

UNIVERSIDAD DE COSTA RICA
SISTEMA DE ESTUDIOS DE POSGRADO

USO DE REDES NEURONALES PARA EL RECONOCIMIENTO DE PATRONES DEL
COMPORTAMIENTO DE LAS ENTIDADES BANCARIAS EN EL SISTEMA
NACIONAL DE PAGOS ELECTRÓNICOS (SINPE)

Trabajo final de investigación aplicada sometido a la consideración de la Comisión del
Programa de Posgrado en Economía para optar al grado y título de Maestría Profesional en
Finanzas y Riesgo

HAZEL BRENES UMAÑA

Ciudad Universitaria Rodrigo Facio, Costa Rica

2025

DEDICATORIA

A Minor, quien ha sido mi compañero de aventuras y mi soporte durante más de ocho años, y quien además me motivó a llevar esta maestría.

AGRADECIMIENTO

Ante todo, agradezco a Dios, quien nunca ha dejado de sorprenderme con sus bendiciones.

A mi familia, quienes siempre me han apoyado en mis proyectos y me han inspirado a dar lo mejor de mí.

A los profesores de la maestría, por los conocimientos compartidos y las valiosas enseñanzas durante el desarrollo de los cursos. De manera especial, agradezco a José Pablo, César y Carlos, por su generosa disposición a integrar el comité evaluador y por sus significativos aportes a la elaboración de este trabajo.

Este trabajo final de investigación aplicada fue aceptado por la Comisión del Programa de Posgrado en Economía de la Universidad de Costa Rica, como requisito parcial para optar al grado y título de Maestría Profesional en Finanzas y Riesgo.

M.B.A. Cinthya Arias Leitón
**Representante de la Decanatura
Sistema de Estudios de Posgrado**

Dr. José Pablo Barquero Romero
Profesor Guía

M.Sc. César Ulate Sancho
Lector

M.Sc. Carlos Mora Gómez
Lector

Dr. Edgar Robles Cordero
**Director
Programa de Posgrado en Economía**

Hazel Brenes Umaña
Sustentante

TABLA DE CONTENIDO

DEDICATORIA	II
AGRADECIMIENTO	III
HOJA DE APROBACIÓN	IV
TABLA DE CONTENIDO	V
RESUMEN EN ESPAÑOL	VIII
ABSTRACT	IX
LISTA DE CUADROS	X
LISTA DE TABLAS	XI
LISTA DE FIGURAS	XII
LISTA DE ILUSTRACIONES	XIV
LISTA DE ABREVIATURAS	XV
1 GENERALIDADES	1
1.1 INTRODUCCIÓN	1
1.2 JUSTIFICACIÓN	3
1.3 OBJETIVOS	5
1.3.1 OBJETIVO PRINCIPAL	5
1.3.2 OBJETIVOS ESPECÍFICOS	5
1.4 ALCANCE	5
1.5 LIMITACIONES	6
2 MARCO TEÓRICO	7
2.1 ESTABILIDAD FINANCIERA	7
2.2 ASPECTOS GENERALES DE LOS SISTEMAS DE PAGO	8
2.3 RIESGO SISTÉMICO Y ESTABILIDAD EN LOS SISTEMAS DE PAGO	9
2.4 ESTUDIOS ANTERIORES RELACIONADOS	12
2.5 RECONOCIMIENTO DE PATRONES	14

3	MÉTODOS Y MATERIALES	16
3.1	DATOS Y FUENTES DE INFORMACIÓN	16
3.2	INDICADORES DE LIQUIDEZ INTRADÍA.....	19
3.3	TOPOLOGÍA DE REDES.....	23
3.4	ANÁLISIS DE COMPONENTES PRINCIPALES.....	26
3.4.1	<i>DEFINICIÓN.....</i>	26
3.4.2	<i>SELECCIÓN DE LA CANTIDAD</i>	26
3.5	REDES NEURONALES ARTIFICIALES.....	28
4	ANÁLISIS DE RESULTADOS.....	31
4.1	RESULTADOS INDICADORES DE HÁBITOS DE PAGO	31
4.1.1	<i>REQUERIMIENTO MÁXIMO DIARIO DE LIQUIDEZ.....</i>	32
4.1.2	<i>SALDO INICIAL EN LA CUENTA DE RESERVA.....</i>	39
4.1.3	<i>PAGOS ENVIADOS Y RECIBIDOS.....</i>	40
4.1.4	<i>OBLIGACIONES A HORAS ESPECÍFICAS Y OTRAS OBLIGACIONES CRÍTICAS</i>	42
4.1.5	<i>HORA DE LOS PAGOS INTRADÍA.....</i>	44
4.1.6	<i>DISTRIBUCIÓN HORARIA</i>	46
4.1.7	<i>CORRELACIONES ENTRE VARIABLES DE HÁBITOS DE PAGO.....</i>	47
4.2	RESULTADOS ANÁLISIS DE TOPOLOGÍA DE REDES	50
4.2.1	<i>RED SERVICIOS DE LIQUIDACIÓN BRUTA EN TIEMPO REAL (LBTR) ..</i>	50
4.2.2	<i>RED MERCADO INTEGRADO DE LIQUIDEZ (MIL)</i>	53
4.2.3	<i>RED MERCADO DE MONEDAS EXTRANJERAS (MONEX)</i>	57
4.3	RESULTADOS ANÁLISIS DE COMPONENTES PRINCIPALES.....	60
4.3.1	<i>ACP INDICADORES DE HÁBITOS DE PAGO</i>	60
4.3.2	<i>ACP INDICADORES DE REDES</i>	64
4.4	RESULTADOS REDES NEURONALES ARTIFICIALES.....	66
5	CONCLUSIONES Y RECOMENDACIONES	70
5.1	CONCLUSIONES.....	70
5.2	RECOMENDACIONES.....	75
	REFERENCIAS BIBLIOGRÁFICAS.....	77

APÉNDICES	82
APÉNDICE A. EJEMPLOS DE TIPOS DE LIQUIDACIÓN	82
APÉNDICE B. RESUMEN DE LAS PRINCIPALES CARACTERÍSTICAS DE LAS REDES CONSTRUIDAS EN ALGUNOS ESTUDIOS QUE UTILIZAN INFORMACIÓN DE SISTEMAS DE PAGO	84
APÉNDICE C. RESULTADOS GRÁFICOS DEL ANÁLISIS DE CONGLOMERADOS DE K MEDIAS UTILIZANDO COMO VARIABLES LOS ESTADÍSTICOS DESCRIPTIVOS DE LAS SERIES DE LOS INDICADORES DE HÁBITOS DE PAGO	85
APÉNDICE D. RESULTADOS DEL ANÁLISIS EN COMPONENTES PRINCIPALES (ACP).....	89
APÉNDICE E. RESULTADOS DEL ANÁLISIS DE REDES NEURONALES	97
ANEXOS.....	98
ANEXO A: LISTA DE SERVICIOS Y CÓDIGOS DE MOTIVOS SINPE.....	98
ANEXO B: REPRESENTACIÓN MATEMÁTICA DEL MODELO MLP SEGÚN GÜNTER Y FRITSH (2010)	99
ANEXO C: DETERMINACIÓN DE LOS COMPONENTES PRINCIPALES SEGÚN JOHNSON (2000).....	100

RESUMEN EN ESPAÑOL

Con el propósito de aproximar el patrón del comportamiento de las entidades del sistema bancario nacional (SBN) en el Sistema Nacional de Pagos Electrónicos (SINPE) del Banco Central de Costa Rica (BCCR) se aplicó la técnica de redes neuronales, utilizando tanto indicadores de hábitos de pago, como indicadores de centralidad de la red de transferencias de fondos y de los mercados de negociación construidos a partir de más de 336 millones de registros correspondientes al periodo comprendido entre el 2018 y el 2022. Se utilizaron técnicas de validación cruzada para evaluar el desempeño de las redes neuronales. Luego de ejecutar 100 procesos de entrenamiento independientes se seleccionó un modelo con una capa oculta y 20 neuronas con un error medio de clasificación de 0,88% en la muestra de entrenamiento y de un 3,12% en la muestra de prueba. La metodología presentada aquí es sólo una propuesta preliminar debido a la falta de evaluación en momentos de tensión de las entidades y la evaluación por parte de expertos, no obstante, puede llegar a convertirse en una importante herramienta que contribuya a mejorar las tareas de supervisión y vigilancia de las autoridades financieras, especialmente en el diseño de sistemas de alerta temprana.

