

Pruebas de tensión integral como herramienta de política macroprudencial mediante un enfoque de aprendizaje profundo (*deep learning*) *

Patricia Aranda Blanco
Boris Alfredo Luna Acevedo

RESUMEN

Las pruebas de estrés en sistemas bancarios son esenciales para evaluar la capacidad de las entidades de intermediación financiera de resistir situaciones extremas y garantizar la estabilidad del sistema financiero. Este trabajo explora un nuevo método de estimación para la prueba de tensión mediante modelos de aprendizaje de redes neuronales profundas aplicados al sistema financiero boliviano. Utilizando un enfoque basado en datos históricos y simulaciones, se desarrollan modelos predictivos que permiten analizar los efectos de condiciones económicas adversas en la solvencia bancaria. Se presenta una metodología para integrar el análisis de estrés dinámico con redes neuronales profundas, conocida como *Deep-Stress*, que mejora la precisión de los resultados en comparación con métodos tradicionales. Los resultados obtenidos proporcionan una herramienta robusta para la toma de decisiones estratégicas y la gestión del riesgo en entornos bancarios complejos.

Clasificación JEL: G10, G21 y G32

Palabras claves: Pruebas de tensión, *deep learning*, redes neuronales y riesgos integrados

* El contenido del presente documento es de responsabilidad de los autores y no compromete la opinión del Banco Central de Bolivia.

Comprehensive stress testing as a macroprudential policy tool using a deep learning approach

Patricia Aranda Blanco
Boris Alfredo Luna Acevedo

ABSTRACT

Stress testing in banking systems is essential for assessing the ability of financial intermediaries to withstand extreme situations and ensure the stability of the financial system. This paper explores a new estimation method for stress testing using deep neural network learning models applied to the Bolivian financial system. Using an approach based on historical data and simulations, predictive models are developed to analyze the effects of adverse economic conditions on bank solvency. A methodology for integrating dynamic stress analysis with deep neural networks, known as Deep-Stress, is presented, which improves the accuracy of the results compared to traditional methods. The results provide a robust tool for strategic decision-making and risk management in complex banking environments.

JEL Classification: *G10, G21 y G32*

Keywords: *Stress testing, deep learning, neural networks, and integrated risks*

* The content of this document is the responsibility of the authors and does not represent the opinion of the Central Bank of Bolivia.

I. Introducción

De manera general, la estabilidad financiera es un componente esencial en el crecimiento y funcionamiento de la economía. La crisis financiera de 2007 generó quiebras y el deterioro patrimonial de varias instituciones financieras, lo que implicó la intervención del Estado con programas de salvataje y un elevado costo social e impacto negativo para el sector real de la economía.

Una oportuna detección de fragilidad financiera de las entidades bancarias permite implementar medidas correctivas necesarias para la restauración de la solidez y evitar potenciales pérdidas, por lo que es una prioridad para las entidades rectoras y reguladoras, más aún, si la probabilidad de contagio entre bancos es alta.

En esta línea, volvió a tomar relevancia el análisis de las pruebas de tensión o de estrés (*tension testing*), en un contexto de riesgos financieros y desempeño económico. Particularmente, el Fondo Monetario Internacional (FMI) ha ido desarrollando este tipo de modelos, considerándolo como una herramienta clave para evaluar la solidez y resiliencia de un sistema financiero en un país, frente a escenarios adversos. En particular, el FMI utiliza las pruebas de tensión como parte de su evaluación de la estabilidad financiera en países miembros, mediante el Programa de Evaluación del Sector Financiero (FSAP, por sus siglas en inglés), permitiendo analizar la relación entre la calidad de activos de las entidades financieras y el entorno macroeconómico.

Conceptualmente, según el Oura y Schumacher (2012) el *stress testing* es una técnica que mide la vulnerabilidad de una cartera, una institución o todo un sistema de entidades financieras bajo diferentes eventos o escenarios hipotéticos. Es un ejercicio cuantitativo de “que pasaría si”, con el capital, las ganancias, los flujos de efectivos, etc., si ciertos riesgos se materializarían.

Según la guía de *stress testing* de Ong (2014), una prueba de tensión suele evaluar dos aspectos del desempeño de las entidades financieras: la prueba de solvencia y la de liquidez. La prueba de solvencia, se centra en la solidez del balance general de la entidad para cumplir con sus obligaciones financieras en escenarios adversos, evaluando si dispone

de capital suficiente para absorber pérdidas potenciales y continuar operando, sin comprometer su capital mínimo.

La prueba de liquidez, mide la capacidad de la entidad financiera de cumplir con sus obligaciones de corto plazo en escenarios adversos. Se busca determinar si la entidad tiene suficientes recursos líquidos (o activos fáciles de convertir en efectivo) para enfrentar retiros de depósitos, pagos a proveedores y otras demandas de efectivo en situaciones de estrés financiero, es decir, se evalúa la suficiencia de los activos líquidos de la entidad para cubrir las salidas de fondos en escenarios de alta demanda de efectivo.

Considerando que la solvencia es un elemento clave para garantizar la estabilidad financiera, ya que asegura que las entidades financieras puedan cumplir con sus obligaciones a largo plazo, incluso en condiciones adversas, su evaluación adquiere especial relevancia. En el caso boliviano, la solvencia no solo es fundamental desde una perspectiva prudencial, sino que también constituye un requisito legal indispensable para el funcionamiento de las entidades financieras. Por ello, en este documento se evaluará la resistencia del indicador de solvencia bajo un contexto de estrés.

En este marco, cada tipo de prueba de estrés aporta una perspectiva específica para analizar la resiliencia de las instituciones y del sistema financiero en su conjunto. Combinando estos tipos de pruebas, el FMI busca proporcionar una evaluación integral que permita a los reguladores y a las propias instituciones financieras anticipar y mitigar el impacto de crisis potenciales, asegurando así la estabilidad financiera.

Aunque gran parte de la literatura se enfoca en analizar un tipo de riesgo específico de forma aislada, este trabajo presenta una prueba de tensión integral que considera simultáneamente tres tipos de riesgo: crédito, liquidez y mercado. Este enfoque tiene como objetivo proporcionar una visión más completa y precisa sobre la resiliencia del sistema financiero.

Este tipo de pruebas demanda una herramienta econométrica avanzada, sin embargo, la econometría clásica presenta ciertas restricciones, por lo que fue necesario la búsqueda de métodos alternativos, como el aprendizaje autónomo y/o el *deep learning*, que permita establecer

modelos no lineales, principalmente, porque las relaciones entre variables en un contexto financiero y de riesgos están interconectados y estos efectos de contagio son difíciles capturar con métodos econométricos tradicionales.

En línea con la metodología del FMI, se plantea dos escenarios: a) escenario base, examina las condiciones normales del mercado y proyecta ganancias y pérdidas; b) escenario estresado, que simula situaciones extremas que podrían perturbar el sistema financiero como una recesión económica profunda, una crisis financiera global, o un colapso en los precios de los activos.

En este sentido, el trabajo se enfocará en realizar una prueba de solvencia, evaluando la resistencia del sistema bancario boliviano en un escenario estresado de las variables macroeconómicas, a través de un nuevo método de estimación denominado de aprendizaje profundo. En primera instancia se hará una revisión de la literatura y las principales características de este tipo de modelos, luego se presentará el planteamiento del modelo con la selección de variables y el desarrollo del modelo como tal, con la exposición de resultados, validación y posteriormente los resultados.

II. Revisión de la literatura

En el marco del nuevo acuerdo de Basilea III, las pruebas de estrés se han consolidado como un componente esencial para evaluar la capacidad de los bancos de absorber pérdidas y mantener su estabilidad ante situaciones extremas. Estas pruebas, alineadas con los requisitos de capital y liquidez establecidos por Basilea, aseguran que las instituciones bancarias cuenten con la fortaleza necesaria para enfrentar crisis, contribuyendo así a la estabilidad del sistema financiero global.

Desde una perspectiva teórica, las pruebas de estrés tienen como base los principios de gestión de riesgos financieros, donde se evalúa la exposición a riesgos externos poco probables y se relaciona también con la teoría de la estabilidad financiera sistémica que pretende prevenir efectos negativos en las entidades financieras o en el sistema en su conjunto.

Danielsson *et al.* (2001), explican que los modelos tradicionales subestiman los riesgos sistémicos por un enfoque individualista, sin

considerar las interacciones entre ellas. Sin embargo, si a las pruebas de estrés se incorporan externalidades, interconexiones y mecanismos de contagio, estas pueden ofrecer una perspectiva más integral del sistema financiero.

En los últimos años, las pruebas de estrés tomaron relevancia y han sido debatidas ampliamente. Čihák (2004) realizó una revisión de la literatura y los métodos cuantitativos con que se puede medir las vulnerabilidades del sistema financiero, identificando elementos clave para el diseño de escenarios específicos que reflejan con precisión las dinámicas del sistema financiero.

