en base a Refinitiv

El pago trimestral de cupón por cada 100 nominales de YMCHO DUAL resulta evidentemente variable tomando la naturaleza de su prospecto. Realizando la proyección del cash flow de la ON modificada, y tomando en consideración su desagregación interna de subyacentes junto con la misma cantidad de nominales que en el caso anterior, se abonaría un total de USD 103.623.232,80. Esta cifra implica un ahorro de USD 10.956.706,72 desde su fecha de emisión, lo que representa el 0,7 % de su flujo de caja informado en el tercer trimestre de 2023 y una reducción de su deuda del 0,1 % para el mismo plazo.

En términos comparados, desde su emisión, YMCHO DUAL reportó una mayor cuantía de cupón hasta fines del año 2022, mientras que para los cupones con vencimiento posterior se verifica un mayor servicio de renta de la ON original, tal como se observa en la ilustración 5.

La rentabilidad variable producto de la evolución de la cesta de commodities y de la tasa interbancaria de Londres ha permitido una estabilidad en torno al cupón a cobrar por parte del inversor y en línea con los prospectos de deuda de empresas en jurisdicciones calificadas como *investment grade*.

Ilustración 5: Flujo de cupones YMCHO vs YMVHO Dual



La emisión de prospectos de deuda de empresas en países con alto riesgo soberano obliga a ofrecer servicios de renta elevados o de tipo step-up. En este último caso, las tasas cupón para los primeros periodos resultan reducidas, por lo que la retención en la cartera de los inversores será posible si el reperfilamiento de deuda optimiza la capacidad de repago del deudor.

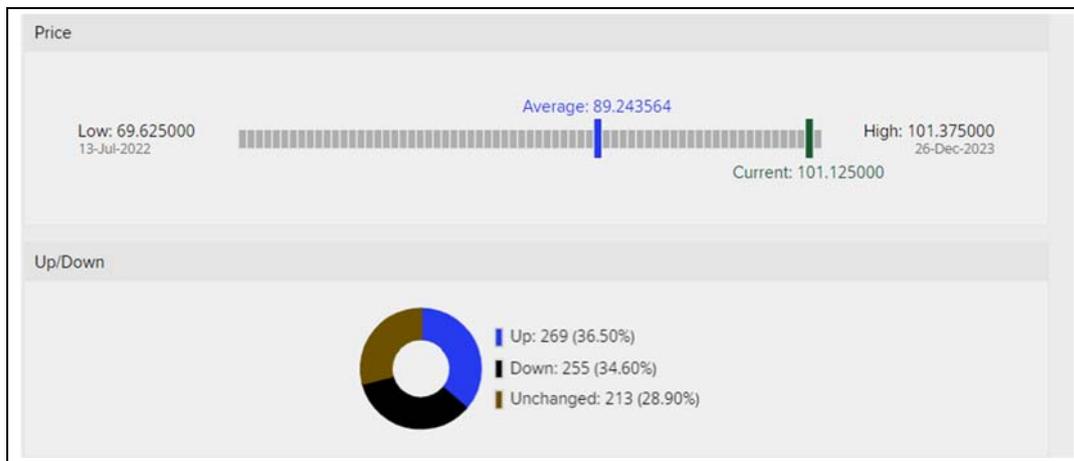
En línea con lo expuesto, la ganancia sobre un instrumento de renta fija puede obtenerse a partir de dos fuentes que se retroalimentan: el pago de cupones periódicos y la variación de precio del valor negociable. En este sentido, la volatilidad en su cotización repercute en las colocaciones futuras y por ende en la tasa implícita del mercado primario y secundario de deuda. Así, el incentivo a captar fondos se traslada a la tasa cupón, toda vez que ésta debe ser lo suficientemente grande para incentivar la captación de fondos.

