

DETECCIÓN DE ANOMALÍAS EN EL SISTEMA DE PAGOS DEL ECUADOR: APLICACIÓN DE REDES NEURONALES.

Jeniffer Rubio*
John Arroyo**1

Resumen

Los Bancos Centrales monitorean las operaciones que se canalizan por las infraestructuras de mercado financiero, por ser de gran importancia en el fomento de la estabilidad financiera y el crecimiento económico. Las transacciones son reflejo de la actividad económica y comercial, proporcionan información de cómo los bancos gestionan la liquidez. El análisis de estos datos con la detección de anomalías, permite identificar el comportamiento de un flujo de pago inusual indicando eventos futuros y ayuda a la supervisión financiera para iniciar intervenciones oportunas.

Este documento realiza una aplicación de método de reducción de dimensiones, basada en el aprendizaje automático por redes neuronales (*Autoencoder*) para la detección de anomalías en el Sistema de Pagos Interbancarios en el Ecuador. La evaluación del modelo se realiza con una simulación en la alteración de los flujos de un banco. Los resultados reflejan que los modelos construidos detectan los periodos en que el banco presentó anomalías. Se propone una herramienta útil para el monitoreo de operaciones en el sistema de pago para identificar los cambios repentinos en los flujos, que podrían atribuirse a problemas de liquidez, operativos, etc. Este documento es un ensayo de la aplicación de la metodología construida por Triepels et al. (2017).

Palabras clave: Detección de anomalías, *Autoencoder*, Redes Neuronales, Aprendizaje automático, Inteligencia artificial, Sistemas de pagos, Infraestructura de mercado financiero.

Códigos JEL: C45, E42, E58.

Fecha de recepción: 27 de abril de 2020.

Fecha de aceptación: 15 de mayo de 2020.

^{1*} Economista por la Universidad de las Américas. Máster en Economía Aplicada por la Universidad de Alcalá (España), Banco Central del Ecuador, correo electrónico: jrubio@bce.ec ^{**} Ingeniero Comercial por la Pontificia Universidad Católica del Ecuador. Máster en Finanzas por el Instituto Tecnológico Autónomo de México, Banco Central del Ecuador, correo electrónico: jarroyo@bce.ec Los comentarios emitidos en el documento son criterios propios de los autores y desvincula a la Institución que representan. Agradecimientos a la asistencia de Nicolás Maffa.

Abstract

Central banks monitor operations that are channeled through financial market infrastructures, as they are of great importance in promoting financial stability and economic growth. Transactions are a reflection of economic and commercial activity; they provide information on how banks manage liquidity. Analyzing this data with anomaly detection identifies the behavior of an unusual payment flow indicating future events and helps financial supervision to initiate timely interventions.

This document makes an application of a dimension reduction method based on machine learning by neural networks (*Autoencoder*) for the detection of anomalies in the Interbank Payment System in Ecuador. The evaluation of the model is carried out by means of a simulation in the alteration of the flows of a bank. The results reflect that the constructed models detect the periods in which the banks presented anomalies (liquidity stress). A useful tool for monitoring operations in the payment system is proposed to identify sudden changes in flows, which could be attributed to liquidity, operational or other problems. This document is an essay of the application of the methodology constructed by Triepels et al. (2017).

Keywords: Anomaly Detection, *Autoencoder*, Neural Network, Artificial intelligence, ACSS, Financial, Market Infrastructure, retail payments. Machine Learning.

JEL classifications: C45, E42, E58.

Receipt date: April 27, 2020.

Acceptance date: May 15, 2020.

1. Introducción

El Comité de Sistemas de Pago y Liquidación, y Comité Técnico de la Organización Internacional de Comisiones de Valores (2012), define las infraestructuras del mercado financiero (IMF), como sistemas multilaterales en los cuales las entidades participantes compensan, liquidan y registran pagos, valores, derivados y otros activos financieros. Adicionalmente, se establece que las IMF contribuyen al mantenimiento y al fomento de la estabilidad financiera y el crecimiento económico. Por esa razón, las IMF son de interés y están bajo la vigilancia de los bancos centrales, que velan por su buen funcionamiento, fomentan su eficiencia y su seguridad.

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

Las IMF se consideran la columna vertebral financiera de nuestra la sociedad moderna, Heuver y Triepels (2019). En los últimos años, los datos de pago generados por las IMF se han convertido en una nueva fuente de información importante para detectar riesgos, entre ellos el riesgo de liquidez. Por otra parte el análisis de redes financieras es una herramienta común para las autoridades financieras de supervisión, León (2019).

Los bancos centrales monitorean cuidadosamente las actividades de pago de los bancos en las IMF para detectar señales de alerta temprana de estrés de liquidez que pueden afectar a la estabilidad financiera. Esto supone que una entidad que presente problemas de liquidez puede extenderse al sistema de pagos incumpliendo con sus compromisos de pagos y afectar a la posición de liquidez de otras entidades (efecto contagio) (Heuver y Triepels, 2019). La aparición de problemas financieros para una institución financiera participante, podría provocar una disminución de la confianza y consecuentemente un aumento repentino en el retiro de depósitos, conocido como una corrida bancaria, (Sabetti y Heijmans, 2020).

En el caso de Ecuador el Sistema de Pagos Interbancarios (SPI) es uno de los canales de pagos más importante del país. Durante el año 2018, se canalizó pagos interbancarios por un monto total de 107.699,78 millones de dólares por medio de 68.9 millones de transacciones, este monto es equivalente a 1 vez el PIB del país. Del monto total canalizado 62.376,21 millones de dólares corresponden a pagos realizados por bancos privados por medio de 28.9 millones de operaciones, estas transacciones de pago son demandadas por personas naturales y jurídicas a través de los diferentes bancos privados. El SPI, permite la acreditación en las cuentas del cliente final, 3 veces al día (Cortes), es decir, es un sistema de pago en tiempo diferido. El SPI, es administrado por el Banco Central del Ecuador.

El objetivo de este artículo es la detección de anomalías mediante la aplicación de un método de aprendizaje automático (*autoencoder*) en el SPI, para detectar los flujos de pagos que no se ajustan al comportamiento esperado. Mediante la información analizada se puede conocer los patrones de comportamiento habitual de pago de las entidades financieras y se busca encontrar los casos, en que estos patrones, se desvíen de lo esperado, generando una anomalía. Dichas anomalías deberán ser analizadas para conocer a profundidad sus fuentes, ya que en ocasiones puede ser a que uno/varios bancos enfrenten estrés de liquidez, que los obligan a cambiar su comportamiento de pago habitual; puede ser impulsada por el mercado (todo el sistema), problemas operativos, tecnológicos, entre otros. Este artículo está estrechamente relacionado con Triepels et al. (2017), dado que se aplica la metodología propuesta por estos autores en los datos de pago de Ecuador. El presente documento puede ser utilizado por los gerentes de riesgo, los supervisores bancarios, expertos en estabilidad

Jeniffer Rubio y John Arroyo

financiera u operadores de los sistemas. Es un aporte a la literatura sobre la detección de valores atípicos en los sistemas de pago, que desde nuestro conocimiento aún es escasa.

El *autoencoder*, es una red neuronal de aprendizaje automático no supervisado, que aprende de los datos reales de entrenamiento y los reconstruye para generar resultados, obteniendo solo las características principales de los datos de entrada. Reduce dimensiones de los datos de pago y aprende a discriminar patrones comunes en los casos que no identifique un comportamiento habitual, alertan una anomalía. Para ello se entrena y valida el modelo con datos del SPI, se lo prueba con otro set de datos nunca vistos por el modelo. No se cuenta con datos históricos que se hayan identificado como anomalías, por lo tanto, para evaluar el rendimiento de *autoencoder* para detectar pagos anómalos, se realizó una simulación con una entidad bancaria importante para el país. Los resultados obtenidos del *autoencoder* se denominan errores de reconstrucción; si el error de reconstrucción es pequeño, la matriz de pagos observada se ajusta a lo que es típico, pero si el error de reconstrucción es grande, la matriz de pagos observada debe considerarse una anomalía (atípico) causada por algún factor que debe ser analizado. La fortaleza de este método es que se puede llegar a determinar el periodo de tiempo específico y los participantes que influyeron en el comportamiento no común de pagos.

En la Sección 2 se describe el Sistema de Pagos Interbancarios (SPI), la sección 3 proporciona una breve descripción de la literatura relacionada sobre sistemas de pago y detección de anomalías. La Sección 4 define las notaciones y conceptos del *autoencoder*, detección de anomalías, simulación de la ejecución de un banco y la preparación de los datos para el *autoencoder*. La sección 5 muestra los resultados obtenidos. Finalmente, la sección 6 presenta las conclusiones del artículo.