Según el Banco Central de Europa (BCE), las pruebas de estrés son procesos de evaluación que miden la resistencia, principalmente de los bancos, ante escenarios adversos, permitiendo determinar su capacidad para soportar crisis financieras o económicas severas sin comprometer su solvencia, estabilidad y capacidad de operación. En línea con el FMI, el BCE examina la solidez de los balances bancarios, evaluando el impacto en términos capital y liquidez, determinando como objetivos del ejercicio: evaluar la capacidad de absorción de pérdidas de las entidades bancarias; identificar los bancos que podrían necesitar más capital o ajustes al modelo de negocio; guiar decisiones regulatorias y de supervisión, relacionadas con la constitución de capital adicional o alguna implementación de medidas de contingencia; y aumentar la transparencia del sector para fortalecer la confianza del público y los inversionistas del sistema financiero.

Para llevar a cabo pruebas de estrés, se recurre a una amplia variedad de modelos cuantitativos, que suelen ser complejos y altamente demandantes en términos de información. Si bien estas herramientas permiten entender y gestionar los riesgos financieros, es fundamental complementarlas con análisis cualitativos y otras metodologías para obtener una visión integral de los posibles efectos sobre el sistema financiero. Entre los enfoques utilizados, destacan los modelos basados en simulaciones, los cuales permiten estimar probabilidades de incumplimiento y evaluar el impacto de choques económicos sobre los balances de las entidades. Estos modelos se pueden clasificar en tres tipos: i) modelos históricos, que replican eventos pasados que afectaron al sistema financiero; ii) modelos hipotéticos, que simulan escenarios extremos pero plausibles para analizar la respuesta del sistema ante situaciones inesperadas; y iii)

modelos de sensibilidad, que evalúan el efecto de variaciones drásticas en un único factor de riesgo sobre las instituciones financieras.

Uribe *et al.* (2008), estudiaron la resiliencia del sistema bancario colombiano frente a escenarios de estrés económico, simulando diversos factores adversos que podrían afectar la estabilidad del sistema bancario de Colombia. Con la metodología planteada por Čihák, evaluaron la resiliencia del sistema bancario colombiano ante diversos choques económicos simultáneos, identificando factores de riesgos individuales como el riesgo de crédito, tasa de interés, tipo de cambio, liquidez y contagio interbancario y el desarrollo de escenarios conjuntos, con *shocks* simultáneos en los diferentes factores de riesgo identificados. Con la ayuda de modelos econométricos como vectores autorregresivos, lograron capturar las interrelaciones dinámicas entre variables econométricas y financieras, lo que permitió simular choques en variables macroeconómicas y evaluaron sus efectos en el sistema bancario en el largo plazo.

Pérez y Trucharte (2011) abordaron la evolución de las pruebas de estrés tras la crisis financiera de 2007, resaltando la necesidad de integrar múltiples modelos y herramientas para reflejar con mayor precisión los riesgos emergentes. Desde otra perspectiva, Chafik *et al.* (2022) emplearon un modelo DSGE para analizar políticas macroprudenciales en Marruecos, incluyendo la interacción entre bancos, hogares y empresas, demostrando su utilidad en la formulación de políticas orientadas a mitigar riesgos sistémicos.

Desde otro enfoque, a través de un modelo de Equilibrio General Dinámico y Estocástico (DSGE), Chafik *et al.* (2022), presentaron un análisis de la política macroprudencial en Marruecos, incluyendo el comportamiento de los bancos, hogares y empresas, y su interrelación en la economía real y su efecto en la estabilidad financiera, proporcionando una herramienta valiosa para la formulación y evaluación de políticas destinadas a mitigar los riesgos sistémicos. Si bien existe una amplia literatura sobre el desarrollo de los modelos econométricos, estos presentan muchas limitaciones frente a modelos más avanzados y métodos de *machine learning* como el *deep learning*, principalmente en el contexto de pruebas de estrés financiero. Entre las principales limitaciones, se identifican la relación lineal que existe entre las variables, lo que no permite la captura compleja y no lineal en los mercados financieros, ya que los supuestos de los modelos son muy

rígidos sobre la distribución de errores y otras propiedades estadísticas que pueden no cumplirse en condiciones de estrés, restringiendo su capacidad para adaptarse a cambios en las condiciones de mercado.

Las pruebas de estrés en el ámbito financiero se utilizan para evaluar la resiliencia de un sistema bancario ante situaciones extremas. Los modelos econométricos y los modelos de aprendizaje profundo (*deep learning*) son dos enfoques diferentes para realizar estas pruebas, y cada uno tiene sus propias ventajas y limitaciones.

Gai y Kapadia (2010) destacaron las interacciones no lineales y los efectos de retroalimentación entre los participantes del sistema financiero, analizando cómo estas características afectan la estabilidad sistémica y se pierden en modelos lineales convencionales, ya que los modelos econométricos como los ARIMA asumen una relación lineal entre las variables de entrada y las variables de salida y suelen tratar los riesgos como independientes y de forma aislada, sin capturar las interacciones entre las instituciones y los mercados financieros, por lo que es necesario implementar modelos de correlación dinámica que permitan comprender el contagio financiero y su impacto simultáneo. En cambio, los modelos *deep learning* son más efectivos para capturar relaciones no lineales complejas, útil en el contexto de las pruebas de estrés. Estos modelos pueden capturar interacciones complejas entre diferentes variables (por ejemplo, variables macroeconómicas, tasas de interés y variables del balance de los bancos) sin la necesidad de especificar explícitamente estas relaciones (Lecun *et al.*, 2015).

Varian (2014) revisó los desafíos de los métodos econométricos tradicionales que luchan con la dimensionalidad y el manejo de los grandes volúmenes de datos, reduciéndose a una selección cuidadosa de variables y limitando la capacidad predictiva de dichos modelos, sugiriendo nuevas herramientas como *machine learning* para superar estas barreras. Los modelos de aprendizaje profundo son más flexibles, ya que pueden aprender automáticamente representaciones complejas de los datos.

Considerando que los modelos econométricos tradicionales presentan limitaciones en pruebas de estrés financieras, se han ido desarrollando enfoques y herramientas más avanzadas, como *machine learning* y

deep learning, teoría de redes y análisis de valores extremos, que buscan complementar o reemplazarlos cuando se compromete la precisión de las evaluaciones de riesgo y la identificación de vulnerabilidades sistémicas.

En esta línea, Petropoulos *et al.* (2019) propusieron un modelo con técnicas de aprendizaje profundo para las pruebas de estrés en balances financieros, denominado *deep stress*, que permitió simular de manera más precisa y eficiente los escenarios adversos en el balance de las instituciones financieras, capturando interacciones complejas entre variables financieras y macroeconómicas, reflejando decisiones de gestión y cambios en el entorno económico.

Por su parte, Chronopoulos *et al.* (2023) exploró la aplicación de redes neuronales profundas en modelos de datos de panel, ofreciendo una alternativa a los métodos econométricos tradicionales para capturar relaciones no lineales complejas en modelos de datos de panel, principalmente en la estimación del promedio condicional, con una mayor comprensión de los procesos subyacentes, principalmente en la estimación del pronóstico, no solo en la economía sino en otras ramas.

En el trabajo de Huang y Cho (2020) se realizó una revisión general de las diversas técnicas de aprendizaje profundo en el sector financiero y bancario utilizados para la clasificación, predicción y regresión de datos financieros para series temporales, que sean capaces de capturar dependencias de largo plazo en secuencias de datos muy comunes en mercados financieros.

Tsaryk (2020) destacó la capacidad de los modelos de aprendizaje profundo para manejar grandes volúmenes de datos y detectar patrones complejos en los estados financieros de los bancos, mejorando así la precisión de las pruebas de estrés ante escenarios adversos, en la evaluación de la solidez financiera de las instituciones bancarias.

III. Metodología

III.1. Modelo de deep learning

La técnica de *deep learning* (redes neuronales profundas), es un conjunto de algoritmos que forma parte del aprendizaje automático, cuyo propósito

es la simulación de datos que funcionan en base a un proceso de capas, denominadas neuronas, para modelar y entender patrones complejos en grandes volúmenes de información.

Este tipo de algoritmos, están inspirados en el funcionamiento de un cerebro biológico, al simular la interconexión de neuronas en múltiples capas que le permite aprender representaciones jerárquicas, que se distingue de una red neuronal simple porque son caracterizados por una arquitectura de múltiples capas y comprenden dos o más capas ocultas¹.

El entrenamiento en este tipo de modelos tiene dos pasos principales: 1) la propagación hacia adelante, donde los datos se introducen a la red y los cálculos se realizan capa por capa para producir una salida que se compara con la salida deseada y se calcula una señal de error; 2) la retropropagación, paso crucial, que consiste en ampliar la señal de error hacia atrás a través del error de la red, ajustado por parámetros de la red (pesos y sesgos) para minimizar el error.

Este tipo de entrenamiento interactivo de propagación y retropropagación, es apoyado por algoritmos de optimización que permite a las redes neuronales profundas aprender y mejorar su rendimiento en el tiempo.

Los procesos de múltiples capas permiten mapear funciones complejas no lineales. Su aplicación ha ganado relevancia en diferentes disciplinas de la ciencia, en particular, en el ámbito financiero debido a la creciente disponibilidad de datos y a la necesidad de herramientas avanzadas para procesarlos y analizar grandes volúmenes de información estadística y extraer patrones financieros².