En efecto, desde su colocación en mercado primario hasta el 31/10/2022, la rentabilidad sobre el precio de mercado alcanzó sólo el 0,75 % en dólares, evidenciando un mercado con poco apetito por el riesgo corporativo y soberano argentino a lo que se suma un cupón retrasado en términos de cuantía nominal. En tanto, para los cupones a vencer desde 2023 y a consecuencia de la suba en el precio de petróleo y cierta tendencia dolarizadora en la cartera de los agentes, se verificó una ganancia del 18,76 %, en línea con la suba de precios de los activos argentinos a fines del 2023.

Durante el periodo 2021-2023, el precio de la ON tuvo su valor más bajo el 13 de julio de 2022 alcanzado los USD 69,62 y su valor máximo el 26 de diciembre de 2023 al tocar los USD 101,37. Dentro de ese intervalo, el 36,5 % de las veces se observaron movimientos alcistas en su cotización, un 34,6 % se verificaron movimientos bajistas mientras que el 28,9 % de las veces el activo estuvo sin cambios.

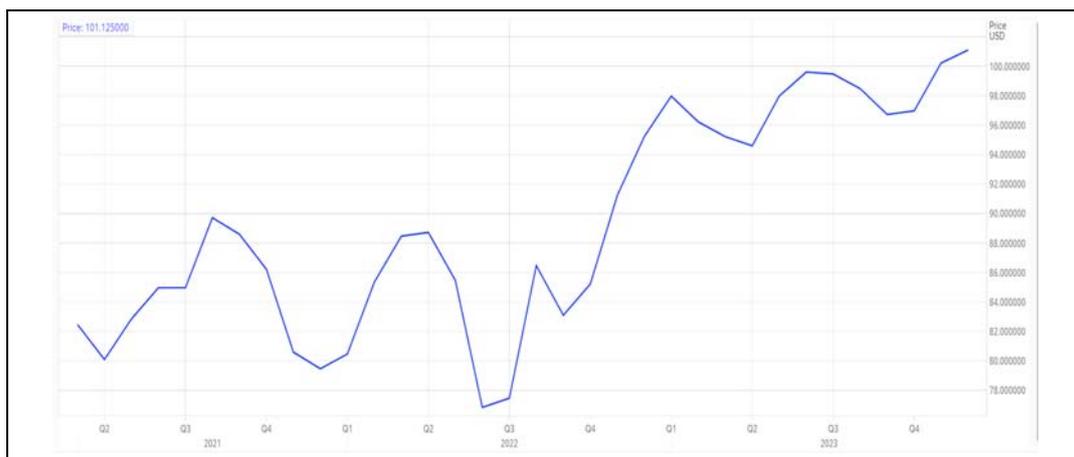
Como se denota, el rezago en la tasa cupón y la jurisdicción del emisor le imprimió fuerte volatilidad al instrumento. En este sentido, los inversores que incorporan en su cartera a YMCHO por el pago de cupón pueden tender a vender el instrumento ante la falta de competitividad de la tasa. Sumado a ello, la fuerte prominencia del riesgo corporativo y soberano puede provocar la captación de nominales por parte de fondos de alto riesgo, adicionando mayor variabilidad en su cotización.

Ilustración 6: Movimientos en la cotización de YMCHO



Fuente: Refinitv consultado 04 de febrero de 2024

Ilustración 7: Cotización YMCHO



Fuente: Refinitv consultado 04 de febrero de 2024

La implementación de una obligación negociable que ajuste la tasa cupón conforme fluctúa los subyacentes de la stablecoins permitirá dotar al instrumento de un mayor atractivo para los tenedores. Al asegurar un piso mínimo y máximo de rentabilidad, la formación de expectativas sobre la rotación de carteras tendrá mayor previsibilidad, contribuyendo a estabilizar la volatilidad implícita y evitar desprendimientos de tenencias que produzcan un desplome del precio.