ABSTRACT

With the intention to approximate the pattern recognition of financial institutions' payment behavior in the National System of Electronic Payments (SINPE) managed by the Central Bank of Costa Rica, the artificial neural networks technique (machine learning) was applied, using indicators of payment habits, centrality in the funds transfer network and centrality in trading markets network calculated handling more than 336 million records corresponding to the period from 2018 to 2022. Cross-validation techniques were applied to evaluate the performance of the neural networks. After running 100 independent training processes, a model with a hidden layer and 20 neurons was selected with a mean classification error of 0.88% in the training sample and 3.12% in the validation sample. The methodology presented here is only a preliminary proposal due to the lack of evaluation in times of stress of the entities and evaluation by experts, however, it may become an important tool that contributes to improve the supervision and surveillance tasks of the financial authorities, especially in the design of early warning systems.

LISTA DE CUADROS

Cuadro 3.1. Cantidad de registros en la base de movimientos del SINPE por año. 2018-2022	18
Cuadro 4.1. Estadísticas básicas de la red de servicios de LBTR por moneda. Promedios diarios y desviaciones estándar 2018-2022	50
Cuadro 4.2. Correlaciones entre los indicadores de propiedad en los vértices para la red de transacciones de servicios de LBTR por moneda.....	53
Cuadro 4.3. Estadísticas básicas de la red de MIL por moneda. Promedios diarios y desviaciones estándar 2018-2022	54
Cuadro 4.4. Correlaciones entre los indicadores de propiedad en los vértices para la red de negociaciones del MIL por moneda.....	57
Cuadro 4.5. Estadísticas básicas de la red de Monex. Promedios diarios y desviaciones estándar 2018-2022.....	58
Cuadro 4.6. Correlaciones entre los indicadores de propiedad en los vértices para la red de negociaciones del Monex.....	60
Cuadro 4.7. Resultados ACP de indicadores de hábitos de pago en colones: Eigenvalores	62
Cuadro 4.8. Resultados ACP de indicadores de hábitos de pago en dólares: Eigenvalores.	63
Cuadro 4.9. Resultados ACP de redes: Eigenvalores	64
Cuadro 4.10. Error medio de clasificación y desviación estándar para diferentes elecciones del número de neuronas en la capa oculta según conjunto de datos - calculado sobre 100 procesos de entrenamiento diferentes –	67

LISTA DE TABLAS

Tabla 3.1. Indicadores de seguimiento del manejo de la liquidez intradía.....	19
Tabla 3.2. SINPE: servicios de liquidación neta	21
Tabla 3.3. Propiedades de los vértices (centralidad)	25
Tabla 4.1. Variables de hábitos de pago incorporadas para el Análisis de Componentes Principales.....	61
Tabla 4.2. Variables de análisis de redes incorporadas para el Análisis de Componentes Principales.....	64

LISTA DE FIGURAS

Figura 4.1. SINPE: Monto de los pagos liquidados según moneda y tipo de entidad. 2018-2022	31
Figura 4.2. SBN: Montos diarios de la mayor salida neta en las cuentas de fondos en el BCCR por banco origen y moneda de liquidación. 2018-2022.....	33
Figura 4.3. SBN: Distribución de los montos diarios de la mayor salida neta en las cuentas de fondos en el BCCR por banco origen y moneda de liquidación. 2018-2022.....	35
Figura 4.4. SBN: Montos diarios de la mayor entrada neta en las cuentas de fondos en el BCCR por banco destino y moneda de liquidación. 2018-2022.....	36
Figura 4.5. SBN: Distribución de los montos diarios de la mayor entrada neta en las cuentas de fondos en el BCCR por banco destino y moneda de liquidación. 2018-2022	38
Figura 4.6. SBN: Saldo inicial en las cuentas de fondos en el BCCR por banco y moneda. Cifras diarias 2018-2022.....	39
Figura 4.7. SBN: Pagos enviados y recibidos en las cuentas de fondos en el BCCR por banco y moneda. Cifras diarias 2018-2022	41
Figura 4.8. SBN: Montos liquidados en servicios de liquidación neta por banco origen y moneda. Cifras diarias 2018-2022	43
Figura 4.9. SBN: Hora promedio de los pagos enviados y recibidos por banco y moneda. Cifras diarias 2018-2022.....	45
Figura 4.10. SBN: Porcentaje acumulado de pagos enviados según hora por banco y moneda. Cifras diarias 2018-2022.....	46
Figura 4.11. Matriz de correlaciones variables hábitos de pago por moneda.....	48
Figura 4.12. SBN: Caras de Chernoff para variables de hábitos de pago. Promedios sobre cifras diarias 2018-2022.....	49
Figura 4.13. Red transacciones de servicios de LBTR del SINPE en colones a diciembre de cada año. 2018-2022.....	51

Figura 4.14. Red transacciones de servicios de LBTR del SINPE en dólares a diciembre de cada año. 2018-2022.....	52
Figura 4.15. Red negociaciones en MIL colones a diciembre de cada año. 2018-2022.....	55
Figura 4.16. Red negociaciones en MIL dólares a diciembre de cada año. 2018-2022.	56
Figura 4.17. Red negociaciones en Monex a diciembre de cada año. 2018-2022.....	59
Figura 4.18. Resultados ACP de indicadores de hábitos de pago en colones: Puntajes de los 2 primeros componentes principales (PC).....	62
Figura 4.19. Resultados ACP de indicadores de hábitos de pago en dólares: Puntajes de los 2 primeros componentes principales (PC).....	63
Figura 4.20. Resultados ACP indicadores por red: Puntajes de los 2 primeros componentes principales (PC)	65
Figura 4.21. Error promedio de clasificación para diferentes elecciones del número de neuronas en la capa oculta según conjunto de datos - calculado sobre 100 procesos de entrenamiento diferentes -	67
Figura 4.22. Distribución del error de clasificación para diferentes elecciones del número de neuronas en la capa oculta - calculado sobre 100 procesos de entrenamiento diferentes - .	68
Figura 4.23. Matriz de confusión y porcentaje de acierto en datos de prueba -el error de clasificación más bajo se consiguió en una ejecución con 20 neuronas-.....	69

LISTA DE ILUSTRACIONES

Ilustración 1.1. Flujo de fondos a través del sistema financiero.....	2
Ilustración 2.1. Pasos básicos para realizar una tarea de aprendizaje automático	15
Ilustración 3.1. Progreso de desarrollo del SINPE	17
Ilustración 3.2. Requerimiento máximo diario de liquidez	20
Ilustración 3.3. Red cometa	23
Ilustración 3.4. Red transacciones de servicios LBTR del SINPE en colones en diciembre de 2018.	24
Ilustración 3.5. Ejemplo Scree Plot	27
Ilustración 3.6. Ejemplo de una red neuronal con dos neuronas de entrada (A y B), una neurona de salida (Y) y una capa oculta que consta de tres neuronas ocultas.....	29