1 Siguiendo a Elhoseny et al. (2022), la primera distinción entre la red neuronal clásica y deep neuronal es el número de capas ocultas y el procedimiento de entrenamiento.

2 Por su parte Tsaryk (2020) explora la aplicación de técnicas avanzadas de inteligencia artificial para abordar problemas financieros que enfrentan los bancos y las autoridades regulatorias. El trabajo se centra en cómo las redes neuronales artificiales (ANNs) y el *deep learning* pueden mejorar las pruebas de estrés en sistemas bancarios, especialmente en la evaluación de la resiliencia de estos sistemas ante choques adversos y en la identificación de las principales fuentes de riesgo. Tsaryk argumenta que muchos problemas financieros reales exhiben comportamientos no lineales que son difíciles de capturar con herramientas estadísticas tradicionales. Por ello, propone la implementación de ANNs para abordar estas no linealidades.

Siguiendo a Elhoseny *et al.* (2022), el modelo *deep learning* utiliza redes neuronales para procesar datos complejos y realizar análisis predictivos, según las siguientes definiciones:

Paso 1: Función de propagación

Etapas inicial en el entrenamiento donde los datos se introducen a la red y los cálculos se realizan capa por capa para producir una salida que se compara con la salida deseada y se calcula una señal de error.

1. Cálculo de la entrada ponderada, este cálculo es fundamental en cada neurona de la red, ya que permite combinar las entradas de forma ponderada antes de aplicar una función de activación. Se define como:

$$z_j = \sum_{i=1}^n W_{kj} a_i + \beta_j \quad (1)$$

donde:

z_j : Es el valor que genera la neurona j como resultado de las entradas ponderadas y su sesgo. El valor puede ser procesado por una función de activación en etapas posteriores.

$\sum_{i=1}^n$: Representa la suma de las contribuciones de todas las neuronas en la capa anterior (n entradas).

W_{kj} : Es el peso que conecta la entrada k de la capa previa con la neurona j en la capa actual. El peso determina la influencia de cada entrada en el resultado z .

a_i : Es la a -ésima entrada o activación proveniente de una capa anterior o de los datos de entrada iniciales si es la primera capa.

β_j : Ayuda a gestionar la salida del nodo.

2. Función sigmoide, función de activación más común. Permite introducir la no linealidad en el modelo y transformar el valor de entrada en (z_j) valor de salida con un rango de (0,1). Se multiplica por los pesos de cada conexión y se aplica una función de activación. Siendo útil para problemas de clasificación binaria o normalización de valores en redes neuronales.

La sigmoide transforma la función de la siguiente manera:

$$f_j(x) = \frac{1}{1+e^{-z_j}} \quad (2)$$

3. Para la salida de una neurona o el **resultado final** de una capa de la red se calcula la siguiente ecuación:

$$\hat{y}_k = \sum_{i=1}^m W_{ki} f_i + \beta_k \quad (3)$$

donde:

\hat{y}_k : Es la k -ésima neurona en la capa actual, es el resultado antes de aplicar cualquier función de activación o transformación final.

W_{kj} : Es el peso asociado a la conexión entre el nodo j en la capa previa y el nodo k en la capa actual.

f_i : Representa la activación de la i -ésima neurona en la capa interior. Usualmente es el resultado de aplicar una función de activación como ReLU, sigmoide o Tanh sobre la suma ponderada de entradas en la capa anterior.

β_k : Es el sesgo de la k -ésima neurona. Proporciona un valor adicional que ayuda a ajustar la salida del nodo, permitiendo que el modelo sea más flexible al capturar patrones complejos.

A partir de la ecuación, se obtiene una salida preliminar que se compara con la salida real para calcular el error.

Paso 2: Retropropagación

La función **de la retropropagación** es el proceso que permite a las redes neuronales ajustar los pesos (W) y los sesgos (β) minimizando el error de las predicciones \hat{y} y las salidas reales y . Este ajuste se realiza mediante el cálculo del gradiente³ de la función de pérdida y su propagación. Para el efecto, se utilizan las siguientes formulas:

a) Función de pérdida

Mide el error entre las salidas reales y las predichas por la red. Un ejemplo común es el Error Cuadrático Medio (MSE)

3 El **gradiente** es un vector que contiene las derivadas parciales de una función de pérdida con respecto a los parámetros del modelo (por ejemplo, los pesos y sesgos de las redes neuronales). Este gradiente indica cómo cambiar los parámetros para minimizar la función de pérdida y mejorar el rendimiento del modelo en una tarea específica.

$$E = \frac{1}{2} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (4)$$

donde:

y_k : Salida real para la k -ésima entrada.

\hat{y}_k : Salida predicha por la red para la k -ésima entrada.

n : Número total de ejempls.

b) Gradiente del error respecto de los pesos y sesgos

Es el vector que contiene las derivadas parciales de una función de pérdida. Este gradiente indica cómo cambiar los parámetros para minimizar la función de pérdida y mejorar el rendimiento del modelo en una tarea específica respecto de los pesos y sesgos. Así, respecto de los pesos W_{ij} , que tiene por objetivo el ajustar los pesos minimizando la función de pérdida. El gradiente respecto a un peso específico W_{ij} es:

$$\frac{\partial E}{\partial W_{ij}} = \delta_j a_i \quad (5)$$

δ_j : Error de la neurona j de la capa actual

a_i : Activación de la neurona i en la capa anterior.

Gradiente respecto al Sesgo, el gradiente respecto al sesgo de la neurona j es:

$$\frac{\partial E}{\partial \beta_j} = \delta_j \quad (6)$$

c) Cálculo del error de las neuronas δ_j

Para la capa de salida, se calcula directamente a partir de la función de pérdida.

$$\delta_j = \frac{\partial E}{\partial z_j} = (y_j - \hat{y}_j) f'(z_j) \quad (7)$$

$z_j = \sum_{i=1}^n W_{ij} a_i + \beta_j$: entrada ponderada a la neurona j

$f'(z_j)$: Derivada de la funcion de activacion en la salida z_j

Para las capas ocultas, el error de las capas ocultas de propaga desde la capa siguiente:

$$\delta_j = f'(z_j) \sum_{k=1}^m \delta_k W_{kj} \quad (8)$$

m : Número de neuronas en la capa siguiente.

δ_k : Error de las neuronas en la capa siguiente

W_{kj} : Pesos que conectan las neuronas de la capa actual con la capa siguiente.

d) Actualización de los pesos y sesgos

Los pesos y sesgos se actualizan utilizando el método del descenso del gradiente:

$$W_{ij} = W_{ij} - \eta \frac{\partial E}{\partial W_{ij}} \quad (9)$$

$$\beta_{ij} = \beta_{ij} - \eta \frac{\partial E}{\partial \beta_{ij}} \quad (10)$$

η : Tasa de aprendizaje

$\frac{\partial E}{\partial W_{ij}}$: Gradiente del error respecto al peso

$\frac{\partial E}{\partial \beta_{ij}}$: Gradiente del error respecto al sesgo

El modelo realiza el proceso completo en varias iteraciones en cuatro pasos:

1. **Propagacion hacia adelante:** Se calcula las salidas de todas las capas mediante

$$z_j = \sum_{i=1}^n W_{kj} a_i + \beta_j, \quad a_j = f(z_j) \quad (11)$$

2. **Cálculo del Error en la Capa de Salida:** Usa la función de pérdida para calcular δ_j .
3. **Propagación hacia atrás:** Calcula los errores (δ_j) para cada capa de manera iterativa, desde la capa de salida hasta la primera capa oculta.
4. **Actualización de parámetros:** Se ajusta W_{kj} y β_j utilizando las formulas del gradiente descendente.

IV. Aplicación del modelo *deep learning*

Considerando que la tarea es realizar una prueba de tensión integral, el objetivo de la utilización de la *deep learning* es aprovechar la capacidad

del modelo para realizar relaciones complejas y no lineales entre tres tipos de riesgos y evaluar simultáneamente el impacto combinado de escenarios en el sistema financiero boliviano.

IV.1. Datos y fuentes

La base de datos contiene 1.041 observaciones en un panel de datos de 13 bancos en un periodo de marzo de 2005 hasta diciembre de 2023 con una periodicidad trimestral. La fuente de información para las variables financieras proviene de la Autoridad de Supervisión del Sistema Financiero (ASFI) y el Banco Central de Bolivia (BCB), mientras que para las variables macroeconómicas se utiliza el Instituto Nacional de Estadística (INE). Los datos están aglutinados en 38 variables financieras y 5 variables macroeconómicas (ver Apéndice A).

Cabe destacar que el panel de datos utilizado es balanceado, es decir, cada entidad bancaria cuenta con observaciones completas y continuas para todos los periodos del análisis. Esta característica resulta fundamental para la aplicación de modelos de *deep learning*, en particular, aquellos diseñados para capturar patrones temporales como las redes neuronales recurrentes (RNN) y las LSTM (*Long Short-Term Memory*). Contar con un panel balanceado asegura una estructura homogénea en las secuencias de entrada, mejora la estabilidad del entrenamiento, reduce la necesidad de imputación de datos faltantes, y permite una comparación consistente entre las distintas entidades financieras a lo largo del tiempo.