2. Sistema de Pagos Interbancarios (SPI)

Los sistemas de pagos, según el Comité de Sistemas de Pago y Liquidación, y el Comité Técnico de la Organización Internacional de Comisiones de Valores, son un conjunto de instrumentos, procedimientos y reglas para la transferencia de fondos entre dos o más participantes; el sistema comprende a los participantes y a la entidad que gestiona el mecanismo. Los sistemas de pago suelen basarse en un acuerdo entre dos o más participantes y el operador. La transferencia de fondos se efectúa por medio de una infraestructura operativa convenida. Complementariamente, Summers (2012), lo define como el conjunto de instrumentos y procedimientos para que las transferencias de dinero puedan circular

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

eficientemente en la economía. A nivel mundial los avances en tecnologías de información han fomentado el desarrollo de las plataformas electrónicas que facilitan las transacciones de compra-venta vía electrónica y reducen el uso del dinero físico (monedas y billetes) (Banco de Inglaterra, 2012).

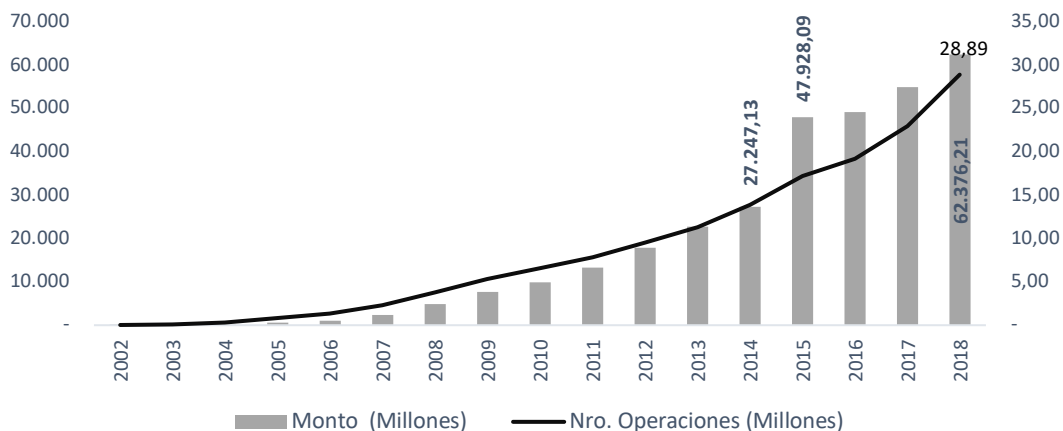
En el Ecuador, el sistema nacional de pagos está compuesto por el Sistema Central de Pagos (SCP), operado por el Banco Central del Ecuador (BCE) y los Sistemas Auxiliares de Pago operados por entidades privadas. Los montos canalizados por los sistemas que conforman el Sistema Central de Pagos en el Ecuador han evolucionado en el tiempo. Actualmente el más importante es el Sistema de Pagos Interbancarios (SPI), que canaliza el 60% del monto total en el SCP², este sistema es el que será analizado en este documento. El SPI permite realizar pagos entre clientes de las entidades financieras bancarias del Ecuador. El Banco Central del Ecuador, compensa y liquida las operaciones de pago entre entidades financieras durante tres periodos en el día (denominados cortes) por medio del SPI. Los recursos son debitados y acreditados en las cuentas de los clientes finales por medio de las entidades bancarias, conforme los siguientes horarios de liquidación de fondos 8h00 am, 11h00 a. m. y 15h00 p. m. El SPI es el sistema más fuerte y antiguo en el BCE, inició sus operaciones en el 2002 y a partir del 2015 los principales participantes son los clientes del sector financiero privado. Entre el 2010 y 2018, el monto canalizado por este sistema se ha incrementado en alrededor de 4 veces. (BCE, 2019).

En este documento se analizan los pagos realizados entre los 24 bancos privados del Ecuador, quienes a partir del 2015, presentaron el mayor impulso en el SPI, pasando de USD 27.247,13 millones en 2014 a USD 47.928,09 millones de dólares por pagos interbancarios en 2015; es decir un incremento de alrededor de 76%. Desde entonces hasta la actualidad, el crecimiento interanual es en promedio del 9%. El crecimiento del 2015, se explica por una participación más activa de los depositantes de las 6 entidades bancarias más grandes del país. En el 2018, los bancos privados canalizaron USD 62.376,21 millones por concepto de pagos interbancarios a través de 28.9 millones de operaciones.

² Seguido por los cheques liquidados en la Cámara de Cheques con el 32% del monto total canalizado, el Sistema de Cobros Interbancarios con el 6% y finalmente las Cámaras de Compensación Especializadas con el 2%.

Jeniffer Rubio y John Arroyo

Gráfico 1. Pagos interbancarios (Bancos Privados – ordenantes)
 Periodo 2002 – 2018, Monto y Nro. Operaciones (eje der) (En millones)




Fuente: BCE
Elaboración: Autores

Para la descripción de los flujos interbancarios que se realizan entre las entidades bancarias por medio del SPI, similar a lo aplicado por Sabeti y Heijmans (2020), se gráfica un mapa de calor del intercambio de flujos promedio por corte durante el año 2018 entre las 24 entidades bancarias, con ello se puede tener una idea de la actividad en el intercambio monetario entre entidad ordenante en relación a las entidades beneficiarias y sus relaciones dentro del SPI. Existen flujos promedios por corte cercanos a cero o cero, en esos casos lo que refleja es la no existencia de flujos entre esas entidades o participación escasa (el color más oscuro), mientras que existen otros casos que su flujo de pagos es más activa y con montos mayores.

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

Gráfico 2. Flujos interbancarios medios

Año 2018



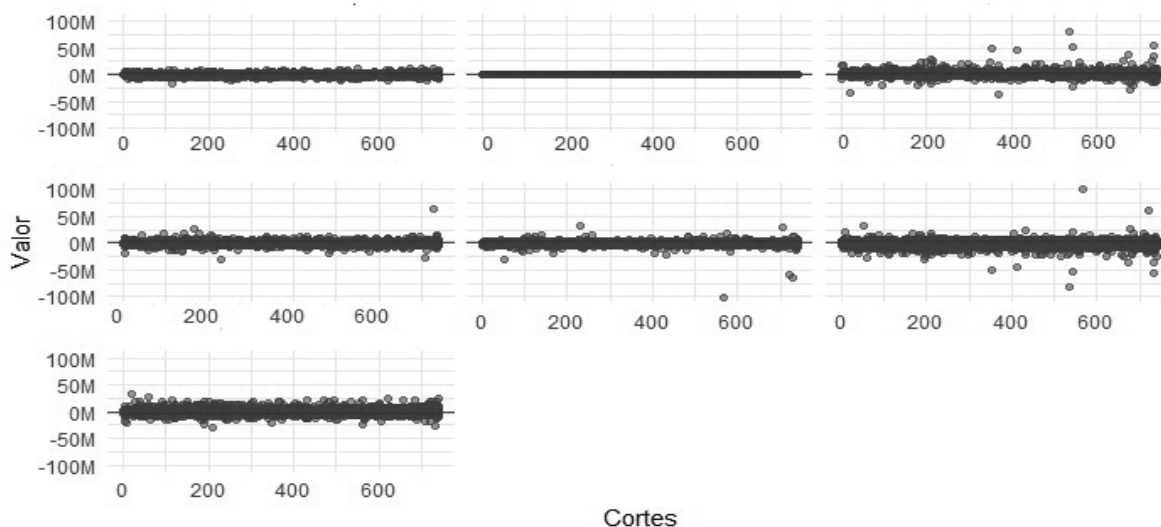
Fuente: BCE

Elaboración: Autores

Por otra parte se representa gráficamente los montos por corte de siete entidades, los negativos (-), representan salida de pagos realizados por la entidad y los positivos (+), representan flujos de entrada, es decir los pagos que recibe la entidad. Visualmente se observa que los datos se concentran alrededor de cero, sin embargo, algunos cortes de las entidades sobresalen de ese comportamiento común (Sabetti y Heijmans, 2020).

Jeniffer Rubio y John Arroyo

Gráfico 3. Flujos entrada/salida (Izquierda)



Fuente: BCE

Elaboración: Autores

3. Literatura relacionada

Por el creciente uso de la tecnología y comercio electrónico, que se ha unido al aumento de los pagos en línea, la detección anomalías se ha convertido en un factor importante para las entidades financieras. Por lo tanto, centrarse en una variedad de métodos de detección de anomalías, así como en nuevas formas de abordarlos y prevenirlos, es cada vez más de interés Zamini y Montazer (2018); Thottan et al. (2010). Esto concuerda con Patcha et al. (2007), que hacen un compendio de las tendencias tecnológicas recientes para la detección de anomalías mediante aprendizaje automático³.

La literatura, que aborda temas relacionados a la detección de anomalías y la aplicación de aprendizaje automático e inteligencia artificial en los sistemas de pagos, concuerda que por medio de estos métodos y los datos de pago se busca encontrar los patrones usuales del manejo de la liquidez de los bancos dentro de un sistema de pagos, examinando casos en los

³ Los métodos en esta área se pueden clasificar en términos generales como detección de anomalías supervisadas o detección de anomalías no supervisadas.