Para el emisor, la obligación negociable enlazada a su stablecoin le abrirá las puertas a inversores del mundo de criptomonedas ávidos por incursionar en estos instrumentos innovadores. Sin perjuicio de ello, e incluso ante su inexistencia o escasa participación en el global de la emisión, el establecimiento de una tasa variable que esté en línea con los principales drivers de la firma, junto con commodities correlacionados con la actividad económica del soberano y una tasa internacional de referencia logrará comulgar con inversores que busquen diversificar su exposición a la renta fija. Incluso, en caso de lograrse mayor afluencia de ofertas permitirá un descenso de la tasa de corte y/o un mayor monto de captación, marcando un antecedente para

futuras colocaciones. La repitencia permitirá, a futuro, crear curvas de rendimientos de estos instrumentos las cuáles en escenarios más favorables puedan favorecer colocaciones a más largo plazo y mejorar las paridades existentes.

Pruebas de contraste. La imperativa validación de modelos requiere la realización de los contrastes necesarios para verificar la robustez de los resultados obtenidos.

T-Test: Realizado el contraste de significatividad sobre las variables explicativas, se obtienen los resultados que se muestran en tabla 4.

Tabla 4: Contraste de significatividad global

Beta	Name	Logit	Std Error	T-Test
B1	Intercept	0,62321	0,00227	2,74818
I1	Petróleo	-0,73985	0,11965	6,18352
I2	Soja	0,27198	0,02915	9,33108
I3	Trigo	-0,46729	0,09527	4,90489
I4	Girasol	-0,16306	0,06806	2,39583
I5	Libor	-0,12286	0,06446	1,90591

Se verifica que existe evidencia empírica suficiente para rechazar la hipótesis de no significatividad de los regresores.

Test Fisher-Snedecor: representa la distribución de probabilidad continua de una prueba estadística sobre el análisis de la varianza.

$$F = \frac{R^2}{\frac{1-R^2}{n-(k+1)}}$$

Tabla 5: Test Fisher-Snedecor

Test	LOGIT
R Pearson	0,69370
R Adjustment	0,71350
Fisher	0,69048

La prueba de Fisher-Snedecor arroja un valor de 69,37 %, explicando la significatividad de la regresión respecto de la cantidad de parámetros empleados, manteniendo una correlación positiva entre las variables.

Test Durbin Watson: se emplea el contraste a los fines de determinar la existencia de autocorrelación entre los residuos (tabla 6).

$$DWT = 2 \times (1 - P) \times \left(1 - \frac{(Y_{\text{estimated}} - Y_{\text{average}})^2}{(Y - Y_{\text{estimated}})^2}\right)$$

El contraste arroja evidencia de una autocorrelación negativa. El resultado de los residuos tiende a valores que afectan a la variable explicada, por lo que repercute de manera negativa en la autocorrelación de las variables independientes. Debemos considerar que factores externos que tengan un grado de autocorrelación implícita, tales como la guerra, factores climáticos, entre otros, pueden generar una mayor autocorrelación de las variables, por lo que resulta necesario de una mayor experiencia en el tiempo para luego realizar un análisis de cambio estructural en los parámetros de la regresión calculada.

Tabla 6: Test Durbin-Watson

Name	DWT
Petróleo	0,67450
Soja	0,69330
Trigo	0,67410
Girasol	0,69810
Libor	0,69940
General	0,68788

5. Conclusiones

El uso de redes neuronales artificiales (RNA) en el ámbito de las finanzas ofrece tanto beneficios como desafíos. En cuanto a los primeros, pueden capturar patrones complejos y no lineales en conjuntos de datos financieros, dotando de una mayor adaptabilidad a las fluctuaciones de precios en las cotizaciones y las ponderaciones de las variables de control durante el entrenamiento, lo que imprime mayor flexibilidad ante cambios de tendencias. Asimismo, las RNA son capaces de procesar grandes volúmenes de datos de manera eficiente siendo una característica deseada en series de alta frecuencia.