Normalización de datos

Previo a la estimación mediante un modelo de *deep learning*, los datos reciben un tratamiento de normalización que forma parte del proceso de modelación. Esta normalización se debe realizar dentro de un rango uniforme con la finalidad de prevenir que los números/valores grandes anulen números/valores pequeños y evitar una saturación prematura de las capas ocultas con una consecuencia en la tasa de aprendizaje más lenta, considerando que los números del mundo real no son uniformes y están distribuidos sobre un rango demasiado diferente.

Siguiendo a Tsaryk (2020) y Basheer y Hajmeer (2000), la normalización de datos consiste en un vector de variables de entrada y variables de salida z_i en un intervalo $[\lambda_1, \lambda_2]$ que corresponde al rango de la función de activación.

$$x_1 = \lambda_1 + (\lambda_2 - \lambda_1) \left(\frac{z_i + z_i^{\min}}{z_i^{\max} - z_i^{\min}} \right) \quad (12)$$

donde x_i es el valor escalado de z_i , z_i^{\max} y z_i^{\min} representan valores máximo y mínimo del vector z_i en la base de datos.

IV.2. Selección de variables

Como parte de la selección de variables, se presenta un análisis de las variables que serán utilizadas como entrada para entrenar una red neuronal, reflejando las variables que pueden influir en los riesgos analizados (riesgo de crédito, liquidez y mercado) con el objeto que el modelo capture las interacciones y dependencias relevantes entre ellos.

Se realizó un ejercicio que tiene por objeto validar las variables que se utilizarán y que capturen los riesgos de crédito, liquidez y mercado, empleando el modelo de clasificación denominado "árbol de decisión" que se volvió recurrente en temas financieros, ya que permiten optimizar la toma de decisiones⁴ principalmente en situaciones de incertidumbre.

4 Según Berlanga et al. (2013), los árboles de decisión son una herramienta analítica que permite, en primer lugar, expresar de forma gráfica y, posteriormente, bajo una esquematización matemática, los diferentes caminos, variables, causas y efectos que pueden materializarse como resultado de las acciones de los individuos involucrados. Esto es especialmente relevante bajo condiciones de incertidumbre y riesgo donde, en cada fase, convergen elementos estocásticos o aleatorios, representados en términos de probabilidades. Este tipo de clasificación de variables se basa en la teoría de juegos y ofrece varias ventajas:

- i) **Facilidad de interpretación:** generan reglas claras que permiten entender cómo y por qué una variable es clasificada como relevante.
- ii) **Efectividad en entornos mixtos:** funcionan bien en entornos donde los datos son una mezcla de variables categóricas y continuas.
- iii) **Ajustabilidad:** pueden ajustarse con estrategias como asignación de pesos por clase o poda de nodos.
- iv) **Aplicabilidad en riesgos financieros:** son útiles para distintos tipos de análisis de riesgos financieros.

Estos modelos permiten dividir los datos en subconjuntos más homogéneos y tomar decisiones informadas basadas en las variables disponibles.

Árbol de decisión simple (ajustado): Un árbol de decisión ajustado emplea un proceso de división recursiva basado en algún criterio de optimización, como la entropía o la impureza de Gini. El modelo se ajusta seleccionando, para cada división, la característica que mejor segmenta los datos. Este ajuste puede implicar la reducción de la complejidad del árbol a través de la poda, eliminando ramas que no contribuyen significativamente al rendimiento del modelo. La poda ayuda a prevenir el sobreajuste (overfitting) y mejora la capacidad de generalización.

Árbol de Decisión con Validación Cruzada: El árbol de decisión con validación cruzada, también conocido como validación cruzada de k-fold, implica dividir los datos en varias particiones (por ejemplo, 10 particiones en un esquema de validación cruzada de 10-fold) y luego entrenar y evaluar el árbol de decisión en diferentes subconjuntos de datos. Este enfoque permite evaluar el rendimiento del modelo de manera más robusta y mitigar el riesgo de sobreajuste, proporcionando una medida más confiable de la capacidad de generalización del modelo.

Este tipo de modelo se ha consolidado como herramienta útil en la gestión de riesgos financieros, debido a su capacidad para identificar patrones, clasificar eventos, y predecir resultados relacionados con el riesgo.

En este contexto, se elaboró un árbol de decisión por tipo de riesgo y fue diseñado para clasificar las variables objetivo y relevantes que explican los tres tipos de riesgo que se describen a continuación, de un conjunto de variables predictivas que sugiere la literatura⁵, que muestran la jerarquía de las variables para cada tipo de riesgo, lo que permitirá entender de mejor manera las predicciones que se podrían realizar.

Determinación de datos de ensayo y predicción en un árbol de decisión

El proceso para construir y validar un árbol de decisión implica dos etapas clave:

i) División de los datos

- Los datos se dividen en conjuntos de entrenamiento y prueba (*test*), típicamente en proporciones como 80%-20%, equivalente al periodo de diciembre de 2020.
- El conjunto de entrenamiento se utiliza para ajustar el árbol, determinando las reglas y divisiones óptimas a través del método simple, ajustado y de validación cruzada, para riesgo de crédito, mercado y liquidez.
- El conjunto de prueba se reserva para evaluar el desempeño del árbol con datos no vistos, lo que permite medir su capacidad de generalización.

ii) Predicción y evaluación

- Una vez ajustado, el árbol predice el resultado para los datos del conjunto de prueba.
- Los resultados predichos se comparan con los valores reales utilizando métricas como precisión, sensibilidad o el error promedio.

⁵ Al no ser el objetivo de este trabajo determinar las variables más relevantes por riesgo, se presenta el árbol de decisiones de manera general, pudiendo mejorar los resultados con otros modelos, para otro tipo de trabajo como determinantes de los riesgos financieros.

iii) Determinación de las variables objetivo para el riesgo de crédito, de mercado y de liquidez

Se tienen tres variables objetivo que buscan predecir o explicar los riesgos de crédito, mercado y liquidez, apoyados en la literatura y el criterio experto. Estas son: índice de mora, diferencial *spread*, y cobertura de corto plazo.

Estas variables se transforman en variables categóricas de 0 y 1 con los siguientes umbrales (en todos los casos las variables tratadas son balanceadas):

Cuadro 1: VARIABLES Y UMBRALES POR TIPO DE RIESGOS

Riesgo	Variable	Umbral	Justificación
Riesgo de Crédito	Índice de Mora (IM)	3,60%	Promedio de países
Riesgo de Mercado	Spread	0,1166%	Percentil 75
Riesgo de Liquidez	Cobertura de Corto Plazo (ccp)	39,41%	Percentil 75

Fuente: Elaboración propia

iv) Presentación de resultados

Riesgo de crédito. El modelo identifica las variables más relevantes que influyen en la clasificación, a partir de un árbol de decisión de validación cruzada. Entre las principales se encuentran: mora, variación de ingresos financieros, cobertura de previsiones, y pueden servir de guía para elegir las variables que se pueden incluir en el modelo de aprendizaje profundo. Las métricas de validación tienen un excelente rendimiento en términos generales de 95,86%, especialmente cuando el IM es menor a 3,6%.

**Cuadro 2: VARIABLES PRINCIPALES PARA LA PREDICCIÓN
 Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE CRÉDITO**

	precisión	recall	f1-score	support
0	0,96	0,99	0,98	148
1	0,94	0,71	0,81	21
ACCURACY			0,96	169
MACRO AVG	0,95	0,85	0,89	169
WEIGHTED AVG	0,96	0,96	0,96	169

Variable	Importancia
mora	31,12
var_ing_fin	30,51
cob_prev	118,69
c_prom	9,22
apr	3,58
patrimonio_eficiente	2,76
prom_var_if	1,35
t_prom_c	1,13
t_prom_d	0,83
dpr	0,58
cf	0,18
prom_var_gf	0,06
roa	3,41553E-16

Riesgo de mercado

Para el riesgo de mercado (tasa de interés) la variable más relevante es la tasa promedio de cartera y depósitos y, en menor grado, la variación de los ingresos financieros. En este caso el modelo clasifica correctamente el 96% de toda la muestra, impulsado por el desempeño de observaciones por debajo del percentil 75, aunque con un desempeño moderado de la clase 1. El modelo tiene alta precisión, *recall* y F1-score para la clase 0, lo que indica que clasifica bien los casos comunes.