LISTA DE ABREVIATURAS

ACP	Análisis de Componentes Principales
BCBS	Comité de Supervisión Bancaria de Basilea (<i>Basel Committee on Banking Supervision</i>)
BCCR	Banco Central de Costa Rica
BIS	Banco de Pagos Internacionales (<i>Bank for International Settlements</i>)
CPMI	Comité de Pagos e Infraestructuras del Mercado (<i>Committee on Payments and Market Infrastructures</i>)
CPSS	Comité de Sistemas de Pago y Liquidación (<i>Committee on Payment and Settlement Systems</i>)
ECB	Banco Central Europeo (<i>European Central Bank</i>)
FMI	Fondo Monetario Internacional
GLM	Modelo Lineal Generalizado (<i>Generalized Linear Model</i>)
IBAN	<i>International Bank Account Number</i>
LBTR	Liquidación Bruta en Tiempo Real
MIL	Mercado Integrado de Liquidez
MLP	Perceptrón Multicapa (<i>Multilayer perceptrón</i>)
MONEX	Mercado de Monedas Extranjeras
RNA	Red Neuronal Artificial
RSP	Reglamento del Sistema de Pagos
SBN	Sistema Bancario Nacional
SINPE	Sistema Nacional de Pagos Electrónicos
SINPE-TP	SINPE Transporte Público
SP	Sistema de Pagos
TR	Topología de Redes

1 GENERALIDADES

1.1 INTRODUCCIÓN

Los bancos centrales tienen un interés fuerte y natural en salvaguardar la estabilidad financiera. Sobre todo, porque las instituciones financieras, en particular los bancos, son los emisores de la mayor parte de la masa monetaria. Del mismo modo, un sistema financiero estable es necesario para la transmisión eficaz de la política monetaria y para el buen funcionamiento de los sistemas de pago (European Central Bank, 2005).

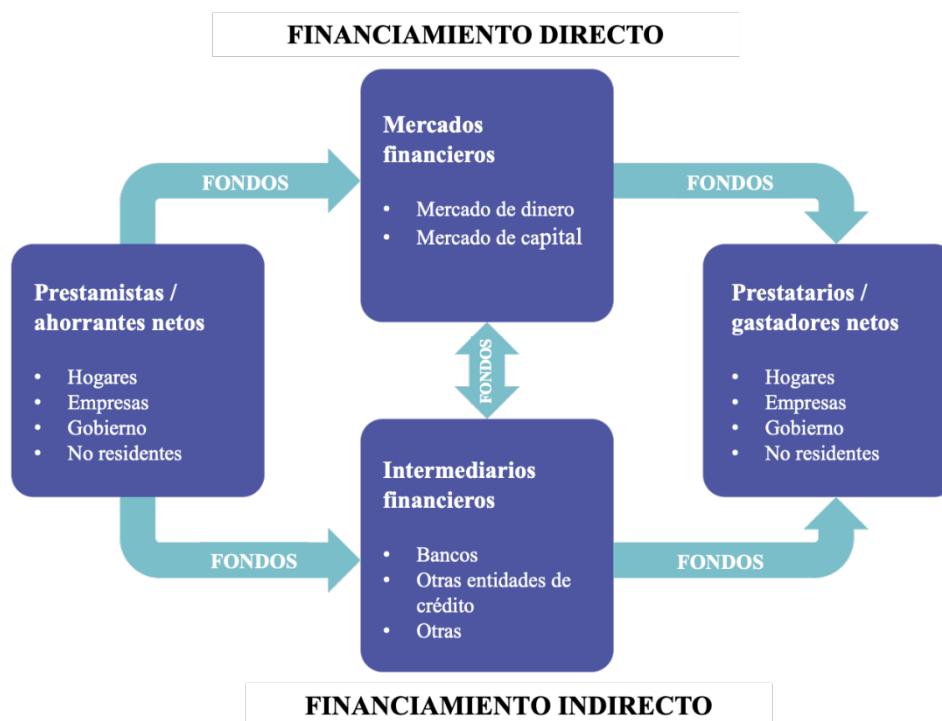
El sistema financiero comprende las entidades de préstamo bancarias y no bancarias, las empresas de seguros, los mercados de valores y los fondos de inversión. Pero, también abarca los sistemas de compensación, los sistemas de pagos, los bancos centrales y los sistemas regulatorios y de supervisión financiera. Estas instituciones aportan el marco necesario para efectuar transacciones económicas y conducir la política monetaria, y para canalizar el ahorro hacia la inversión, promoviendo así el crecimiento económico (Fondo Monetario Internacional, s.f.)

En la Ilustración 1.1 se muestra el proceso mediante el cual los mercados financieros ejecutan la función económica esencial de canalizar los fondos de las familias, las empresas y los gobiernos que han ahorrado sus excedentes al gastar una cantidad menor a su ingreso, a aquellos que tienen un déficit de fondos porque han gastado una cantidad mayor a sus ingresos. Aquellos que han ahorrado y que han estado prestando sus fondos, los prestamistas, están a la izquierda, y aquellos que deben solicitar fondos en préstamo para financiar su gasto, los prestatarios, aparecen en el lado derecho (Mishkin, 2016).

Los fondos fluyen de los prestamistas a los prestatarios por dos vías. En la financiación directa o basada en el mercado, los deudores toman fondos prestados directamente de inversores que operan en los mercados financieros vendiéndoles instrumentos financieros, también llamados títulos (como títulos de deuda y acciones), que son derechos sobre los ingresos o activos futuros del prestatario. Si los intermediarios financieros desempeñan un

papel adicional en la canalización de fondos, se habla de financiación indirecta (Bank of Finland, 2023).

Ilustración 1.1. Flujo de fondos a través del sistema financiero



Fuente: Elaboración propia con base en *Bank of Finland* (2023)

Las infraestructuras del sistema financiero se refieren a los sistemas de pago y liquidación, a través de los cuales se realizan concretamente las operaciones de los mercados financieros. Un funcionamiento fluido y fiable de los sistemas de pago y liquidación favorece la eficacia de los movimientos de capital en la economía y, por tanto, apoya la estabilidad financiera (Bank of Finland, 2023).

La estabilidad financiera puede definirse como una situación en la que el sistema financiero es capaz de resistir perturbaciones y una corrección brusca de los desequilibrios financieros (Banco Central Europeo, 2017).

Como respuesta de los países a la crisis financiera del 2008 se dieron avances prácticos e intelectuales en el análisis de la estabilidad financiera, uno de los más importantes es quizás

el abordaje del fenómeno de forma sistémica, dejando atrás normas microprudenciales enfocadas en entidades financieras individuales y surgiendo el enfoque macroprudencial.

El prefijo “macro” indica que una política o medida se dirige al conjunto del sistema financiero o a partes significativas del mismo, en lugar de a entidades financieras individuales. Dado que “prudencia” es la cualidad de obrar con precaución, las políticas prudenciales comprenden medidas que promueven buenas prácticas y limitan la asunción de riesgos. En consecuencia, las políticas macroprudenciales contribuyen a asegurar que todos los agentes actúen con precaución frente a riesgos potencialmente sistémicos, es decir, que pueden afectar al conjunto del sistema financiero (Banco Central Europeo, 2017).

Los objetivos centrales de un marco para salvaguardar la estabilidad financiera son la prevención y resolución de problemas financieros sistémicos. Una clave de la prevención es la identificación temprana de los riesgos para la estabilidad, y de las fuentes potenciales de vulnerabilidad en el sistema financiero antes de que conduzcan a desequilibrios y consecuencias insostenibles y potencialmente perjudiciales. Por su parte, la clave de la resolución consiste en disponer de mecanismos y herramientas de política para remediar situaciones en las que el sistema financiero parece avanzar hacia la inestabilidad (European Central Bank, 2005).