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

que el comportamiento de pago de los bancos se desvía de sus patrones esperados (anomalías). En los sistemas de pago, las anomalías son configuraciones particulares de una red de pago fuera de lo normal. Las anomalías se pueden explicar por algunos factores, entre ellos: estrés de liquidez, comportamiento de pago no deseado, errores operativos, tecnológicos u otros, lo que conlleva en algunos casos a una reducción de confianza por el sistema financiera (reducción de depósitos o corrida bancaria) (Heuver y Triepels (2019); Triepels et al. (2017); Sabetti y Heijmans (2020). Por ello la importancia de contar con estas herramientas de monitoreo que permite a los bancos centrales detectar alertas tempranas de posibles eventos dentro de los sistemas de pagos e iniciar intervenciones oportunas. Las anomalías en la red de pagos pueden ser examinadas a mayor profundidad para identificar su raíz, que puede ser impulsada por los participantes (es decir, causada por una institución financiera) o impulsada por el mercado, es decir, un cambio en todo el sistema, León (2019).

La literatura existente relacionada a la detección de anomalías en sistema de pagos bajo metodologías de aprendizaje automática es escasa, por lo que este documento aporta a esta área de investigación. Entre los pioneros en este ámbito de estudio destaca Triepels et al. (2017), que realizan un método de aprendizaje automático no supervisado para la detección automática de las anomalías en el sistema de pagos de alto valor de liquidación en tiempo real (inmediata) canalizados por el TARGET2 (Sistema automatizado transeuropeo de transferencia urgente para la liquidación bruta en tiempo real) en el segmento de Holanda. Esta investigación proporciona un enfoque diferente para medir el riesgo sistémico y monitoreo de operaciones de sistemas de pago, mediante un *autoencoder*, que consiste en entrenar la red neuronal para que aprenda de las características de los datos, comprimiéndolos en un espacio dimensional más bajo y, en consecuencia, reconstruyéndolos en el espacio original. Además, evaluaron el rendimiento de dos tipos de codificadores automáticos (*autoencoder*.) con simulaciones de corridas bancarias (salidas de liquidez adicionales por parte de una entidad financiera). Sus resultados demuestran que el *autoencoder* pueden detectar los cambios inesperados en los flujos de liquidez entre los bancos. Conforme lo indican los autores, la metodología propuesta y estimada es el punto de partida (*autoencoder general*) para futuras estimaciones con mayores complejidades dentro del *autoencoder*.

Similar a la metodología de Triepels et al. (2017), en Sabetti y Heijmans (2020), propenden detectar flujos anómalos en la base de datos de pagos canalizados por el Sistema Automatizado de Compensación y Liquidación de Canadá (ACSS), aplicando redes neuronales por medio del *autoencoder*. Además, modelizan y prueban varias arquitecturas de redes neuronales en función del tamaño y el número de capas ocultas creando redes neuronales más profundas y con diferentes funciones de activación. Prueban también *autoencoder* con anomalías históricas y corridas bancarias simuladas, detectando los flujos

Jeniffer Rubio y John Arroyo

de pago anómalos razonablemente bien. La diferencia con la aplicación de Triepels et al. (2017), radica en aplicar el *autoencoder* en un sistema de pagos minorista (bajo valor) que procesa diferentes tipos de instrumentos de pago minorista⁴. Se utiliza datos de pagos bilaterales diarios y finalmente aplican un *autoencoder* profundo (más de una capa oculta).

Una metodología diferente a las mencionadas pero basada en aprendizaje automático, León (2019), para la detección de anomalías en el sistema de pagos de alto valor de Colombia, aplica una técnica de reducción de dimensionalidades, por medio del Análisis de Componentes Principales y algoritmo de agrupamiento para clasificar los errores de reconstrucción creados en normales y anómalos, lo que permite distinguir las redes de pagos que se desvían del comportamiento habitual. Para probar la metodología realizaron un conjunto de redes anómalas sintéticas creadas mediante simulaciones de pagos intradía. Con sus resultados se evidencia que el enfoque sugerido en este documento proporciona un método factible para detectar redes anómalas, que se suman a las herramientas de monitoreo existentes basadas en datos de menor dimensión.

Por su parte, otra rama de investigación se centra en metodología de aprendizaje automático supervisado, en el documento de Heuver y Triepels (2019), aplican una técnica de aprendizaje automático supervisado para detectar el estrés de liquidez en los bancos europeos, bajo la premisa que los sistemas de pagos permiten obtener dicha información por medio de comportamientos no habituales de los participantes. Para ello construyen clasificadores probabilísticos que estiman la probabilidad de que un banco enfrente un estrés de liquidez. La diferencia principal con las metodologías mencionadas anteriormente es que al ser un modelo supervisado de aprendizaje automático se entrena con un conjunto de datos etiquetados que distinguen casos históricos de bancos que enfrentaron eventos de estrés conocidos, como una adquisición o una corrida bancaria. Por medio de ello el modelo aprende los patrones que son característicos de un banco estresado y no estresado, y distingue si un banco probablemente enfrenta estrés de liquidez o no. Heijmans y Zhou (2019), estudian la detección de valores atípicos en los indicadores de riesgo basados en datos de transacciones del sistema de pago de gran valor en el TARGET2 de Holanda. Para ello utilizan la teoría del valor extremo y los métodos locales de factores atípicos para identificar

⁴ El sistema de solución de compensación automatizada (ACSS) es un sistema mediante el cual cheques en dólares canadienses y de pago electrónico se liquidan a artículos, tales como depósitos directos, retiros en cajeros automáticos, transacciones de punto de venta, pagos en línea y pagos de facturas de débito y pre-autorizados. El sistema rastrea el intercambio de elementos de pago y los saldos resultantes debido al y desde los participantes directos.

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

puntos de datos anómalos (valores atípicos)⁵. Heijmans y Heuver (2011), basados en estadística tradicional desarrollaron indicadores de signos de escasez de liquidez y posibles problemas financieros de los bancos con los datos de sistemas de pagos de Holanda y los datos de gestión de garantías. Estudiaron los datos antes, durante y después de eventos estresantes en la crisis, se identifican los patrones de reacción de los bancos. Estos patrones se traducen en un conjunto de reglas de comportamiento, que se pueden usar en los análisis de escenarios de estrés de los sistemas de pago, como simulaciones y topología de red. Para realizar simulaciones de sistemas de pago realistas, es crucial comprender cómo reaccionan los bancos ante las crisis.

En la referida literatura se observa que existen varios métodos planteados para el monitoreo de la liquidez canalizada por los sistemas de pagos relacionada a la detección de anomalías que utilizan ramas de la estadística y construcción de indicadores con varios tipos de riesgos identificados en eventos históricos, con ello catalogar posibles problemas de liquidez (Heijmans y Heuver, 2011) (Heijmans y Zhou, 2019) obteniendo resultados basados en el conocimiento del negocio. Por su parte existe otros trabajos que plantean la detección de anomalías con aprendizaje automático no supervisado, utilizada cuando no se cuenta con información histórica o clasificación de estrés de liquidez conocidos en el sistema de pagos, permitiendo a los modelos encontrar patrones por los cuales los bancos generalmente manejan su liquidez en el sistema de pagos y detectar casos donde el comportamiento de pago actual de los bancos se desvía de sus patrones esperados (Triepels et al., 2018). Este mismo autor plantea otra metodología basada en el aprendizaje automático supervisado para otros sistemas de pagos, la principal diferencia es que entrena su modelo con información etiquetada en la que se identifica los casos de estrés de liquidez pasadas y el modelo aprende de esas características para futuras predicciones, con ello construyen clasificadores probabilísticos que estiman la probabilidad que un banco enfrente estrés de liquidez (Heuver y Triepels, 2019). Este último resulta un método de mayor precisión y mayor valor agregado ya que determina la probabilidad de estrés de liquidez de los bancos. Los autores mencionan que un inconveniente de los métodos no supervisados es que puede ser difícil determinar qué tipo de los patrones se aprenden sobre el comportamiento de pago de bancos, por lo que requiere varias calibraciones, sin embargo, la limitación de la información etiquetada limita la aplicación de dicha técnica.

⁵ En una configuración univariante, el análisis de valor extremo cuantifica la inusualidad de cada valor atípico. En una configuración multivariante, el método del factor de valor atípico local identifica los valores atípicos midiendo la desviación local de un punto de datos dado con respecto a sus vecinos.

4. Autoencoder

El propósito de este estudio es realizar la aplicación del modelo de *autoencoder* discutido en Triepels et al. (2017), para tal efecto se utilizará el concepto, explicación y notación similar a los autores de referencia. Para detectar una red anómala, la reducción de dimensionalidad permite medir hasta qué punto sus características conectivas principales (es decir, la estructura), se desvían de las que se consideran típicas o esperadas. La clave de dicha medida reside en la capacidad de los métodos de reducción de dimensionalidad para reconstruir datos con un error. Este error de reconstrucción sirve como criterio para la desviación de lo que se espera (León, 2019). El método utilizado en este documento es el *Autoencoder*.