Cuadro 3: VARIABLES PRINCIPALES PARA LA PREDICIÓN Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE MERCADO

	precisión	recall	f1-score	support
0	0,99	0,96	0,97	163
1	0,36	0,67	0,47	6,00
ACCURACY			0,96	169
MACRO AVG	0,68	0,81	0,72	169
WEIGHTED AVG	0,97	0,95	0,96	169

Variable	Importancia
t_prom_c	94,0387
t_prom_d	3,8999
var_ing_fin	1,7168
mora	0,3446

Riesgos de liquidez

Las variables más relevantes, por importancia, según arboles de decisión, determina la proporción de liquidez respecto de activos, lo que indica que esta variable es el factor principal en el modelo. Siendo la principal variable, nos sugiere que las entidades de intermediación financiera (EIF) con mayores niveles de liquidez tienden a tener un menor riesgo asociado. En segunda instancia esta la variable disponibilidades sobre obligaciones de corto plazo, relacionado con la capacidad de una EIF para cubrir obligaciones inmediatas. El modelo clasifica correctamente el 96% de todas las instancias, pero esto está sesgado por la predominancia de la clase mayoritaria (clase 1)

Cuadro 4: VARIABLES PRINCIPALES PARA LA PREDICIÓN Y MÉTRICAS DE PRECISIÓN DE RIESGOS DE LIQUIDEZ

Variable	Importancia
liquidez_tot_act	74,73
disp_oblig_cp	7,60
dep_pub	3,90
t_prom_d	3,01
c_prom	2,09
net_loan	1,37
cap	1,06
brecha	1,01
ing_ope	0,91
act_liquid	0,88
apr	0,86
prom_var_if	0,75
roa	0,48
dpr	0,48
t_prom_c	0,37
pas_sin_costo	0,24
cob_prev	0,15
prom_var_gf	0,10

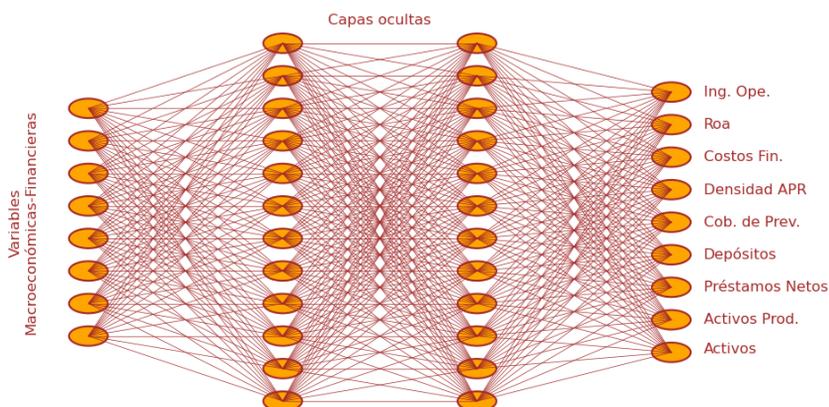
	precisión	recall	f1-score	support
0	0,26	0,59	0,36	17
1	0,95	0,81	0,87	152
ACCURACY			0,96	169
MACRO AVG	0,60	0,70	0,61	169
WEIGHTED AVG	0,88	0,79	0,82	169

Los resultados sugieren que, para la construcción de la prueba de estrés, contamos con variables que pueden capturar la transmisión de los riesgos de crédito, liquidez y mercado.

IV.3. Diseño y construcción del modelo *deep learning*

La estructura de un modelo de aprendizaje profundo incluye varias capas ocultas. En ese sentido, para la construcción de un modelo de prueba de estrés mediante el método *deep learning*, se formula la siguiente red neuronal: una capa de entrada que incluye 38 variables macroeconómicas y financieras; dos capas ocultas; y una capa de salida que incluye 9 variables objetivo: activos, activos productivos, préstamos netos, depósitos, provisiones, densidad de activo ponderado por riesgo, y costos financieros.

Gráfico 1: ESTRUCTURA DE UNA RED NEURONAL PROFUNDA



Fuente: Elaboración propia

Además, para el diseño del modelo *deep learning* se hace uso de la biblioteca *TensorFlow* que es una infraestructura flexible y escalable para el aprendizaje automático profundo y redes neuronales, lo cual nos permite trabajar con una cantidad de información granular.

Siguiendo los pasos del diseño del modelo, se divide los datos en dos partes: entrenamiento y pseudo predicción. Para el periodo de entrenamiento comprende los años 2005 – 2022 y para el periodo de pseudo predicción comprende el año 2023.

IV.4. Evaluación del modelo

Siguiendo la literatura para estimar las variables objetivo se presentan métricas de validación mediante los estadísticos del Error Cuadrático Medio (RMSE, por su sigla en inglés), el Error Absoluto Medio (MAE) y El Error del Porcentaje Absoluto Medio (MAPE, por su sigla en inglés). El modelo apropiado para la predicción tendrá los menores valores de los estadísticos. En este sentido, considerando cinco enfoques de modelación –Modelo de Hoja de Balance Constante, Modelo Satélite, Modelo *Deep Learning*, *Deep Learning* (Bayesian ReLU⁶) y *Deep Learning* (Bayesian LWTA⁷)– para una muestra de entrenamiento 2005 – 2022. Se puede apreciar que los valores de los estadísticos de validación señalan que el poder predictivo reside sobre el modelo *deep learning* con valores menores al resto de los enfoques de modelación. En cambio, para el periodo de entrenamiento 2023, los modelos con menor valor de validación estadística corresponden a los modelos de aprendizaje simple o con métodos bayesianos (ver Cuadro 5).

- 6 ReLU (*Rectified Linear Unit*) es una función de activación clave en deep learning debido a su simplicidad, eficiencia y capacidad para mitigar el desvanecimiento del gradiente. Se define como:

$$f(x) = \max(0, x)$$

$$\begin{aligned} \text{Si: } x > 0, f(x) &= x \\ x < 0, f(x) &= 0 \end{aligned}$$

La Bayesian ReLU es una extensión de la ReLU diseñada para integrar principios de inferencia bayesiana en redes neuronales. Combina la simplicidad y eficiencia computacional de la ReLU tradicional con un enfoque probabilístico, lo que la hace adecuada para modelar incertidumbre en problemas donde esta es crítica, como en tareas de toma de decisiones bajo riesgo o en aplicaciones de pruebas de estrés financiero.

$$f(x) = \max(0, x) + \varepsilon$$

donde, $\varepsilon \sim \mathcal{N}(0, \sigma^2)$ en un término de ruido gaussiano que introduce incertidumbre en el modelo. Los pesos y los sesgos se tratan como distribuciones típicamente gaussianas con priors definidas.

- 7 **LWTA** (*Localized Winner-Take-All*) es un mecanismo de activación y selección utilizado en redes neuronales que fomenta y mejora la robustez del modelo al seleccionar las unidades más relevantes dentro de un grupo para contribuir al aprendizaje. Este enfoque se utiliza en escenarios donde se busca priorizar características importantes, reducir el ruido en los datos y mejorar la capacidad de generalización del modelo. Solo la neurona con la mayor activación en su grupo contribuye a la salida, mientras que las demás son “apagadas”.

Cuadro 5: MEDIDAS DE VALIDACIÓN EN MUESTRA

Entrenamiento			
Modelos	RMSE	MAE	MAPE
Constant Balance Sheet	0,436703	0,328389	0,999348794
Satellite Modelling	0,436703	0,328389	0,999348794
Deep Learning	0,051177	0,021446	5,92967E+11
Deep Learning (Bayesian ReLU)	0,055955	0,021938	6,31552E+11
Deep Learning (Bayesian LWTA)	0,045585	0,022305	7,65014E+11
Prueba			
Modelos	RMSE	MAE	MAPE
Constant Balance Sheet	0,524811	0,448539	1,000000
Satellite Modelling	0,524811	0,448539	1,000000
Deep Learning	0,078167	0,047764	0,279895
Deep Learning (Bayesian ReLU)	0,076717	0,047702	0,329416
Deep Learning (Bayesian LWTA)	0,075109	0,048497	0,278770

Fuente: Elaboración propia

Nota: Los modelos con aprendizaje profundo sea ha estimado mediante LSTM (Long Short Term Memory). La periodicidad de entrenamiento comprende desde el año 2005 hasta el 2022 y el periodo de prueba dentro de muestra se considera el año 2023. La definición de cada uno de los modelos se encuentra en el Anexo

V. Prueba de tensión

V.1. Diseño de prueba de tensión

Una parte importante para analizar la resistencia del sistema financiero son el diseño de escenario de estrés. Un escenario de estrés en el sector financiero es una simulación o análisis que evalúa como responderían las entidades financieras como los bancos ante condiciones macroeconómicas adversas extremas. Estos escenarios se diseñan para medir la resistencia de las entidades frente a eventos de crisis que podrían afectar la liquidez, solvencia y estabilidad. Los escenarios de estrés son esenciales para identificar posibles vulnerabilidades en el sistema financiero y para planificar respuestas efectivas para mitigar riesgos.

En la literatura sobre pruebas de estrés hay características de escenarios de estrés, pero, en su mayoría, suele basarse en suposiciones de eventos económicos severos que podrían impactar sobre las variables importantes

de la economía. Por ejemplo, los choques macroeconómicos implican recesiones profundas, alta inflación, desempleo elevado o caídas significativas.