Por estas razones, los bancos centrales que tienen el mandato de velar (fomentar) por la estabilidad del sistema financiera realizan el seguimiento y la evaluación del sistema financiero como un todo, esto debido a que las debilidades y vulnerabilidades podrían existir en cualquiera de los componentes del sistema financiero - instituciones, mercados o infraestructuras - y podrían implicar a los tres simultáneamente. En consecuencia, las evaluaciones de la estabilidad financiera son una parte fundamental de la prevención de problemas financieros sistémicos (European Central Bank, 2005).

1.2 JUSTIFICACIÓN

La crisis financiera del 2008 dejó en evidencia la importancia de la identificación y gestión de riesgos tanto dentro de las entidades financieras, así como por parte de sus reguladores. A

partir de esta fecha, los diferentes actores de los sistemas financieros de los países alrededor del mundo redoblaron los esfuerzos en investigaciones de temas relacionados.

En línea con lo anterior Heijmans y Heuver (2011) plantean el uso de los datos de las transacciones de los sistemas de pago de alto valor para identificar tempranamente e inclusive en tiempo real problemas de liquidez en las entidades bancarias. Estos autores argumentan que previo a los problemas de solvencia las entidades comienzan a afrontar problemas de liquidez y que los bancos centrales cuentan con información en sus sistemas de pago para hacer esta valoración.

Una forma tradicional de detectar una anomalía en el comportamiento de una institución financiera consiste en determinar lo que debe considerarse un patrón normal a partir de sus registros históricos. En ese sentido, diversos estudios han mostrado la robustez de las redes neuronales cuando el objetivo es la modelación predictiva sobre la explicativa.

Además de la información sobre hábitos de fondeo León et al. (2020) en un estudio sobre el comportamiento de pago de las instituciones financieras a partir de una base de datos de transacciones del sistema de pagos de alto valor de Colombia, comprobaron que la centralidad en la red de pagos y el impacto sistémico son características que efectivamente mejoran el desempeño de la modelación predictiva. Por tanto, en esta investigación, como complemento a los indicadores de hábitos de fondeo de las entidades se va a valorar el aporte de dicha información en el modelo predictivo para el caso costarricense.

Como se señaló previamente, la implementación de modelos de patrones puede ser de gran utilidad para señalar anomalías o cambios de tendencia, que a su vez pueden contribuir como sistemas de alerta temprana.

Aunque actualmente, el Banco Central de Costa Rica (BCCR) cuenta con una serie de indicadores calculados a partir de la información del Sistema Nacional de Pagos Electrónicos (SINPE), algunos de ellos se actualizan diariamente, otros han sido calculados solo esporádicamente o para estudios puntuales.

El análisis que se hace hoy en día de la situación de una entidad a partir de la información contenida en los indicadores que se calculan diariamente, queda a discrecionalidad del analista, ya que no se cuenta con un protocolo establecido que defina a partir de cuántos indicadores que muestran un cambio de tendencia se considera un cambio en el comportamiento de la entidad.

Por tanto, el resultado de esta investigación puede complementar el conjunto de herramientas con las que cuenta hoy en día el BCCR para dar seguimiento a las entidades, permitiendo una valoración objetiva en forma conjunta del comportamiento de un grupo de indicadores.

1.3 OBJETIVOS

1.3.1 OBJETIVO PRINCIPAL

Encontrar un modelo capaz de representar el comportamiento de pago de las entidades bancarias a partir de la base de datos de transacciones del SINPE del BCCR. La implementación de modelos de patrones puede ser de gran utilidad para señalar anomalías o cambios de tendencia, que a su vez pueden contribuir como sistemas de alerta temprana.

1.3.2 OBJETIVOS ESPECÍFICOS

- Establecer un conjunto de indicadores sobre hábitos de fondeo, momento y concentración de pagos.
- Realizar un análisis descriptivo de la red de pagos mediante la técnica de topología de redes.
- Utilizar la técnica de topología de redes para identificar a los participantes con un mayor impacto sistémico.

1.4 ALCANCE

La primera parte de este trabajo de investigación tiene un alcance descriptivo cuyo objetivo es generar series estadísticas e indicadores a partir de la información del SINPE. Dicha información va a ser el insumo principal durante la segunda parte de la investigación que es

de carácter predictivo, en donde los indicadores calculados van a ser utilizados como covariables en la construcción del modelo de reconocimiento de patrones mediante el método de redes neuronales.

En el año 2022, el SINPE contó con 114 participantes que incluyen, además del BCCR, 13 bancos comerciales, 2 bancos creados por leyes especiales, 2 mutuales de ahorro y préstamo, 15 puestos de bolsa, 25 cooperativas de ahorro y crédito, 6 operadoras de pensiones, 5 compensadores externos, 18 entidades de gobierno, 23 proveedores de servicios de pago y otros, además de 4 bancos extranjeros. No obstante, el presente trabajo de investigación se va a limitar al análisis de las 14 entidades bancarias que conforman el Sistema Bancario Nacional (SBN).

Las cifras utilizadas para el análisis corresponden a los días hábiles del periodo comprendido entre enero 2018 y diciembre 2022.

1.5 LIMITACIONES

En concordancia con lo establecido en el artículo 20 de la *Ley del Sistema de Estadística Nacional* (Ley 9694), relativo a la confidencialidad de la información. Los resultados de la presente investigación se van a presentar sin revelar nombres o en forma agregada cuando los valores individuales permitan la identificación inmediata de los interesados, o bien, que por su estructura, contenido o grado de desagregación conduzcan a la identificación indirecta de estos.

Una segunda limitación de este trabajo se da por el hecho que no se cuenta con una entidad bancaria que en el periodo de análisis haya presentado fallas. Lo cual impide la valoración de la metodología planteada como sistema de alerta temprana.

2 MARCO TEÓRICO

2.1 ESTABILIDAD FINANCIERA

Aunque muchos autores delimitan la estabilidad financiera en términos de la ausencia de perturbaciones, Schinasi (2004) la define de la siguiente manera “*un sistema financiero está en un rango de estabilidad cuando es capaz de facilitar (en lugar de impedir) el desempeño de una economía, y de disipar desequilibrios financieros que surgen en forma endógena o como resultado de serios eventos adversos no anticipados*”.

De esta definición el autor destaca lo siguiente: primero, la definición incluye la totalidad del sistema financiero, y no solamente instituciones y mercados específicos. Segundo, se define un rango de estabilidad y no solamente estabilidad financiera como un estadio específico del sistema financiero. El concepto de rango da la idea de un continuo de situaciones en las cuales un sistema financiero es estable y, por tanto, de un continuo de situaciones donde el sistema no lo es. Tercero, se destaca la contribución del sistema financiero en cuanto a facilitar (en lugar de impedir) el desempeño de la economía. Es decir, se hace énfasis en la capacidad de los sistemas financieros para asignar recursos y distribuir riesgos de forma de contribuir al desarrollo económico. Cuarto, la frase “*disipar desequilibrios financieros*” incorpora la idea de avanzar a lo largo de un continuo de posibilidades en la dirección de la estabilidad financiera, alejándose de sus fronteras tanto como sea posible. Quinto, la definición considera el caso que estos desequilibrios emerjan en forma endógena. Este aspecto de la definición es de suma importancia, especialmente para los sistemas bancarios, a la luz de la evidencia histórica que indica que dichos sistemas son especialmente vulnerables al desarrollo de desequilibrios y fragilidades que derivan en problemas de inestabilidad.

A partir de la definición anterior Ponce y Tubio (2010) plantean algunos problemas prácticos a la hora de evaluar la estabilidad de un sistema financiero y de implementar acciones para su preservación. De estos, se señala como el primero de ellos que “*la estabilidad financiera no puede ser resumida en un único indicador*”. Según estos autores, la estabilidad financiera es un concepto que involucra múltiples dimensiones. Además, estas dimensiones pueden adquirir diferente importancia dependiendo de las circunstancias. Esta característica del concepto de estabilidad financiera representa una importante diferencia con, por ejemplo, el

concepto de estabilidad de precios. En este caso, la tasa de inflación es un buen indicador de resumen.