El resultado de la reducción de dimensionalidad es una compresión con pérdida de datos de pagos. Tiene pérdidas porque solo se preservan las características esenciales de los datos, por lo que es útil para detectar observaciones anómalas, León (2019).

Las metodologías de *autoencoder*, han sido parte del panorama histórico de las redes neuronales durante décadas y las primeras aplicaciones se remontan a los años 80, Goodfellow et al. (2016). Un *Autoencoder* es una red neuronal artificial capacitada que tiene como objetivo reconstruir, lo más similar posible, la capa de entrada en la capa de salida. Lo hace procesando la entrada a través de una capa oculta en la que unos conjuntos de neuronas forman una representación de la entrada en un espacio dimensional inferior (compresión). Está constituido por dos partes principales: un codificador (encoder) y un decodificador (decoder).

La particularidad de *autoencoder*, es que está diseñado para no poder aprender a copiar perfectamente. Por lo general está restringido, de manera que permite copiar solo aproximadamente, y copiar solo la entrada que se parece a los datos de entrenamiento. Debido a que el modelo se ve obligado a priorizar qué aspectos de la entrada deben copiarse, obteniendo las propiedades útiles de los datos. Goodfellow et al. (2016), en su libro detalla *autoencoder* y sus variantes.

a. Notación general del *autoencoder*

Para la entrada $a^{(k)}$ el *autoencoder* estima una reconstrucción $\widehat{a}^{(k)}$ de $a^{(k)}$ a través de una capa oculta (centro) que consta de l neuronas ($h_l^{(k)}$). El mapeo de reconstrucción se compone de dos funciones ϕ y ψ , la función de entrada (Encoder - codificador) ϕ y ψ la función de salida (Decoder):

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

$$\phi: R^{n^2} \rightarrow R^l \quad (1)$$

$$\psi: R^l \rightarrow R^{n^2} \quad (2)$$

Primero, $a^{(k)}$ está codificado por ϕ en el espacio dimensional procesándolo a través de la capa oculta:

$$\phi(a^{(k)}) = f^{(l)}(W_1 a^{(k)} + b_1) \quad (3)$$

Donde, W_1 es una matriz de pesos l por n^2 , b_1 es un vector de términos de sesgo l , y $f^{(l)}(y) = [f(y_1), \dots, f(y_l)]$ es un conjunto de funciones de activación que se aplican a los elementos de y . Las funciones potenciales para f son la función *ReLU* y la función *Tangente Hiperbólica*, utilizadas en el presente estudio. El resultado de la codificación $f \phi(a^{(k)}) = [h_1, \dots, h_l]$ es un vector de l activaciones de neuronas ocultas que forman una representación (comprimida) de $a^{(k)}$ en R^l . Luego, $\phi(a^{(k)})$ se decodifica de nuevo por ψ en el espacio n^2 -dimensional procesándolo a través de la capa de salida:

$$\psi(a^{(k)}) = g^{(n^2)}(W_2 \phi(a^{(k)}) + b_2) \quad (4)$$

Donde, W_2 es una matriz de pesos l por n^2 , b_2 es un vector de términos de sesgo n^2 y $g^{(n^2)}(y)$ es un conjunto de funciones de activación. El resultado de la decodificación $\psi(\phi(a^{(k)})) = [\hat{a}_1^{(k)}, \dots, \hat{a}_{n^2}^{(k)}]$ es un vector de n^2 salidas que forman una reconstrucción de $\phi(a^{(k)})$ en R^{n^2} .

Con ello se representó que el objetivo del *autoencoder* es aprender un mapeo desde la capa de entrada a la capa de salida de manera que $a^{(k)} \approx \psi(\phi(a^{(k)}))$ para todo $a^{(k)} \in D. + \}$.

Por su parte, para el aprendizaje del *autoencoder*: Los parámetros $\theta = \{W_1, W_2, b_1, b_2\}$ del *autoencoder* se estiman a partir de flujos de liquidez históricos. Hacemos esto minimizando⁷ el error de reconstrucción medio (*MRE*), es decir:

⁶ Los pesos y los sesgos generalmente se inicializan aleatoriamente y luego se actualizan iterativamente durante el entrenamiento a través de *Backpropagation*.

⁷ (Triepels et al., (2017), Un enfoque es aplicar el descenso de gradiente (estocástico) junto con la retro propagación para calcular eficientemente todos los gradientes durante el proceso de optimización. En este caso, los parámetros se actualizan de forma iterativa proporcional al gradiente negativo de la *MRE*. Este proceso se repite hasta que los parámetros convergen a una configuración para la cual el *MRE* es (localmente) mínimo.

Jeniffer Rubio y John Arroyo

$$\theta = \arg \min_{W_1, W_2, b_1, b_2} MRE(D) \quad (5)$$

b. Detección de anomalías con *autoencoder*

El *autoencoder* estima el *error de reconstrucción (RE)* en diferentes niveles de agregación, para un flujo de liquidez individual $a_{ij}^{(k)}$, el error de reconstrucción se estima tomando la diferencia al cuadrado entre su valor de transacción reconstruido y el valor de transacción original:

$$RE(a_{ij}^{(k)}) = \frac{1}{2} \left(\psi \left(\phi(a^{(k)}) \right)_{i+n(j-1)} - a_{ij}^{(k)} \right)^2 \quad (6)$$

De manera similar, el error de reconstrucción de todos los flujos de liquidez combinados en el intervalo de tiempo t_k se puede estimar tomando la norma l_2 al cuadrado de la diferencia entre el vector de liquidez reconstruido y el vector de liquidez original:

$$RE(a^{(k)}) = \frac{1}{2} \left\| \psi \left(\phi(a^{(k)}) \right) - a^{(k)} \right\|^2 \quad (7)$$

Finalmente, tomando el error de reconstrucción medio de todos los vectores de liquidez en D obtenemos el Error de Reconstrucción Media (MRE) general:

$$MRE(D) = \frac{1}{m} \sum_{k=1}^m RE(a^{(k)}) \quad (8)$$

Con ello, sea M un modelo de compresión con pérdida⁸. Medimos el error de reconstrucción de $a^{(k)}$ después de que M lo comprime y reconstruye mediante la función RE :

$$RE: D \rightarrow [0, +\infty) \quad (9)$$

Cuando $RE(a^{(k)}) \geq \varepsilon$, donde $\varepsilon > 0$ es un umbral, entonces $a^{(k)}$ se considera *anómalo* porque su error de reconstrucción es alto. No hay una forma matemática de determinar cuál debe ser el ε . Depende del juicio de un experto en el dominio, Sabetti y Heijmans (2020). Para este estudio para la elección del umbral se determinó con media de los errores y desviación estándar.

⁸ La compresión con pérdida es una forma particular de compresión en la que los datos pueden no recuperarse por completo. En este caso el Autoencoder construido. Triepels et al., (2017).

Con ello se busca encontrar todos los vectores de liquidez en D cuyo error de reconstrucción es mayor que ε . Dado un conjunto de vectores de liquidez D , un modelo de compresión con pérdida M_θ con parámetros θ y umbral ε , encuentre el conjunto de anomalías:

$$F = \{a^{(k)} \in D \mid RE(a^{(k)}) \geq \varepsilon\}$$

c. Simulación

Para evaluar el rendimiento del *autoencoder* en la detección de anomalías, se realizó una simulación de corrida bancaria artificial, tomando de referencia la metodología de Triepels et al. (2017).

Se eligió un Banco A para agregar liquidez adicional a los flujos de salida dirigidos al resto de entidades. La cantidad de liquidez adicional es aleatoria con distribución exponencial y una probabilidad de ocurrencia, que sigue una distribución Bernoulli. A medida que avanza el tiempo la cantidad adicional es mayor y la probabilidad de ocurrencia, es decir, al inicio de la corrida bancaria la probabilidad de ocurrencia del incremento del monto adicional al flujo es (p_s) y se agrega una cantidad promedio de ($1/\lambda_s$), al final de la corrida bancaria la probabilidad de ocurrencia del incremento del valor adicional al flujo es (p_e) y se agrega un valor en promedio de ($1/\lambda_e$), donde necesariamente $p_s < p_e$ y $\lambda_s < \lambda_e$. Donde:

- λ_s y λ_e son los parámetros de velocidad al principio y al final de la corrida bancaria, respectivamente. Aumento exponencial de $\lambda_s = 10^{-4}$ a $\lambda_e = 10^{-7}$.
- Probabilidad de que se agregara liquidez durante las corridas bancarias aumentó de $p_s = 0$ a $p_e = 0.8$. p_s y p_e son valores iniciales y finales de p_x respectivamente, donde $P(x) \in \{0,1\}$.
- La ejecución bancaria comenzó al final del conjunto de prueba y duró $d = 90$ intervalos de tiempo (cortes), desde el corte 651 y terminando en el 741.