Con base en los estadísticos históricos de las variables macroeconómicas, se definen dos escenarios para el periodo 2024: el escenario base, que utiliza el valor promedio histórico de cada variable para representar condiciones macroeconómicas normales, y el escenario de estrés, que considera valores cercanos al percentil 10 de la distribución histórica para evaluar las condiciones más desfavorables registradas en el pasado. Este último afecta a variables como el Producto Interno Bruto (PIB), el gasto público como porcentaje del PIB (g_pib) y las exportaciones como proporción del PIB (exp). En el caso de la inflación (inf) y el desempleo (unem), se emplea el percentil 90 para identificar los niveles más altos de inflación y las tasas de desempleo más elevadas. La inclusión de este escenario permite evaluar la capacidad de resistencia del sistema financiero ante situaciones de mayor tensión macroeconómica. A continuación, el Cuadro 6, presenta el diseño de escenarios de las variables macroeconómicas⁸:

Cuadro 6: DISEÑO DE ESCENARIOS

Escenarios	PIB	g_PIB	exp_PIB	inf	unem
Base	3,95	16,13	2,79	4,47	4,34
Estresado	1,33	1,26	-11,58	10,42	5,87

Fuente: Elaboración propia

V.2. Transmisión de escenarios de estrés en la hoja de balance

Petropoulos *et al.* (2019) proponen un modelo con técnicas de aprendizaje profundo para las pruebas de estrés en balances financieros. El modelo integra datos financieros históricos y variables macroeconómicas en un modelo de aprendizaje profundo para simular de forma dinámica el impacto de choques económicos sobre el balance bancario. A diferencia de los modelos convencionales que requieren suposiciones rígidas, *deep-*

8 El diseño de escenarios de estrés comprende tres escenarios: base, moderado, estresado. En el escenario base, se calcula la media de cada una de las variables macroeconómicas para el periodo 2005 – 2023. Para el escenario moderado se calcula el percentil 90 para cada una de las variables macro, y para el escenario estresado se calcula el percentil 10 de las variables macro.

stress emplea un enfoque dinámico y adaptativo que se ajusta a nuevas informaciones y cambios en el mercado. Este enfoque permite a los bancos y a los reguladores evaluar con mayor precisión la solvencia y liquidez bajo distintos escenarios de estrés.

Para el cálculo de los resultados de la prueba de estrés en la hoja de balance, los autores utilizan la siguiente ecuación:

$$\text{Capital}_t = \text{Ganancias de los activos}_t - \text{Previsiones de cartera}_t \\ + \text{Ingresos operativos netos}_t - \text{Gastos Financieros}_t + \text{Capital}_{t-1}$$

Según los autores, se tiene la siguiente relación de las variables objetivo con el cálculo de las variables de la ecuación.

- Ganancias de los activos (GA), es el resultado de multiplicar activos por el ROA.
- Las provisiones de cartera (PREV), que representan los cargos por incobrabilidad de cartera, en este caso determinadas a partir de la contabilización de las provisiones relacionadas con la calificación de cartera.
- Ingresos operativos netos (IO), donde se consideran los otros ingresos netos del balance financiero.
- Los gastos financieros (GF) aproximados a partir de los costos financieros.
- El Capital, para nuestro caso, será considerado como el patrimonio neto (PN), con el objeto de realizar el cálculo del CAP.

En este sentido la ecuación se transformaría en:

$$\text{Capital}_t = \text{GA}_t - \text{PREV} + \text{IO}_t - \text{GF}_t + \text{PN}_{t-1} \quad (13)$$

Si bien la cartera neta y los activos totales no son considerados en la ecuación, se debe considerar que ambas variables afectan el cálculo del patrimonio neto ya que afectan la calidad del balance y el patrimonio contable de las EIF.

Por su parte, la densidad de los activos ponderados por riesgos, es importante para el cálculo de los Activos Ponderados por Riesgos (APR) y el cálculo del Coeficiente de Adecuación Patrimonial (CAP).

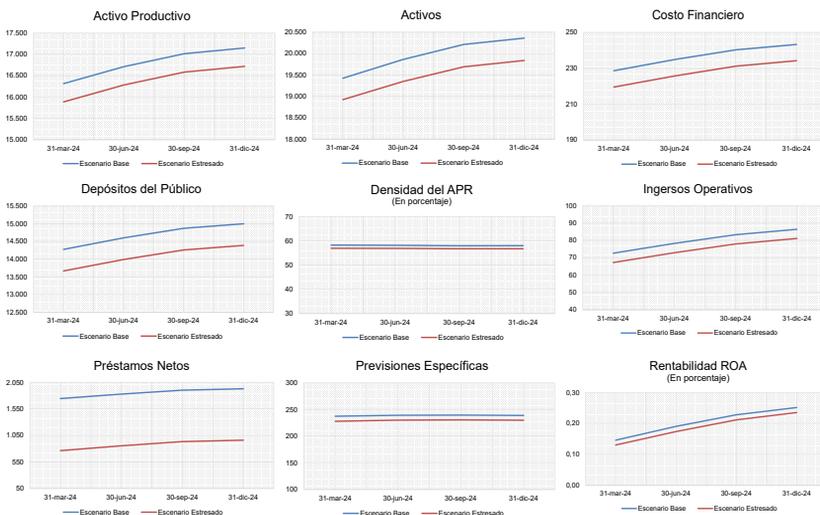
Así:

$$CAP_{t+1} = \frac{\text{Patrimonio Neto}_{t+1}}{APR_{t+1}} \quad (14)$$

VI. Resultados

En el Gráfico 2, se presentan los resultados para las nueve variables objetivo, calculado mediante el modelo de aprendizaje profundo. Las variables presentan un comportamiento adecuado sin cambios atípicos, tanto para el escenario base, así como para el escenario estresado. En este sentido, ante un posible deterioro de las variables macroeconómicas, las variables objetivo presenta menores niveles que en el escenario base.

**Gráfico 2: RESULTADO DE LA VARIABLES OBJETIVOS
(En millones de Bs)**



Fuente: Elaboración propia

Nota: Previo a la predicción fuera del periodo muestral, se ha realizado una evaluación mediante una pseudo predicción para cada una de las variables objetivo para evaluar el ajuste sobre el valor observado

Para evaluar el impacto sobre el CAP, en primera instancia, se calcula el capital en función de las variables objetivo (determinantes) para obtener el valor en el periodo de predicción, tanto para el escenario base como para el escenario estresado. En cambio, el Activo Ponderado por Riesgo se

obtiene a partir de una predicción mediante el modelo simple de *deep learning*. En el Cuadro 7 se presenta los resultados de los componentes del CAP.

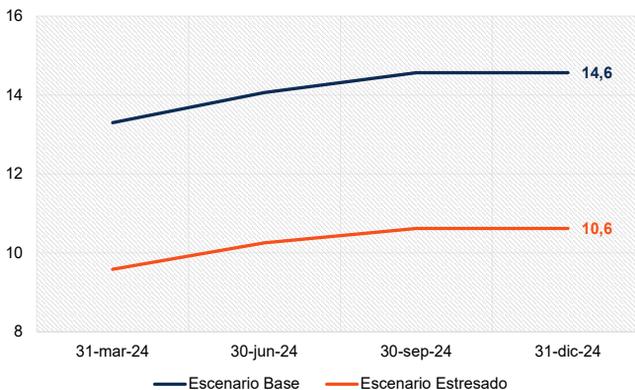
Cuadro 7: RESULTADO DE LA VARIABLES OBJETIVOS

Fecha	APR	CAPITAL	
		Escenario Base	Escenario Estresado
31-mar-24	12.038	1.646	1.173
30-jun-24	11.895	1.729	1.251
30-sep-24	11.577	1.753	1.273
31-dic-24	11.661	1.766	1.287

Fuente: Elaboración propia

Una vez realizada la proyección de las variables objetivo y haber agregado dichas variables para evaluar el impacto de las variables macroeconómicas estresadas por escenarios, se obtuvieron los siguientes resultados en el CAP proyectado.

Gráfico 3: RESULTADOS DE LOS ESCENARIOS DEL CAP⁹



Fuente: Elaboración propia

Nota: CAP promedio de las entidades bancarias

En este sentido, los resultados reflejan la capacidad de resiliencia del sistema bancario ante escenarios macroeconómicos adversos, proyectados en un horizonte de 12 meses. Los resultados muestran que,

9 En el Apéndice B se presenta los resultados por EIF.

bajo un escenario estresado, el CAP podría disminuir del 14,0% actual al 10,6%, manteniéndose por encima del requisito regulatorio mínimo del 10%.

Aunque el CAP proyectado permanecería dentro del margen legal, se recomienda fortalecer el patrimonio neto para garantizar el cumplimiento de los requisitos regulatorios, especialmente en escenarios estresados. Además, resulta crucial establecer un monitoreo continuo de las variables relacionadas con los riesgos financieros para anticipar posibles vulnerabilidades y mitigar su impacto.

Mapa de calor del indicador de solvencia por bancos

El siguiente gráfico evalúa el impacto que tendría la materialización del deterioro de las variables macroeconómicas sobre la solvencia de los bancos. Considerando los dos escenarios, los resultados muestran que la mayoría de los bancos cuentan con niveles adecuados de solvencia. Sin embargo, seis bancos presentarían problemas de solvencia para la gestión 2024, situándose por debajo del umbral establecido en la Ley 393 de Servicios Financieros¹⁰ (Gráfico 4).

¹⁰ En la Ley No 393 de Servicios Financieros, se establece un umbral de 10% para el indicador de solvencia de Coeficiente de Adecuación Patrimonial.