Este último aspecto es importante por cuanto destaca la importancia del desarrollo de metodologías que consideren el análisis conjunto de múltiples indicadores para tener una perspectiva holística al momento de dar seguimiento a la estabilidad del sistema financiero.

2.2 ASPECTOS GENERALES DE LOS SISTEMAS DE PAGO

El Banco de Pagos Internacionales (BIS por sus siglas en inglés) define un sistema de pagos como el “*conjunto de instrumentos, procedimientos bancarios y sistemas de transferencia de fondos interbancarios que aseguran la circulación del dinero*” (Comité de Sistemas de Pago y Liquidación [CPSS-BIS], 2003)¹. De esta forma, el buen funcionamiento de los sistemas de compensación y liquidación de fondos y valores resulta fundamental para el desarrollo y la estabilidad financiera de un país (Cerdas & Melegatti, 2014).

Entre las principales funciones de los sistemas de pago se encuentra el intercambio seguro y eficiente de fondos entre agentes económicos para facilitar las transacciones comerciales. Al asemejarlos con un mercado, los sistemas de pago son infraestructuras de intercambio de obligaciones y derechos monetarios donde el bien transable es el dinero, convirtiéndose, por tanto, en un instrumento esencial para el buen funcionamiento de la economía (Cerdas & Melegatti, 2014).

Los sistemas de pago pueden clasificarse en función del tipo de liquidación, es decir, si los pagos se procesan uno a uno por su monto individual (sistema bruto) o si existe una compensación² entre las órdenes de los distintos participantes del sistema (sistema neto).

¹ Actualmente denominado “Comité de Pagos e Infraestructuras del Mercado” (CPMI) es un organismo internacional de normalización que promueve, supervisa y formula recomendaciones sobre la seguridad y la eficiencia de los sistemas de pago, compensación, liquidación y mecanismos conexos, apoyando así la estabilidad financiera y la economía en general. El CPMI también sirve de foro para la cooperación de los bancos centrales en asuntos relacionados con la vigilancia, la política y las operaciones, incluida la prestación de servicios de banco central.

² Según el CPSS-BIS (2003) el término “compensación” tiene dos significados en los mercados de valores. Puede hacer referencia al proceso mediante el cual se calculan las obligaciones mutuas de los participantes,

Por otra parte, el proceso de compensación o neteo puede llevarse a cabo entre dos participantes (compensación bilateral), sustituyendo a cada uno sus derechos y obligaciones derivados de las operaciones que mantiene con otro participante por una posición única frente a él (deudora o acreedora). También puede ser entre tres o más participantes (compensación multilateral), sustituyendo a cada uno sus derechos y obligaciones derivados de las operaciones que mantiene con los demás, por una única posición neta frente a todo el sistema (deudora o acreedora). Dependiendo de las características y reglas de operación propias de cada sistema, sus participantes pueden optar por uno u otro tipo de liquidación (Cerdas & Melegatti, 2014). En el Apéndice A, se muestran dos ejemplos numéricos relacionados con el concepto del tipo de liquidación.

Los sistemas de liquidación bruta exigen que la liquidación de una orden se haga solo si existen fondos en las cuentas de los deudores al momento de su procesamiento, lo cual conlleva a que las entidades deban mantener una mayor reserva de liquidez que en un sistema de liquidación neta. Sin embargo, los efectos de un fallo en la liquidación son potencialmente mayores y menos controlables en un sistema neto, pues si un participante no puede atender sus pagos, está dejando de cumplir todas las operaciones que están “detrás” de esa posición neta. Además, su incumplimiento puede transmitir riesgos de liquidez al resto de participantes y provocar interrupciones en la corriente de pagos. Por el contrario, en un sistema bruto sí es posible conocer exactamente cuál operación es la que entra en conflicto, mitigándose así la posibilidad de contagio al resto del sistema (Cerdas & Melegatti, 2014).

2.3 RIESGO SISTÉMICO Y ESTABILIDAD EN LOS SISTEMAS DE PAGO

Ortiz-Cevallos (2020) citando a Freixas et al. (2015) define el riesgo sistémico como “*la amenaza sobre la estabilidad financiera capaz de perjudicar el funcionamiento de una parte esencial en el sistema financiero con efectos adversos y severos en el sector real*”. Las políticas macroprudenciales tienen como objetivo mitigar ese riesgo. Sin embargo, la

generalmente en términos netos, para el intercambio de valores y efectivo. También puede aludir al proceso de transferencia de los valores en la fecha de liquidación, y en este sentido el término “sistema de compensación” se utiliza en ocasiones para referirse a los sistemas de liquidación de valores.

medición de ese objetivo de política es una tarea difícil, razón por la cual no se dispone de una única metodología para ese fin.

Al estar basados en la interacción entre sus participantes, los sistemas de pago (SP) conforman redes expuestas a diversos riesgos, siendo uno de los más importantes el riesgo sistémico. La incidencia que ello tiene sobre la estabilidad financiera y la transmisión de la política monetaria son algunas de las razones que explican el interés de los bancos centrales por promover los objetivos de seguridad y eficiencia en los SP (Machado, et al., 2011).

En el contexto de los sistemas de pago y liquidación de valores, el riesgo sistémico se refiere al riesgo de que el incumplimiento por parte de un participante en un sistema de sus obligaciones requeridas haga que otros participantes no puedan cumplir sus obligaciones a su vencimiento (Leinonen & Soramäki, 2003).

El Reglamento del Sistema de Pagos³ (RSP) costarricense en su artículo 48 define a los sistemas de importancia sistémica como *“las infraestructuras de compensación y liquidación de fondos y valores en las que participan al menos tres asociados y que ante una falla en su operación puede generar o transmitir efectos negativos a mayor escala entre sus participantes o crear alteraciones sistémicas en el conjunto de agentes económicos”*. Adicionalmente, amparado al Tratado sobre sistemas de pagos y de liquidación de valores de Centroamérica y República Dominicana, Ley 8876, el artículo 49 del RSP establece los siguientes criterios para el reconocimiento de un sistema de pago o de valores como de importancia sistémica:

- a) Si el sistema es utilizado por el BCCR en su papel de autoridad monetaria.
- b) La actividad incorrecta, ineficiente o no fiable del sistema, pueda afectar la red de pagos de la economía y con ello, amenazar la estabilidad o la confianza del sistema financiero y; derivar en serias consecuencias para el comercio u otros intereses en el país.

³ Aprobado por la Junta Directiva del Banco Central de Costa Rica en la sesión 5825-2018, artículo 6, del 2 de mayo de 2018 y publicado en el Alcance 97 a la Gaceta 83 del 14 de mayo de 2018. Modificado en el acta de la sesión 6099-2022, artículo 4, del 21 de diciembre de 2022 y publicado en la Gaceta 7 del 17 de enero de 2023

- c) El valor total de las órdenes de pago que se reciben y procesan.
- d) La cantidad total de órdenes de pago que se reciben y procesan.
- e) El número de participantes.

En línea con lo anterior en el artículo 50 del RSP, reconoce como sistemas de pago o de valores de importancia sistémica los siguientes: el SINPE; los sistemas que operan los mercados administrados por la Bolsa Nacional de Valores; los sistemas que realizan el procesamiento, compensación y liquidación de las transacciones en cajero automático (redes ATM) o compra en comercios con tarjetas de pago VISA, MasterCard y American Express (redes de puntos de venta) y el Sistema Nacional de Pago Electrónico del Transporte Público (SINPE-TP).