No obstante, el empleo de esta modelización trae desafíos relevantes, como es el caso del sobreajuste. Cuando las RNA se ajustan demasiado a los datos de entrenamiento y no generalizan bien a los nuevos datos, puede llevar a decisiones erróneas, por lo que se requiere de datos de alta calidad y relevantes para producir resultados certeros. Esta es precisamente la justificación por la que a este tipo de modelos se los consideran cajas negras, lo que induce inmediatamente a considerar que el proceso de entendimiento y toma de decisiones puede ser dificultoso y requiere de una metodología transparente, más aún en la administración del perfil de financiamiento.

Con relación a ello, las redes neuronales pueden ser efectivas en el análisis de series tiempo aunque resulta relevante considerar factores como la estacionalidad, la tendencia y posibles shocks exógenos que puedan afectar a la variable modelada. La implementación de un modelo de redes neuronales aplicados a la implementación de una tasa cupón ligada a una obligación negociable presenta diversas ventajas y oportunidades en el ámbito financiero.

Este enfoque innovador permite una diversificación selectiva, en tanto amplía las opciones de inversión brindando una herramienta diversificada vinculada a la economía real que esté correlacionada con el ciclo económico pero que a la vez asegure bandas mínimas y máximas de rentabilidad. Paralelamente, la propuesta descripta posibilita una gestión de riesgos mejorada, en virtud que el instrumento posee la capacidad de anticipar y gestionar riesgos asociados con la volatilidad de los commodities y tasas de interés, contribuyendo a la mitigación de eventos no deseados y redundando en un ahorro significativo para las empresas emisoras e inversores al permitir la utilización más eficiente de recursos.

Por otro lado, futuras contribuciones a este trabajo pueden explorar la implementación de elementos de stop loss en los modelos de redes neuronales para la predicción de la rentabilidad de bonos duales de manera de limitar las pérdidas en situaciones de alta volatilidad y asegurar que la tasa variable no genere un sobreendeudamiento innecesario.

La integración de stop loss en modelos de redes neuronales para bonos duales no solo es una medida de protección, sino también una estrategia para optimizar el rendimiento y garantizar que la tasa variable del bono esté acorde con las condiciones del mercado. Esta adaptabilidad dinámica es esencial para crear instrumentos financieros que respondan eficientemente a las complejidades del entorno económico, al tiempo que se evita un endeudamiento excesivo y se garantiza la sostenibilidad financiera a largo plazo. En última instancia, estos mecanismos de control de riesgos contribuyen a la creación de instrumentos financieros más robustos y resilientes.

En resumen, la implementación de modelos de redes neuronales en la predicción de la rentabilidad de bonos duales no solo proporciona beneficios financieros concretos, sino que también abre la puerta a nuevas formas de instrumentos financieros más sostenibles y eficientes. Este enfoque tiene el potencial de transformar la emisión de bonos y la gestión de riesgos, promoviendo un sistema financiero más estable y confiable.

REFERENCIAS

- Beck, M. W. (2020). *NeuralNetTools R Package*. <https://fawda123.github.io/NeuralNetTools/articles/Overview.html>
- Bolsas y Mercados Argentinos. (04 de Febrero de 2024). Obtenido de BYMA: www.byma.com.ar
- Blockchain, bitcoin y criptomonedas: Bases conceptuales y aplicaciones prácticas*. (2018). ACCID.
- Hull, J. (2009). *Introducción a los mercados de futuros y opciones*, 6ª Ed. Pearson Educación.
- Rokach, L. & Maimon, O. (2008). *Data mining with decision trees: Theory and applications*. World Scientific.
- Russell, R. (2018). *Redes neuronales: Guía sencilla de redes neuronales artificiales*. CreateSpace Independent Publishing Platform.
- Wickham, H. & Grolemund, G. (2017). *R for data science: Import, tidy, transform, visualize, and model data*. O'Reilly.
- Wright, M. N. (2022). *Package NeuralNet*. <https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>