4.2. Preparación de datos para *autoencoder*

A continuación se representa la notación realizada por Triepels et al. (2017), con aplicación en el SPI en Ecuador. Para el efecto se representa la matriz de liquidez que refleja el intercambio de pagos entre los bancos privados en el periodo de tiempo determinado. Para el efecto:

- $B = \{b_1, \dots, b_n\}$ es el conjunto de n bancos que participan en el sistema SPI. En Ecuador el n es 24 bancos privados existentes.
- $T = \langle t, \dots, t_k \rangle$, conjunto ordenado de k intervalos de tiempo, donde $t_1 = [\tau_0, \tau_1)$, $t_2 = [\tau_1, \tau_2)$, y así sucesivamente. En el caso de aplicación en Ecuador, corresponde a los *CORTES* que son los 3 posibles momentos en el día que se pueden compensar y liquidar los pagos entre los bancos privados en el SPI.
- $A^{(k)}$ se denomina matriz de liquidez $n * n$, cada elemento $a_{ij}^{(k)} \in [0, +\infty)$ denota la cantidad total de liquidez que b_i envía a b_j en intervalo de tiempo t_k (10). Para fines de análisis, derivamos de $A^{(k)}$ la representación vectorizada (11), $a^{(k)}$ es un vector de liquidez. La matriz de liquidez representaría las redes de pagos (nodos) que se encuentran interconectados con los flujos de liquidez.

$$A^{(k)} = \begin{bmatrix} a_{11}^{(k)} & \dots & a_{1n}^{(k)} \\ \vdots & \ddots & \vdots \\ a_{n1}^{(k)} & \dots & a_{nn}^{(k)} \end{bmatrix} \quad (10) \quad a^{(k)} = [a_{11}^{(k)}, \dots, a_{n1}^{(k)}, \dots, a_{1n}^{(k)}, \dots, a_{nn}^{(k)}]^T \quad (11)$$

Los datos utilizados para el análisis de este estudio, se centraron en un año completo (2018) de pagos interbancarios entre los 24 bancos privados del Ecuador de enero a diciembre, lo que representan 28.9 millones de órdenes de pagos procedas por el SPI, estos son pagos que los bancos intercambiaron por el comportamiento y demanda de sus clientes. En el año de estudio existieron 741 *CORTES* que representan los 3 cortes diarios durante 247 días laborables en el año, por los cuales los bancos tuvieron la posibilidad de procesar flujos de liquidez (pagos) entre ellos. Bajo este conocimiento, se conformó la matriz de liquidez agregando los pagos a los largo de 741 intervalos de tiempo entre 576 posibles intercambios cada periodo, con ello se obtiene los vectores de liquidez correspondientes. Todos los flujos de liquidez de los vectores se transformaron mediante una transformación logarítmica para hacer que su distribución altamente sesgada fuera menos sesgada. La normalización mínima-máxima se realizó a su vez para normalizar sus valores al intervalo [0,1].

Respecto a la partición de los datos para la aplicación del *autoencoder* se dividió los vectores de liquidez en tres conjuntos de datos: conjunto de entrenamiento: 318 vectores de liquidez de abril hasta agosto (del corte 184 al 501); conjunto de validación: 183 vectores de liquidez de enero a marzo (del corte 1 al 183); conjunto de test: 240 vectores de liquidez de septiembre hasta diciembre (del corte 502 al 741). Al igual que Triepels et al. (2017), este documento realizó la partición de los datos basados en los meses del año. Debemos considerar que, al realizar la partición de los conjuntos de datos con meses del año, se podría tener efectos de estacionalidad en los datos, por lo que el entrenamiento del *autoencoder* se realizaría sin

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

considerar el efecto del último cuatrimestre (periodo que normalmente existen mayores pagos interbancarios). El set de datos del último cuatrimestre se utiliza para realizar la evaluación del *autoencoder*. En otros casos Sabetti et al. (2020), dividen para conjunto de entrenamiento el 80% y la validación 20% de la muestra de datos o realiza entrenamiento de sus modelos con 24 meses León (2019).

En este trabajo, se utilizó el conjunto de datos de entrenamiento para que los parámetros de *autoencoder* aprendan, el conjunto de validación para optimizar el número de neuronas y el número de epochs (el número de veces (iteraciones) o pasadas sobre el conjunto de datos de entrenamiento). Finalmente, el conjunto de datos de prueba para evaluar *autoencoder* construidos. Cabe señalar que en la base de datos disponible del SPI, no hay episodios de fallas que puedan etiquetarse como valores atípicos conocidos. Para complementar la evaluación de *autoencoder*, se realizó simulaciones mediante la alteración de los flujos de liquidez de una entidad bancaria, esperando que sean capaces de reconocer las anomalías del estrés de liquidez o comportamiento inusual del banco en estudio, Triepels et al. (2017), Sabetti y Heijmans (2020).

5. Resultados

La presente sección, describe los resultados obtenidos en las pruebas realizadas para la aplicación de *autoencoder* en el Sistema de Pagos en el Ecuador, específicamente en el sistema SPI.

a. Aplicación de *autoencoder*

Se construyeron dos *autoencoder* con una capa oculta, con una única diferencia en la función de activación utilizada, un *autoencoder* con Tanh (función tangente hiperbólica) y el otro con ReLu (unidad lineal rectificadora definida matemáticamente como $y = \max(0, x)$). Se utiliza las funciones de activación similar a Sabetti y Heijmans (2020).

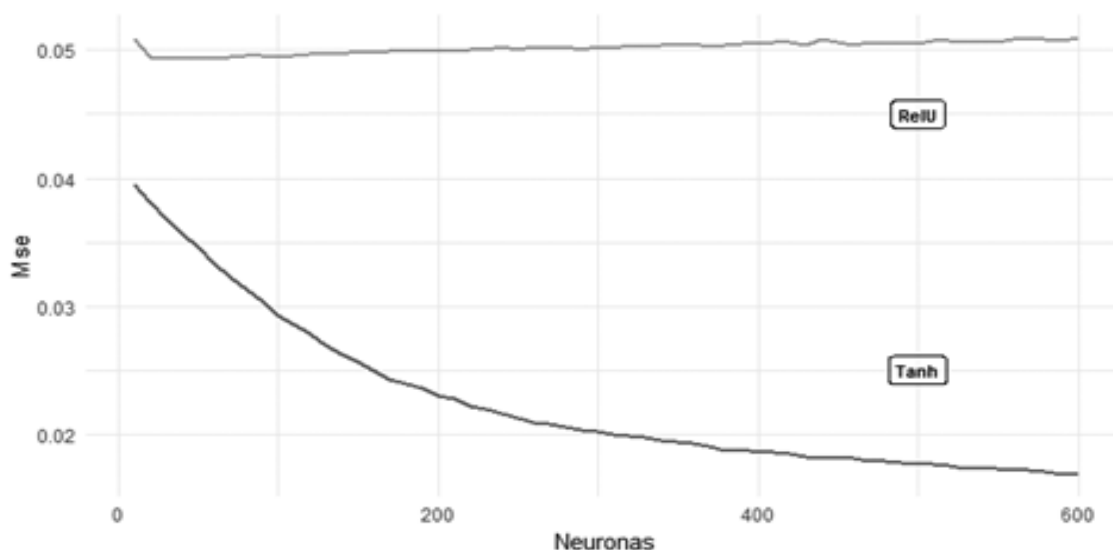
Para la optimización del número de neuronas, se realizó una búsqueda en la cuadrícula, de esta manera en la capa oculta, el número de neuronas se fue incrementando desde 10 hasta llegar a 600, en 10 neuronas adicionales cada prueba (Gráfico 4). Este resultado permite encontrar el punto en el que agregar más neuronas no produce un mejor error (Triepels et al., 2017). El número de nodos tanto en la capa de entrada como en la de salida es 576. Adicionalmente, aplicando la misma técnica se iteró sobre un conjunto de epochs desde 5 a

Jeniffer Rubio y John Arroyo

300 con pasos de 5, los valores óptimos para los parámetros se escogieron de tal forma que al iterar al siguiente valor del parámetro no haya un cambio significativo en el valor del MRE o escogiendo el valor del parámetro que ofrezca el mínimo valor de MRE, con ello el número de epoch utilizado fue de 30, este parámetro permite definir el número de iteraciones que todo el conjunto de entrenamiento pasará por el algoritmo de aprendizaje (Gráfico 5).

A continuación, se presenta el rendimiento de los modelos en el conjunto de datos de validación, en términos de error de reconstrucción medio (MRE) de *autoencoder*, utilizando la función de activación Tanh y ReLu y la optimización del número de neuronas en la capa oculta que va desde 10 hasta 600 neuronas.

Gráfico 4. Error de reconstrucción medio con incremento de neuronas
Modelo con función de activación Tanh y ReLu



Fuente: BCE

Elaboración: Autores

Los MRE que usa la función de activación de Tanh muestra valores generales mucho más bajos que para el ReLu. Los MRE para la función de activación ReLu varían de aproximadamente 0,04 a 0,05 y para el Tanh de 0,01 a 0,03. Medimos el rendimiento del modelo examinando la pérdida general (error de reconstrucción medio) en los conjuntos de validación. Cuanto menor sea este valor, mejor se desempeñará el modelo (Sabetti y Heijmans, 2020).