**Gráfico 4: MAPA DE CALOR DE SOLVENCIA POR BANCOS
 (En porcentaje)**

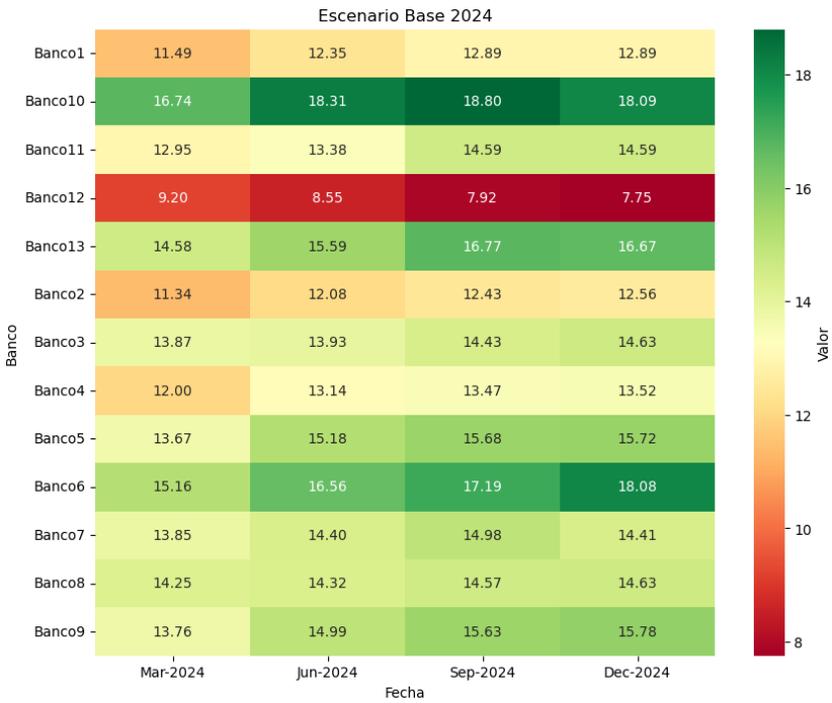
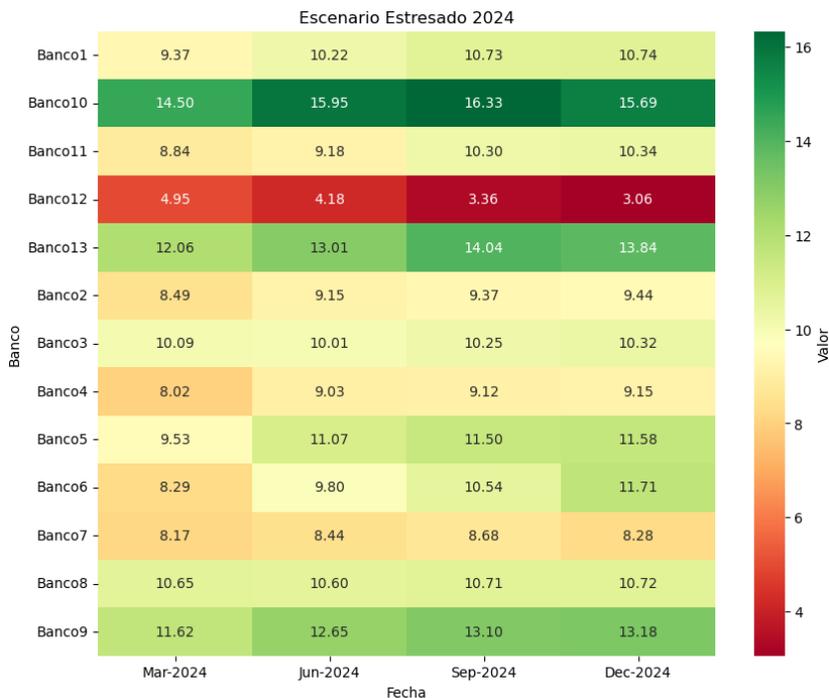


Gráfico 4: MAPA DE CALOR DE SOLVENCIA POR BANCOS (Cont.)
(En porcentaje)



Fuente: Elaboración propia

Nota: El mapa de calor se distribuye en tres colores: el color verde representa elevados niveles de solvencia; amarillo, representa un nivel moderado de solvencia y rojo representa aquellos bancos con bajo nivel de solvencia

VII. Conclusión

- Los modelos basados en aprendizaje profundo (*deep learning*) ofrecen una capacidad superior para capturar relaciones no lineales complejas entre variables macroeconómicas y financieras en pruebas de estrés. Comparados con métodos econométricos tradicionales, como los modelos ARIMA o DSGE, el enfoque propuesto evidencia mayor precisión en la proyección de escenarios adversos, especialmente en términos de solvencia. En particular, el modelo logró predecir con éxito el Coeficiente de Adecuación Patrimonial, mostrando una

disminución en escenarios estresados, pero manteniéndose dentro de los márgenes regulatorios.

- El uso de redes neuronales profundas permite a los reguladores evaluar con mayor precisión la resiliencia del sistema bancario. Este enfoque facilitaría el diseño de políticas macroprudenciales más efectivas y oportunas. Asimismo, los resultados sugieren fortalecer el patrimonio neto de los bancos y mantener un monitoreo constante de las variables clave de riesgo financiero.
- Los resultados de la prueba de tensión integral establecen que, considerando los supuestos el escenario estresado, el CAP, en promedio, se mantiene por encima del 10%, por encima del establecido por la Ley. Determinando que el sistema financiero bancario cuenta con una elevada solvencia.
- Aunque el modelo de aprendizaje profundo muestra un alto rendimiento predictivo, su implementación requiere grandes volúmenes de datos de alta calidad. Las limitaciones en la disponibilidad y consistencia de los datos podrían afectar la precisión del modelo.
- Para investigaciones futuras, se recomienda explorar más este tipo de modelos para potenciar aún más las capacidades predictivas y operativas en la gestión de riesgos financieros desde una visión macroprudencial y mejorar los resultados presentados en este documento.

Referencias bibliográficas

BASHEER, I. and HAJMEER, M., 2000. Artificial Neural Networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43 (1), pp. 3 - 31. ISSN en línea 1872-8359. Disponible en: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)

BERLANGA, Vanesa, RUBIO, María y VILÀ, Ruth, 2013. Cómo aplicar árboles de decisión en SPSS. *Revista d'Innovació i Recerca en Educació*, 6 (1), pp. 65 - 79. ISSN: 1886-1946. Disponible en: <https://doi.org/10.1344/reire2013.6.1615>

BORIO, Claudio, DREHMANN, Matias and TSATSARONIS, Kostas, 2014. Stress-testing macro stress testing: Does it live up to expectations? *Journal of Financial Stability*, 12, pp.3 - 15. ISSN en línea: 1878-0962. Disponible en: <https://doi.org/10.1016/j.jfs.2013.06.001>

BREIMAN, Leo, FRIEDMAN, Jerome, OLSHEN, Richard and STONE, Charles, 1984. *Classification and Regression Trees*. Boca Raton, Florida: Chapman & Hall/CRC. ISBN 978-0-412-04841-8

CHAFIK, Omar, MIKOU, Mohammed, MOTL, Tomas and SLAOUI, Yassine, 2022. A DSGE model for macroprudential policy in Morocco. Bank Al-Maghrib, Working paper, December. Disponible en: <https://www.bkam.ma/content/download/776339/8675179/version/1/file/DSGE+for+macroprudential+policy.pdf>

CHRONOPOULOS, Ilias, CHRYSIKOU, Katerina, KAPETANIOS, George, MITCHELL, James and RAFTAPOSTOLOS, Aristeidis, 2023. Deep Neural Network Estimation in Panel Data Models. Federal Reserve Bank of Cleveland, Working paper No. 23-15, July. Disponible en: <https://www.clevelandfed.org/-/media/project/clevelandfedtenant/clevelandfedsite/publications/working-papers/2023/wp2315.pdf>

ČIHÁK, Martin, 2004. Stress Testing: A Review of key Concepts. Czech National Bank, Internal Research and Policy Note, 2, April. Disponible en: https://www.cnb.cz/export/sites/cnb/en/economic-research/.galleries/research_publications/irpn/download/irpn_2_2004.pdf

DANIELSSON, Jon, SHIN, Hyun and ZIGRAND, Jean-Pierre, 2001. Asset Price Dynamics with Value-at-Risk Constrained Traders. Financial Markets Group, London School of Economics, Discussion Paper No.367. En: *29th EFA Annual Meeting*. Berlin, Germany: EFA, August. Disponible en: <https://dx.doi.org/10.2139/ssrn.302307>

ELHOSENY, Mohamed, METAWA, Noura, SZTANO, Gabor and EL-HASNONY, Ibrahim, 2022. Deep Learning-Based Model for Financial Distress Prediction. *Annals of Operations Research*, 345, pp. 885 – 907. ISSN en línea: 1572-9338. Disponible en: <https://doi.org/10.1007/s10479-022-04766-5>

GAI, Prasanna and KAPADIA, Sujit, 2010. Contagion in financial networks. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466 (2120), pp. 2401–2423. ISSN en línea: 1471-2946. Disponible en: <https://doi.org/10.1098/rspa.2009.0410>

HUANG, Jian, CHAI, Junyi and CHO, Stella, 2020. Deep learning in finance and banking: A literature review and classification. *Frontiers of Business Research in China*, 14 (2). ISSN en línea: 1673-7431. Disponible en: <https://doi.org/10.1186/s11782-020-00082-6>

JURADO, Llorent, HIRALDO, Melgar y SANZ, Ordaz, 2011. Una aproximación a las técnicas cuantitativas en las pruebas de estrés a la banca. En: *XIX Jornadas ASEPUMA – VII Encuentro Internacional*. Valencia: Universidad Pablo de Olavide. Disponible en: <https://investiga.upo.es/documentos/5eb2892329995203e240fe88>

LECUN, Yann, BENGIO, Yoshua and HINTON, Geoffrey, 2015. Deep learning. *Nature*, 521 (7553), pp. 436 – 444. ISSN en línea: 1476-4687. Disponible en: <https://doi.org/10.1038/nature14539>

LOH, Wei-Yin, 2011. Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1 (1), pp. 14 - 23. ISSN en línea: 1942-4795. Disponible en: <https://doi.org/10.1002/widm.8>

ONG, Li, ed., 2014. *A Guide to IMF Stress Testing. Methods and models*. Washington D.C.: International Monetary Fund. ISBN 978-1-47555-129-7.