Con el fin de medir el riesgo sistémico en un SP, Triepels et al. (2017) aplicaron la detección de anomalías en los datos de pagos generados en un sistema de liquidación bruta en tiempo real (LBTR); entendiendo anomalía como un patrón que no se ajusta al comportamiento esperado. En este contexto las anomalías son configuraciones particulares de una red de pago que se desvían considerablemente de la norma esperada. Son causadas por estrés financiero o comportamiento de pago no deseado. El trabajo de Triepels et al. (2017) consistió en la aplicación de una metodología de red neuronal no supervisada y totalmente basada en datos que puede reconocer de forma consistente un patrón típico -aunque potencialmente complejo- de transacciones financieras.

En esta línea, el enfoque de aprendizaje automático basado en datos aplicado a los sistemas de pago otorga una nueva perspectiva a la supervisión y vigilancia de los sistemas financieros. No sólo las metodologías de aprendizaje automático pueden ser entrenadas para representar el comportamiento de pago de las instituciones financieras, sino que también pueden tener en cuenta las interrelaciones de las instituciones financieras en las redes de pagos como determinantes de ese comportamiento (León, Paolo, Acero, & Gage, 2020).

2.4 ESTUDIOS ANTERIORES RELACIONADOS

La primera aplicación práctica de las redes neuronales artificiales (RNA) se produjo a finales de la década de 1950, con la invención de la red perceptrón y la regla de aprendizaje asociada por Frank Rosenblatt. Junto a sus colegas, Rosenblatt construyó una red perceptrón y demostraron su capacidad para reconocer patrones. Este éxito inicial generó un gran interés en la investigación de redes neuronales, sin embargo, posteriormente se demostró que la red perceptrón básica sólo podía resolver una clase limitada de problemas (Hagan, Demuth, Beale, & De Jesús, 2014).

Durante la década de 1980, con las nuevas computadoras personales y estaciones de trabajo, que rápidamente crecieron en capacidad y se hicieron ampliamente disponibles, en conjunto con la introducción de dos nuevos conceptos, se dio un renacimiento de las redes neuronales. El primer concepto fue el uso de la mecánica estadística para explicar el funcionamiento de una cierta clase de red recurrente, que podría usarse como memoria asociativa. El segundo concepto fue el algoritmo de retro propagación para entrenar redes de perceptrón multicapa, que fue descubierto independientemente por varios investigadores diferentes.

Desde la década de 1980, se han escrito miles de artículos sobre las innumerables aplicaciones de las redes neuronales y el campo ha estado lleno de nuevos trabajos teóricos y prácticos (Hagan, Demuth, Beale, & De Jesús, 2014). Por ejemplo, las redes neuronales artificiales se han utilizado para la predicción de quiebras y fracasos empresariales. Aydin, et al. (2022) construyeron un modelo de redes neuronales a partir de un conjunto de 25 razones financieras y 2 variables no financieras de 240 empresas de los sectores de manufactura, servicios y comercio, clasificando correctamente las empresas en quiebra y las que no lo estaban.

Asimismo, en la industria bancaria se ha utilizado esta metodología para la evaluación del riesgo de crédito de los clientes mediante “*credit scorings*”. Yong Hu (2022) construyó un modelo de una red neuronal artificial para predecir el riesgo de crédito de los clientes corporativos de los bancos comerciales. Para ello utilizaron un conjunto de 14 indicadores financieros de las entidades. El método de RNA mostró una mayor capacidad predictiva

frente a las técnicas árboles de decisión y análisis discriminante que también fueron evaluadas.

Por otra parte, Holopainen y Sarlin (2016) utilizaron un conjunto de 14 indicadores considerados como de vulnerabilidades a nivel país (por ejemplo, brecha crédito/PIB, crecimiento de los precios de la vivienda, saldo en cuenta corriente/PIB, préstamos/ingresos, entre otros) para clasificar 15 países de la Unión Europea como pertenecientes a un periodo precrisis, considerando cifras para el periodo 1976 a 2014. Estos autores ajustaron una serie de modelos utilizando enfoques estadísticos tradicionales y métodos de aprendizaje automático, encontrando la fortaleza del segundo enfoque frente al tradicional.

Asimismo, León, et al. (2017) utilizaron un modelo básico de reconocimiento de patrones de RNA sobre los datos de los balances mensuales de 25 bancos colombianos para el periodo de 2000 a 2014, para valorar la precisión de la clasificación de las entidades, concluyendo que una red neuronal artificial es capaz de reconocer a un banco por sus cuentas financieras.

En materia de vigilancia de sistemas de pago Sabetti y Heijmans (2019) aplicaron redes neuronales para detectar flujos de pagos anómalos en el Sistema Automatizado de Compensación y Liquidación Canadiense. Para evaluar el modelo utilizaron datos basados en anomalías históricas, así como corridas bancarias simuladas. Sus resultados demostraron que la técnica empleada detecta razonablemente bien los flujos de pago anómalos.

También León et. al (2020) utilizaron la metodología de redes neuronales artificiales para representar los patrones de pago en el sistema de pagos de alto valor colombiano, utilizando 113 características correspondientes a: contribución de las instituciones financieras a los pagos, hábitos de financiamiento, momento de los pagos, concentración de pagos, centralidad en la red de pagos y los efectos sistémicos debidos a la omisión de un pago. El rendimiento hallado fue de un error de clasificación fuera de la muestra en torno al 3%.

En el Apéndice B se presenta un resumen de las principales características de los modelos de redes neuronales construidos en algunos estudios que utilizan información de sistemas de pago.

2.5 RECONOCIMIENTO DE PATRONES

El reconocimiento de patrones tiene sus orígenes en la ingeniería, mientras que el aprendizaje automático surgió de la informática. Sin embargo, estas actividades pueden verse como dos facetas del mismo campo, y juntas han experimentado un desarrollo sustancial en los últimos años (Bishop, 2006).

El problema de buscar patrones en los datos es fundamental y tiene una larga y exitosa historia. Por ejemplo, las extensas observaciones astronómicas de Tycho Brahe en el siglo XVI permitieron a Johannes Kepler descubrir las leyes empíricas del movimiento planetario, que a su vez proporcionó un trampolín para el desarrollo de la mecánica clásica. Del mismo modo, el descubrimiento de regularidades en los espectros atómicos jugó un papel clave en el desarrollo y verificación de la física cuántica a principios del siglo XX. El campo del reconocimiento de patrones se ocupa del descubrimiento automático de regularidades en los datos mediante el uso de algoritmos informáticos y del uso de estas regularidades para tomar acciones como clasificar los datos en diferentes categorías (Bishop, 2006).

El marco más general y natural para formular soluciones a los problemas de reconocimiento de patrones es el estadístico, que reconoce la naturaleza probabilística tanto de la información que tratamos de procesar como de la forma en que debemos expresar los resultados. El reconocimiento estadístico de patrones es un campo bien establecido con una larga historia (Bishop, 1995).

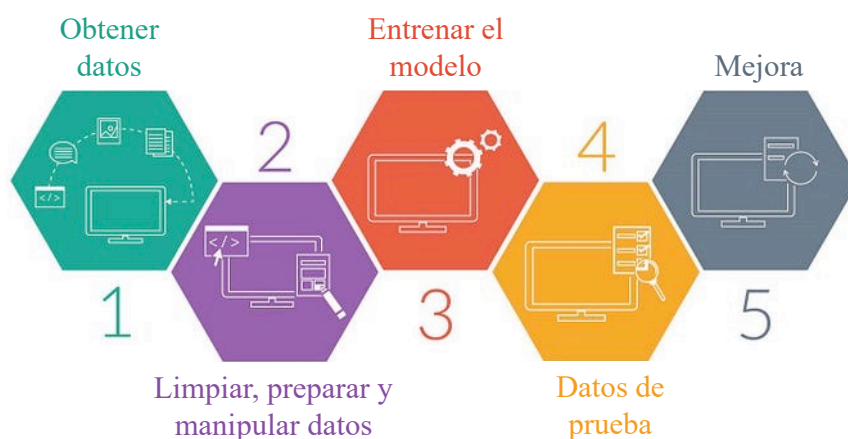
De acuerdo con Bishop (2006), en el enfoque de aprendizaje automático o “*machine learning*” (ML) se toma una muestra de N elementos $\{x_1, \dots, x_N\}$ llamado “datos de entrenamiento” para ajustar los parámetros de un modelo adaptativo. Las categorías de los elementos en el conjunto de entrenamiento se conocen de antemano. Podemos expresar la categoría de un elemento usando el vector objetivo \mathbf{t} .