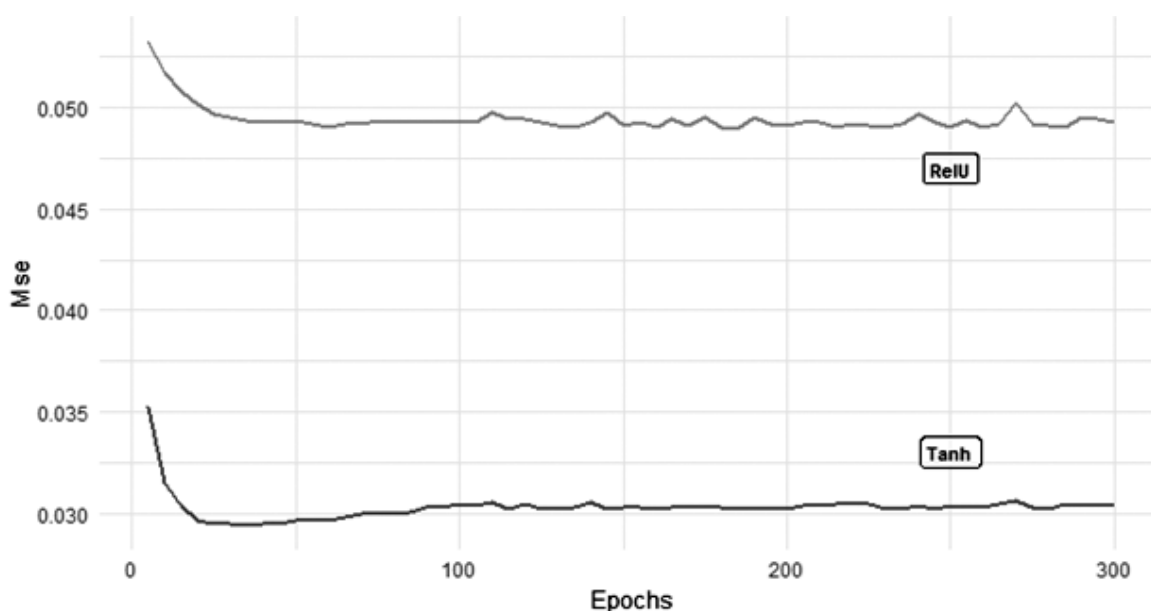
Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

En el *autoencoder* con función de activación Tanh, los errores de reconstrucción disminuyeron rápidamente al aumentar el número de neuronas, después de unas 170 neuronas, se saturó, por lo que es el punto en el que agregar más neuronas no producía un mejor error, similar a (Triepels et al., 2017). Mientras que el *autoencoder* con ReLu los MRE son superiores y más inestables, tardan más en encontrar un número de neuronas en la capa oculta en alrededor de 220 neuronas.

Respecto al número de epochs óptimo, los modelos se comportan de manera similar, es decir, el MRE del conjunto de validación decrece hasta un mínimo y a partir del cual el MRE del conjunto de validación empieza a incrementarse, así tomando como valor óptimo del parámetro el número de epochs correspondiente al MRE mínimo.

Gráfico 5. Error de reconstrucción medio con incremento de EPOCH

Nro. Epoch optimo con función de activación Tanh y ReLu



Fuente: BCE


Elaboración: Autores

Posteriormente, para determinar qué tan bien los *autoencoder* construidos pudieron reconstruir el conjunto de prueba original, se realizó la estimación de *autoencoder* con el conjunto de datos de prueba, estos son datos no vistos por los modelos construidos. Dentro

Jeniffer Rubio y John Arroyo

de este conjunto de datos se encuentran flujos de liquidez que son superiores al percentil 99 de los flujos según la estadística descriptiva.

Gráfico 6. El error de reconstrucción del conjunto de prueba original
Autoencoder con función de activación Tanh (IZQ.) y ReLu (DER.)



Fuente: BCE

Elaboración: Autores

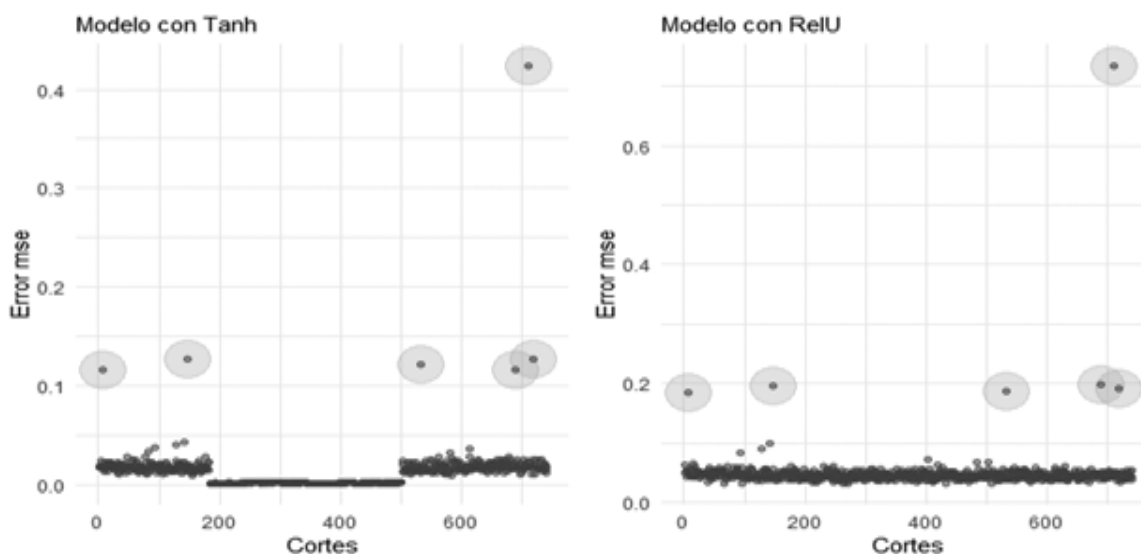
Bajo la consigna de que si el error de reconstrucción de un vector de liquidez es bajo, es un comportamiento o patrón habitual mientras que si el error de reconstrucción es grande, entonces el modelo no reconoce los flujos de liquidez y no puede reconstruir sus valores, en este último caso es una anomalía. El Gráfico anterior muestra los MRE estimados para el periodo de tiempo desde el corte 502 al 741, las curvas de MRE de *autoencoder* son bastante similares y exhiben fluctuaciones en la mayoría de los cortes analizados, existen etapas que los 2 *autoencoder* tuvieron dificultades para reconstruir los vectores de liquidez (Picos). En el caso del *autoencoder* con función de activación Tahn se observa que sus MRE son inferiores en relación a ReLu.

El beneficio de la metodología es que se puede profundizar el error de reconstrucción medio del corte que se detecte como anomalía al nivel del participante individual para obtener una mayor explicación (Sabetti y Heijmans, 2020). Por lo que la tarea pendiente es una examinación más detallada de las alertas. Al revisar de manera general las alertas de anomalías que genera el modelo en relación a la operatividad real del sistema, aparentemente se explica por bajo intercambio de flujos de liquidez en ese corte entre la mayoría de bancos, otros cortes cierto banco no proceso flujos de liquidez que usualmente realizaba.

Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

A continuación, se presenta *autoencoder* por toda la matriz de liquidez, el resultado de los dos modelos entrenados con función de activación Tanh o función de activación Relu. Se detectan 6 principales cortes que los errores de reconstrucción medio son los más elevados respecto a la mayoría de MRE, sin embargo, existe otras alertas con menores MRE superiores a las pruebas de umbrales del ejercicio. Para hacer una comparativa controlada (estadística descriptiva), se realiza la extracción en la base de datos original de los cortes que están sobre el percentil 95 e inferior al percentil 5, obteniendo que los 6 cortes con errores de reconstrucción elevados que alertó el *autoencoder*, están dentro del grupo de los cortes en los percentiles analizados, lo que ayuda a sustentar que el *autoencoder* se encuentra alertando cortes que pueden considerarse atípicos por encontrarse en una posición de extremos. Se debe indicar que al analizar los 6 casos de alertas principales se evidencia que son casos reales en los que existieron comportamientos no comunes dentro del SPI, que podrían alertar estrés de liquidez u otro tipo de fallas de una y/o varias entidades financieras que permitió un normal comportamiento de las entidades conforme otros cortes. Se realiza una breve representación gráfica de las cajas y bigotes de los principales casos en los que se evidencia la existencia de flujos de liquidez atípicos, sin embargo, el *autoencoder* permitió hallar dichas alertas a nivel agregado por corte en función del patrón aprendido por cada flujo.