Disponible en: <https://www.elibrary.imf.org/display/book/9781484368589/9781484368589.pdf>

OURA, Hiroko and SCHUMACHER, Liliana, 2012. Macrofinancial Stress Testing—Principles and Practices. International Monetary Fund, Monetary and Capital Markets Department, Working paper, August. Disponible en: <https://www.imf.org/external/np/pp/eng/2012/082212.pdf>

PÉREZ, Daniel y TRUCHARTE, Carlos, 2011. Los ejercicios de estrés test: Experiencia reciente y reflexiones sobre su futuro. Banco de España, *Estabilidad Financiera*, 21, pp. 63 – 82. Disponible en: <https://www.bde.es/f/webbde/Secciones/Publicaciones/InformesBoletinesRevistas/RevistaEstabilidadFinanciera/11/ref0421.pdf>

PETROPOULOS, Anastasios, SIAKOULIS Vasilis, VLACHOGIANNAKIS, Nikolaos and STAVROULAKIS, Evaggelos, 2019. Deep-Stress: A deep learning approach for dynamic balance sheet stress testing. En: *ICAIF '22: Proceedings of the Third ACM International Conference on AI in Finance*. New York: ICAIF, pp. 53 – 61. Disponible en: <https://doi.org/10.1145/3533271.3561656>

QUINLAN, J. Ross, 1993. *C4.5: Programs for Machine Learning*. London: Morgan Kaufmann Publishers. ISBN 1-55860-238-0

TSARYK, Krystyna, 2020. Artificial Neural Networks and Deep Learning for stress testing a banking system. Università Ca'Foscari Venezia. Master's Degree in Economics and Finance Final Thesis. Disponible en: <https://unitesi.unive.it/bitstream/20.500.14247/16922/1/856865-1247126.pdf>

URIBE, Jorge, MORALES, Miguel y PIÑEROS, José, 2008. Análisis de estrés sobre el sistema bancario colombiano: un escenario conjunto de riesgos. Banco de la República – Colombia, Reporte de Estabilidad Financiera, septiembre. Disponible en: <https://www.banrep.gov.co/sites/default/files/publicaciones/archivos/analisis.pdf>

VARIAN, Hal, 2014. Big Data: New Tricks for Econometrics. *Journal of Economic Perspectives*, 28 (2), pp. 3 – 28. ISSN en línea: 1944-7965. Disponible en: <https://doi.org/10.1257/jep.28.2.3>

APÉNDICES

Apéndice A

DESCRIPCIÓN DE LAS VARIABLES DEL MODELO

Variables	Descripción	Simbolos	Fuente
Variables macroeconómicas			
Crecimiento del Producto Interno Bruto	Es la tasa de crecimiento del PIB trimestral, es la variación a similar periodo.	pi_b	Instituto Nacional de Estadística (INE)
Participación del gasto público	Es la relación de la actividad de gasto público sobre la actividad económica	g_pi_b	
Participación de las exportaciones	Compara la proporción de las exportaciones respecto al PIB	exp	
Inflación	Es la variación del Índice de Precio al Consumidor a similar periodo	inf	
Desempleo	Mide la proporción de la población desocupada en las zonas urbanas.	unem	
Variables financieras			
Activos	Son activos que mantiene la entidad de intermediación financiera	activos	Autoridad de Supervisión del Sistema Financiero (ASFI)
Activo Productivo	Activo generado de ingresos	act_pro	
Activo Improductivo	Activo que no generan ingresos	act_impro	
Cartera bruta	Principal activo de riesgos	cartera_bruta	
Cartera en mora	Saldo de la cartera con incumplimiento de pagos	mora	
Solvencia	Coefficiente de Adecuación Patrimonial, es la relación entre el capital regulatorio sobre el activo ponderado por riesgos.	cap	
Índice de morosidad	Porcentaje de la cartera que se encuentra con incumplimiento del pago	im	
Previsiones específicas	Importe constituido para cubrir el riesgo de pérdida por incobrabilidad de préstamos como consecuencia de la evaluación y calificación individual de los deudores.	prev_esp	
Depósitos del Público	Fondos recibidos en depósito y otros tipos de obligaciones con el público en general.	dep_pub	
Activos Líquidos	Activo de fácil conversión a efectivo, tales como disponibilidades e inversiones financieras negociables en el mercado.	act_liquid	
Pasivos de Corto Plazo	Obligaciones que deben pagarse en un plazo de 90 días	pasivos_cp	
Pasivos sin Costo	Pasivos que surgen de la propia actividad de la EIF	pas_sin_costo	
Pasivos con costo operativo	Obligaciones que tienen un costo financiero implícito de captación	pas_costo_ope	
Patrimonio	Participación en la propiedad de los activos de una EIF después de deducir los pasivos. Refleja el valor que pertenece a los accionistas	patrimonio	
Patrimonio Eficiente	Gestión óptima del patrimonio contable y el mantenimiento de un Coeficiente de Adecuación Patrimonial adecuado (Asset and Liability Management)	patrimonio_eficiente	
Gestión de Activos y Pasivos	Administración de los riesgos financieros que surgen debido a descalces entre los activos y pasivos, especialmente en términos de plazos y tasas de interés.	alm	
Utilidades	Ganancias netas que una empresa obtiene después de deducir todos los costos y gastos asociados a su operación, incluyendo impuestos y otros compromisos financieros.	utilidades	
Rentabilidad sobre Patrimonio	Ratio de rentabilidad, que relaciona la utilidad neta con el patrimonio promedio de una EIF	roe	
Rentabilidad sobre activos	Ratio que relaciona la utilidad neta con el promedio de los activos totales de una EIF. Muestra cuál es la capacidad de los activos para generar utilidades.	roa	
Brecha de cartera y depósitos	Indicador financiero que refleja la diferencia entre el total de depósitos recibidos por las entidades financieras y el total de créditos otorgados	brecha	
Densidad de activos ponderados por riesgo	Proporción de los activos de una institución financiera que han sido ajustados según su nivel de riesgo, en relación con el total de activos.	dpr	
Liquidez sobre total activos	Proporción de los activos líquidos sobre el total de activos	liquidez_tot_act	
Disponibilidades sobre Obligaciones de Corto Plazo	Capacidad de una EIF para cumplir con sus compromisos financieros inmediatos utilizando sus activos más líquidos.	disp_oblig_cp	
Ingresos Financieros	Ingresos del período provenientes de la actividad de intermediación entre la oferta y la demanda de recursos financieros.	if	

Variación de Ingresos Financieros	Variación a 12 meses de los ingresos financieros	var_ing_fin
Promedio de la variación de Ingresos financieros	Variación promedio de los Ingresos financieros a 12 meses	prom_var_df
Cartera promedio	Cartera bruta promedio a 12 meses	c_prom
Gastos Financieros	Gastos del período provenientes de la actividad de intermediación financiera. Comprende los cargos por obligaciones con el público.	gf
Variación de gastos financieros	Variación promedio de los gastos financieros a 12 meses	var_gf
Promedio de la variación de gastos financieros	Variación promedio de los Gastos financieros a 12 meses	prom_var_gf
Depósitos del Público promedio	Depósitos del público promedio a 12 meses	d_prom
Tasa promedio de cartera		t_prom_c
Tasa promedio de depósitos		t_prom_d
Spread	Diferencia entre t_prom_c y t_prom_d	spread
Cobertura de provisiones	Indicador financiero que mide la capacidad de una EFP para absorber los créditos en mora, mediante las provisiones específicas	cob_prev
Activo Ponderado por Riesgo	Valor del activo multiplicado por el ponderador de riesgos	apr
Cobertura de pasivos de corto plazo	Proporción de activos líquidos que cubren pasivos de corto plazo	cp.
Cartera Neta	Cartera neta de garantías reales	net_loan

Apéndice B

RESULTADOS POR BANCOS