El resultado de ejecutar el algoritmo de aprendizaje automático se puede expresar como una función $y(x)$ que toma cada elemento x como entrada y que genera un vector de salida y . La forma precisa de la función $y(x)$ se determina durante la fase de entrenamiento o fase de aprendizaje, sobre la muestra de entrenamiento.

Una vez que se entrena el modelo se puede determinar la identidad de nuevos elementos, que se dice que comprenden los “datos de prueba”. La capacidad de categorizar correctamente nuevos ejemplos que difieren de los utilizados para la capacitación se conoce como “generalización”. En aplicaciones prácticas, la variabilidad de los vectores de entrada será tal que los datos de entrenamiento pueden comprender solo una pequeña fracción de todos los vectores de entrada posibles, por lo que la generalización es un objetivo central en el reconocimiento de patrones. Las redes neuronales son una extensión de las técnicas convencionales de reconocimiento estadístico de patrones.

En la Ilustración 2.1 se muestran las tareas principales en el proceso de aprendizaje automático o “*machine learning*”.

Ilustración 2.1. Pasos básicos para realizar una tarea de aprendizaje automático



Fuente: Maloo (2018)

3 MÉTODOS Y MATERIALES

3.1 DATOS Y FUENTES DE INFORMACIÓN

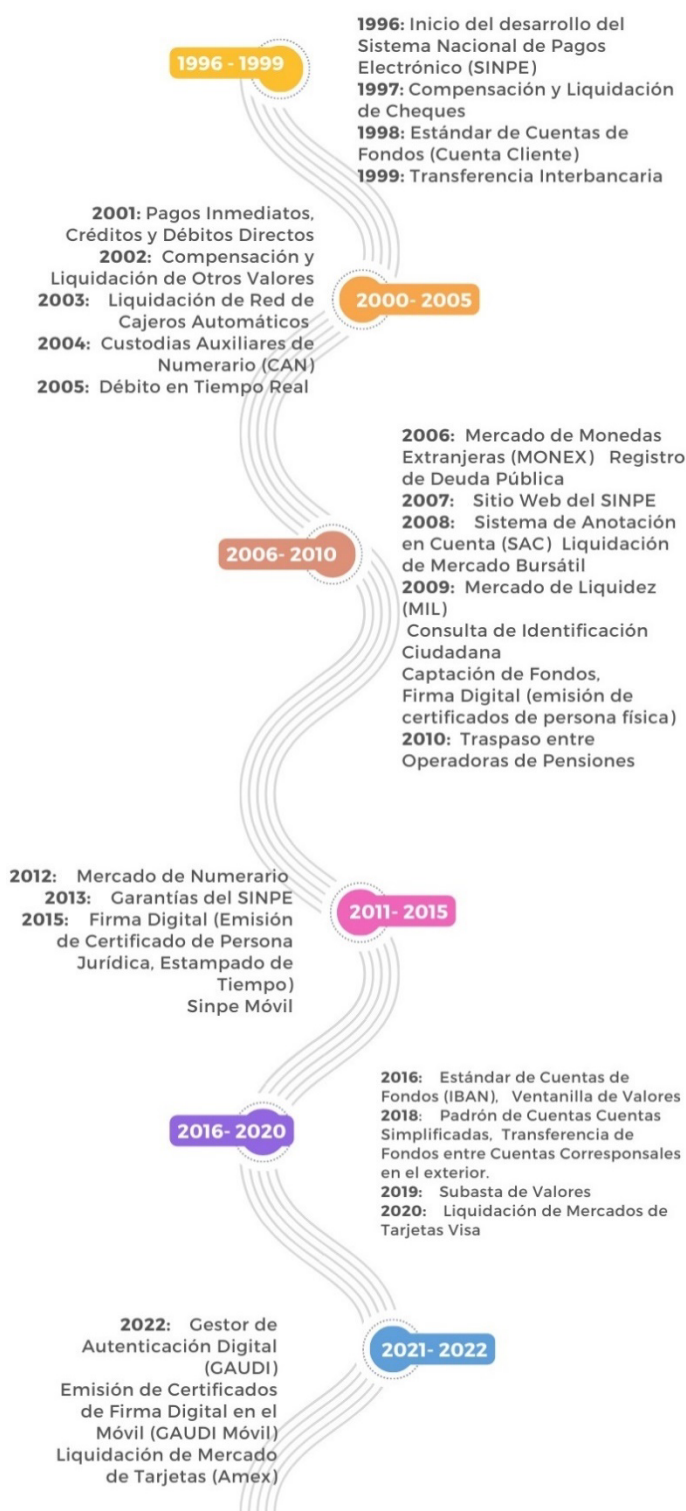
La fuente primaria de la información es el SINPE. Este sistema es una plataforma tecnológica desarrollada y administrada por el Banco Central de Costa Rica, que conecta a entidades financieras, instituciones públicas, entre otras a través de una red privada de telecomunicaciones, la cual les permite realizar la movilización electrónica de fondos entre cuentas IBAN⁴ y participar en los mercados de negociación que organiza el Banco Central de Costa Rica mediante esa plataforma (Banco Central de Costa Rica, 2023).

Esta plataforma tecnológica fue puesta en marcha el 17 de abril de 1997 e inició con el servicio de Compensación y Liquidación de Cheques, logrando así agilizar la liquidación de este instrumento de pago. Ya que, para ese momento, el mismo presentaba un porcentaje importante en lo relativo a la movilización de fondos. A partir de ahí, se han desarrollado otros servicios que no sólo agilizan y disminuyen los riesgos a los asociados directos al SINPE, sino también a los clientes de dichas entidades. Dentro de esos servicios se pueden mencionar: Transferencias de Fondos a Terceros (hoy Pagos Inmediatos), Créditos Directos, Débitos Directos y otros que permiten mayores opciones para movilizar los fondos de una entidad financiera hacia otra (Banco Central de Costa Rica, 2023).

En la Ilustración 3.1 se muestra el progreso de desarrollo del sistema nacional de pagos electrónicos.

⁴ El IBAN (*Internacional Bank Account Number*) es una estructura estandarizada que identifica cuentas de fondos tanto a nivel nacional como internacional. Este formato ha sido promulgado por el Comité Europeo de Estándares Bancarios y cumple con la norma ISO-13616.

Ilustración 3.1. Progreso de desarrollo del SINPE



Fuente: Banco Central de Costa Rica

Por su tamaño, considerando la cantidad y el valor de las transacciones, el SINPE es una plataforma de importancia sistémica. El valor total liquidado en SINPE durante el 2022 equivale a 13,4 veces el valor del PIB, de forma que cada 18,6 días hábiles esta plataforma movilizó el equivalente al total de la producción nacional. En promedio, cada día hábil se movilizan ₡2.375 miles de millones (USD 3.670 millones) (Banco Central de Costa Rica, 2023).

La información base para el análisis de la presente investigación corresponde a los flujos de pago enviados y recibidos por las entidades bancarias durante los días hábiles del periodo comprendido entre enero 2018 y diciembre 2022, para un total de más de 336 millones de registros según se muestra en el Cuadro 3.1.