Gráfico 7. MRE de toda la base de datos




Fuente: BCE

Elaboración: Autores

Jeniffer Rubio y John Arroyo

Gráfico 8. Base de datos original cortes con montos superiores al Percentil 95 y menores al Percentil 5 considerándolos atípicos (Izq.) y comparativo con Alertas principales *autoencoder* (círculos)



Fuente: BCE

Elaboración: Autores


b. Simulaciones: evaluación de *autoencoder*

Dado que no se cuenta con eventos previos sobre flujos de liquidez atípicos en el SPI, para evaluar el rendimiento del *autoencoder* se realizó una simulación de una corrida bancaria de una entidad financiera grande que canaliza operaciones por el SPI. Aplicando la metodología de metodología de Triepels et al. (2017).

Se alteró los flujos de salida de una entidad bancaria (EFI1), hacia el resto de entidades bancarias durante los 2 últimos meses del año, todas las ejecuciones bancarias comenzaron al final del conjunto de prueba en el corte 651 al 741. A continuación se presentan el comportamiento de los datos reales en relación con los alterados en los últimos cortes.

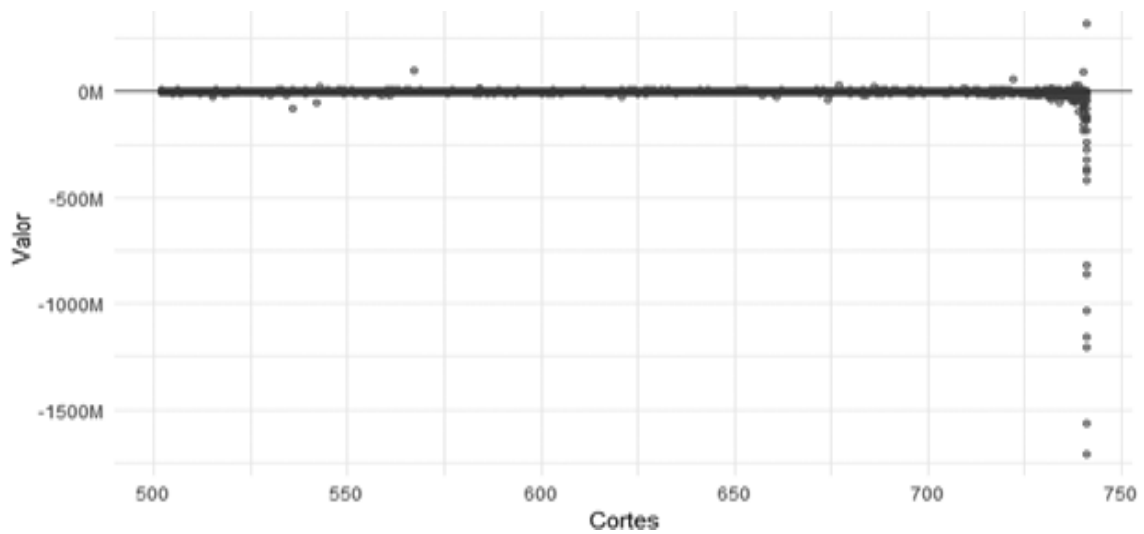
Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

Gráfico 9. Datos reales Flujos de entrada y salida



Fuente: BCE
Elaboración: Autores

Gráfico 10. Datos con banca rota alterado en los últimos cortes

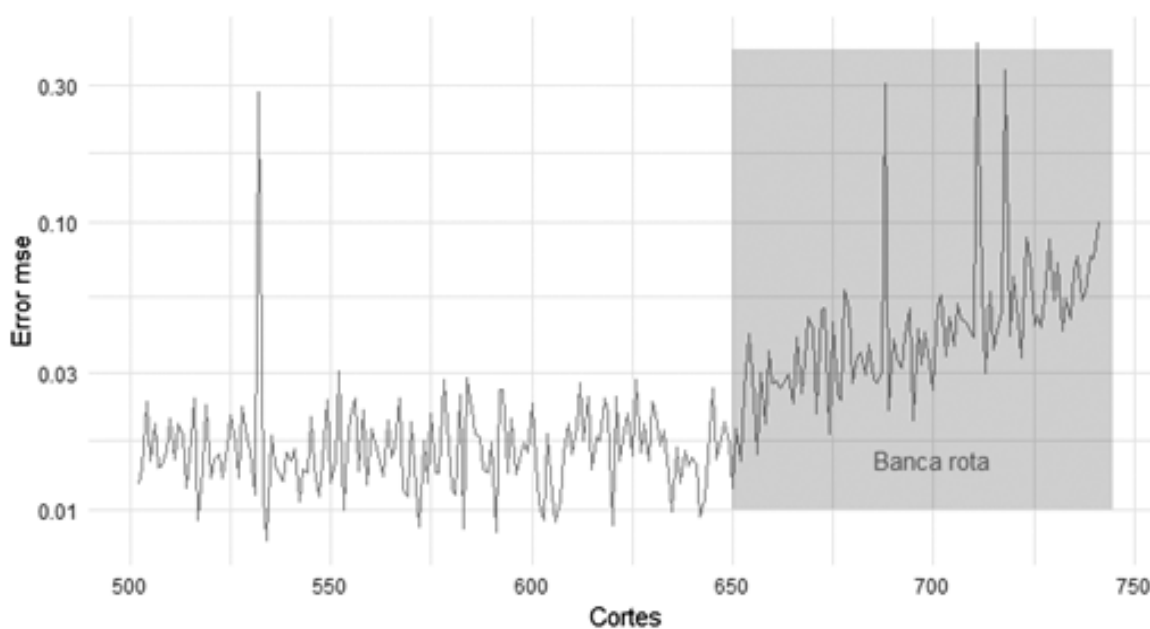


Fuente: BCE
Elaboración: Autores

Jeniffer Rubio y John Arroyo

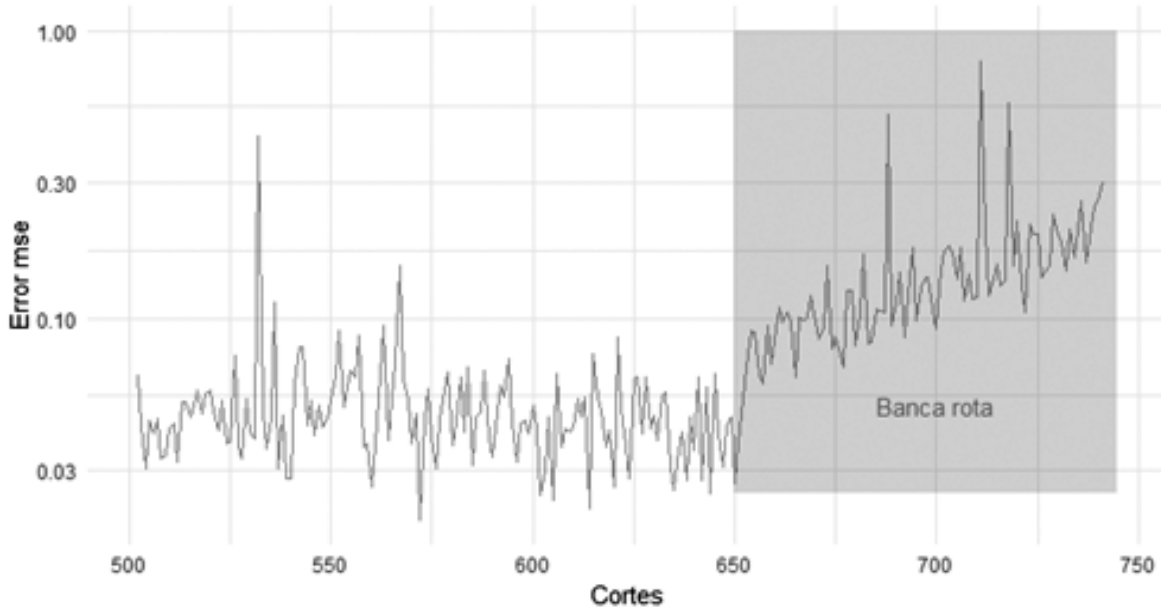
Con los datos simulados, se aplica *autoencoders* construidos con función de activación Tanh y ReLu, y se obtiene los errores de reconstrucción medio (MRE). Las curvas de los resultados de los MRE destacan claramente la corrida bancaria simulada precisamente en los intervalos de tiempo finales. Durante estos intervalos, el error de reconstrucción aumentó rápidamente a medida que la red de pago comenzó a cambiar inesperadamente. Los altos flujos de liquidez salientes del banco estresado no pudieron ser reconstruidos con precisión y causaron un alto error de reconstrucción durante las corridas bancarias. La diferencia entre los dos modelos es que los errores del modelo con Tanh son muchos más estables y menores que los errores del modelo con ReLu.

Gráfico 11. Resultados de Simulación Error cuadrático medio
Modelo con Tanh

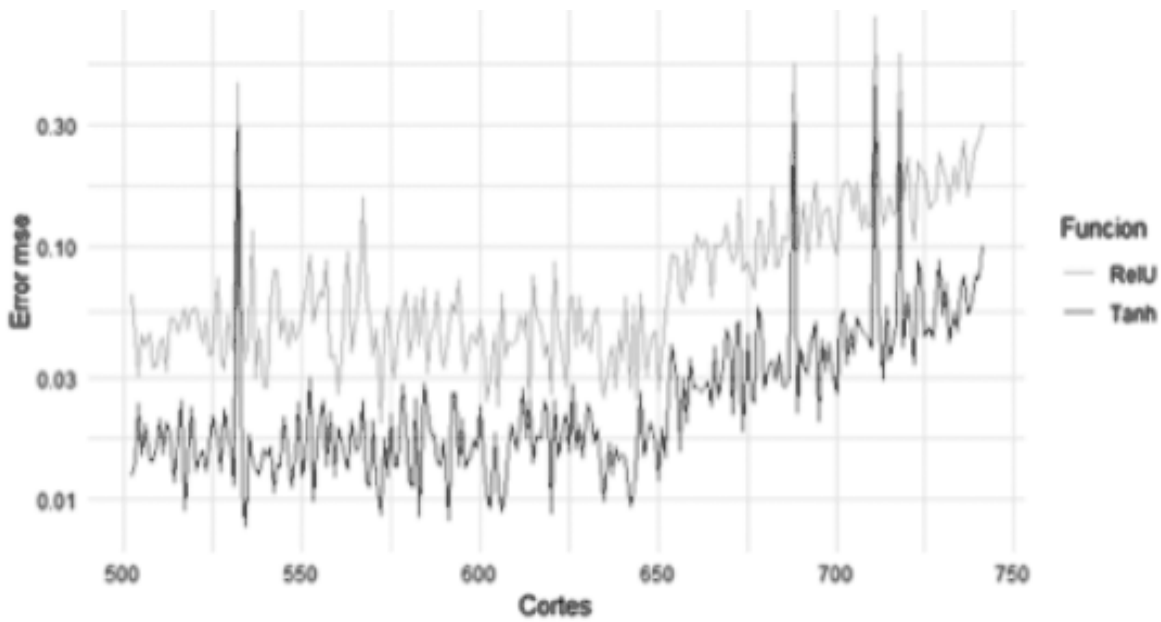


Detección de anomalías en el sistema de pagos del Ecuador: Aplicación de redes neuronales

Modelo con ReLu



Modelo con Tanh y ReLu



Fuente: BCE
Elaboración: Autores

Esto permite probar qué tan bien funciona el *autoencoder* construido en detectar los diferentes tipos de problemas de liquidez. Según los resultados obtenidos, vemos que los *autoencoder* construidos pudieron detectar flujos de pago anómalos.

6. Conclusiones

Los métodos de detección de anomalías, apuntan a identificar observaciones que se desvían de lo que se espera. Estos métodos permiten obtener los patrones por los cuales los bancos usualmente manejan su liquidez dentro de un sistema de pagos y permiten detectar los casos en los que el flujo de pago de alguna entidad se desvía de sus patrones esperados, alertándolos cómo una anomalía. En los sistemas de pagos los comportamientos no esperados pueden ser explicados por problemas de liquidez de una o varias entidades bancarias, problemas operativos o tecnológicos, entre otros. Por lo que es sumamente importante contar con herramientas útiles y automáticas que permitan encontrar esos flujos que se desvían de un comportamiento habitual de pago de una entidad. La metodología propuesta puede ser de utilidad y complementaria para los encargados de supervisar y monitorear los sistemas de pago y la estabilidad financiera.

Este documento realizó la construcción de dos *autoencoder* (redes neuronales), para la detección de anomalías en los flujos procesados por las entidades bancarias en el Sistema de Pagos Interbancarios (SPI) del Ecuador. El *autoencoder* es una técnica de aprendizaje automático no supervisado, consiste en aprender de los datos (capa de entrada) y reconstruir (copiar) en la capa de salida, obteniendo solo las características principales de la información suministrada. El *autoencoder* el momento que identifique un patrón no conocido encuentra problemas en la reconstrucción del dato y alerta cómo anomalía. Se entrenó el modelo con información de pagos entre entidades bancarias durante un periodo de tiempo, en lo posterior se realizó la prueba con un nuevo conjunto de datos nunca vistos por *autoencoder*, pudiendo identificar muy bien cómo anómalos a los flujos superiores al percentil 99 de la base de datos, estadísticamente considerados cómo valores atípicos. Para poder evaluar los modelos se realizó una simulación de corridas bancarias, escogiendo una entidad financiera importante y alterando sus flujos de salida de pagos hacia otras entidades de forma exponencial durante un periodo de tiempo. Los resultados experimentales fueron capaces de reconocer rápidamente el cambio del patrón o comportamiento normal de la entidad y alertan anomalías en los cambios anómalos en los flujos de liquidez entre los bancos. Lo que refleja la

capacidad del *autoencoder* para poder detectar anomalías en el sistema de pagos en el Ecuador.

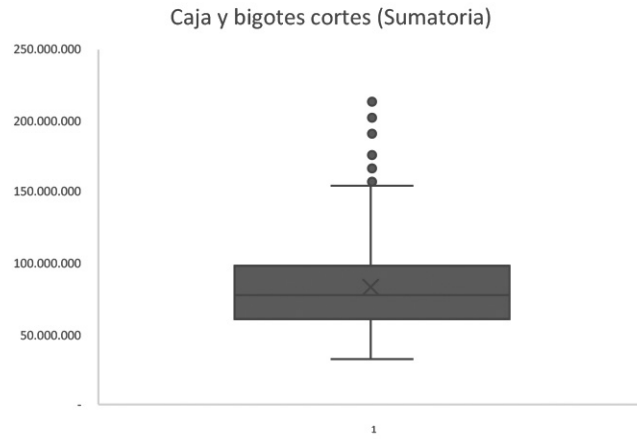
La metodología propuesta en este documento es un primer esfuerzo por aplicar en datos de pagos del Ecuador, lo recogido en Triepels et al. (2017). Para el futuro se debe profundizar más en la construcción del modelo, compararlo con otras técnicas propuestas por otros autores para contrastar los resultados obtenidos, así como la implementación de hiperparámetros del *autoencoder* que permita obtener mejores resultados ejemplo (validación cruzada, mayores números de capas, otros tipos de *autoencoder*, entre otros.) que pueden contribuir a una mejor detección de anomalías.

Bibliografía

- Comité de Sistemas de Pago y Liquidación y Comité Técnico de la Organización Internacional de Comisiones de Valores** (2012) Principios aplicables a las infraestructuras del mercado financiero Banco de Pagos Internacionales.
- Banco de Inglaterra**, 2012 (marzo). Payment Systems Oversight Report 2012. Londres: Bank of England.
- Fan, C., Xiao, F., Zhao, Y., & Wang, J.** (2018). Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data. *Applied energy*, 211, 1123-1135.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*. MIT press.
- Heijmans, R., & Heuver, R.** (2011). Is this bank ill? The diagnosis of doctor TARGET2.
- Heijmans, R., & Zhou, C.** (2019). Outlier detection in TARGET2 risk indicators.
- Heuver, R., & Triepels, R.** (2019). Liquidity stress detection in the European banking sector. De Nederlandsche Bank Working Paper No. 642, June 2019.
- León, C.** (2019). Detecting anomalous payments networks: A dimensionality reduction approach. Banco de la Republica de Colombia.
- Pumsirirat, A., & Yan, L.** (2018). Credit card fraud detection using deep learning based on auto-encoder and restricted boltzmann machine. *International Journal of advanced computer science and applications*, 9(1), 18-25.
- Sabeti L. & Heijmans R.** (2020), Shallow or deep? Detecting anomalous flows in the Canadian Automated Clearing Settlement System using an autoencoder. *Payments Canada*.
- Summers, 2012** Summers B. *Payment Systems: Design Governance and Oversight*. Londres: Central Banking Publications; 2012.
- Thottan, M., Liu, G., Ji, C.** (2010). Anomaly Detection Approaches for Communication Networks. In: Cormode, G. & Thottan, M. (eds.) *Algorithms for Next Generation Networks*. Computer Communications and Networks. Springer: London.
- Triepels, R., Daniels, H., & Heijmans, R.** (2017, April). Detection and explanation of anomalous payment behavior in real-time gross settlement systems. In *International Conference on Enterprise Information Systems* (pp. 145-161). Springer, Cham.
- Zamini, M., & Montazer, G.** (2018, December). Credit card fraud detection using autoencoder based clustering. In *2018 9th International Symposium on Telecommunications (IST)* (pp. 486-491). IEEE.

Anexo

A continuación, se utiliza la técnica de caja y bigotes para realizar una representación de montos totales por corte y sus valores atípicos. Se debe indicar que este análisis contempla todos los flujos intercambiados entre las entidades financieras, sin embargo, no considera su comportamiento habitual individualmente conforme la metodología *autoencoder*.



Cortes por flujos de principales ALERTAS