Cuadro 3.1. Cantidad de registros en la base de movimientos del SINPE por año. 2018-2022

Año	Cantidad de registros
2018	41.684.511
2019	51.746.553
2020	64.222.710
2021	80.205.382
2022	98.372.598
Total	336.231.754

Fuente: Elaboración propia con base en el SINPE.

Los campos utilizados para realizar los análisis fueron los siguientes:

1. **Fecha:** fecha de liquidación del movimiento sobre la cuenta de fondos ISO (YYYY-MM-DD)
2. **Hora:** hora de liquidación del movimiento sobre la cuenta de fondos en el formato hh:mm:ss
3. **CodSinpe:** corresponde al código numérico de 3 dígitos que identifica a cada participante dentro del SINPE⁵.
4. **TipoMovimiento:** si corresponde a un “crédito” o “débito” a la cuenta.

⁵ El listado de los afiliados al SINPE con sus códigos respectivos se encuentra en <https://www.bccr.fi.cr/sistema-de-pagos/informaci%C3%B3n-general/afiliados>

5. **CodTipoMovimiento:** código correspondiente al tipo de movimiento 1 (crédito) o 2 (débito).
6. **Moneda:** información sobre la moneda de la cuenta, los participantes del SINPE deben tener cuentas en tres monedas: colones, dólares y euros.
7. **Monto:** es el monto de la transacción. Cuando el movimiento corresponde a un débito el sistema muestra este monto como un número negativo.
8. **CodServicio:** corresponde al código numérico del servicio del SINPE. El SINPE cuenta con diferentes servicios entre los cuales están, las transferencias entre entidades, las transferencias entre clientes de las entidades, mercado de monedas extranjeras, mercado integrado de liquidez, entre otros (para el listado completo ver Anexo A).
9. **Servicio:** corresponde a las siglas del servicio SINPE.
10. **CodMotivo:** es una clasificación del motivo dentro de cada servicio. Por ejemplo, para el mercado integrado de liquidez existen 2 códigos, uno para el calce de las ofertas y otro para la liquidación de vencimientos.
11. **Documento:** es un identificador del código con que se liquidó el movimiento. Al menos dos operaciones van a tener el mismo código, el movimiento de crédito en un participante va a ser el de débito en otro participante.

3.2 INDICADORES DE LIQUIDEZ INTRADÍA

En la Tabla 3.1 se muestra el conjunto de 8 indicadores propuesto por el Comité de Supervisión Bancaria de Basilea (Basel Committee on Banking Supervision, 2013) para dar seguimiento a la liquidez intradía de los participantes de un sistema de pagos:

Tabla 3.1. Indicadores de seguimiento del manejo de la liquidez intradía

Indicador:	
i.	Requerimiento máximo diario de liquidez
ii.	Liquidez intradía disponible al comienzo del día hábil
iii.	Total de pagos
iv.	Obligaciones a horas específicas y otras obligaciones críticas
v.	Valor de los pagos realizados en nombre de clientes de banca corresponsal ¹
vi.	Líneas de crédito intradía extendidas a clientes ¹
vii.	Hora de los pagos intradía

Indicador:
viii. Orientaciones sobre rendimiento intradía

¹ Aplica a bancos que proporcionan corresponsalía


Fuente: Basel Committee on Banking Supervision (2013)

i. Requerimiento máximo diario de liquidez

Este indicador permite controlar el saldo neto de todos los pagos realizados y recibidos durante el día sobre la cuenta de fondos con el banco central. La posición negativa neta más grande durante el día hábil en la(s) cuenta(s), (es decir, el mayor saldo acumulado neto entre los pagos realizados y recibidos), determinará el uso máximo diario de liquidez intradía de un banco. La posición neta debe determinarse mediante marcas de tiempo de liquidación (o el equivalente) utilizando datos transacción por transacción sobre la(s) cuenta(s). El saldo negativo neto más grande en la(s) cuenta(s) se puede calcular después del cierre del día hábil.

El cálculo del indicador se muestra en la Ilustración 3.2. Una posición neta positiva significa que el banco ha recibido más pagos de los que ha realizado durante el día. Por el contrario, una posición neta negativa significa que el banco ha realizado más pagos de los que ha recibido.

Ilustración 3.2. Requerimiento máximo diario de liquidez



Fuente: Basel Committee on Banking Supervision (2013)

Si un banco tiene una posición neta negativa en algún momento intradía, necesitará acceso a liquidez intradía para financiar este saldo. La cantidad mínima de liquidez intradía que un banco necesitaría tener disponible en un día determinado sería equivalente a su mayor posición neta negativa. (En la Ilustración 3.2 el requerimiento de liquidez intradía sería de 10 unidades).

ii. Liquidez intradía disponible al comienzo del día hábil

Este indicador se refiere a la cantidad de liquidez intradía que un banco tiene disponible al comienzo de cada día para cumplir con sus requisitos de liquidez intradía en condiciones normales. En el SINPE, los bancos cuentan con dos fuentes de liquidez inmediata al inicio del día que son los saldos en la cuenta de reserva y las garantías depositadas y disponibles en el Fideicomiso 1034 correspondiente a las garantías del sistema de pagos.

iii. Total de pagos

Para cada día hábil de un período de referencia se calcula el total de los pagos liquidados enviados y recibidos en el SINPE para cada entidad bancaria.

iv. Obligaciones a horas específicas y otras obligaciones críticas

Es el valor total de las obligaciones temporales que liquidan cada día. Para efectos del SINPE este indicador se puede calcular como la suma de las obligaciones en los servicios compensados, incluyendo la liquidación de vencimientos del Mercado Integrado de Liquidez (MIL) tal y como se muestra en la Tabla 3.2.

Tabla 3.2. SINPE: servicios de liquidación neta

Siglas	Nombre	Hora de liquidación
PMB	Pagos Monedero Bancario	09:00
ATH	Liquidación de Servicios Externos	10:30
CLC	Compensación y Liquidación de Cheques	11:00
COV	Compensación de Otros Valores	11:00
MIL	Mercado Integrado de Liquidez (vencimientos)	11:00
RDE	Registro de Emisiones (vencimientos)	13:00
ILI	Información y Liquidación de Impuestos	14:30

Siglas	Nombre	Hora de liquidación
LIM	Liquidación de Mercados	15:00
VVE	Ventanilla de Valores Estandarizados	15:00
LAI	Comisiones del SINPE	15:30
CCD	Compensación de Créditos Directos	21:15
CDD	Compensación de Débitos Directos	21:15

Fuente: SINPE

v. Valor de los pagos realizados en nombre de clientes de banca corresponsal

Es el valor total de los pagos que realizan en nombre de todos los clientes de sus servicios bancarios corresponsales cada día e informar los tres valores totales diarios más importantes y el valor total promedio diario de estos pagos en el período del informe.

Este indicador no es el aplicable para el caso costarricense.

vi. Hora de los pagos intradía

Este indicador, muestra el tiempo promedio de las liquidaciones de pagos diarios de un banco. Puede describirse como el tiempo medio de liquidación ponderado por valor y se representa mediante la siguiente fórmula:

$$\frac{\sum(\text{Valor} \times \text{Hora de la liquidación})}{\sum \text{Valor}}$$

vii. Rendimiento intradía


Este indicador muestra la proporción, en valor, de los pagos efectuados por un banco que se liquidan a determinadas horas del día (por ejemplo, el porcentaje de los pagos de un día que se liquidan a las 9 de la mañana, a las 10 de la mañana, etc.). Algunas jurisdicciones tienen establecidas reglas u orientaciones de rendimiento, por ejemplo, se les exige a los participantes asegurarse de que, en promedio, un porcentaje de sus pagos se procese antes de una determinada hora u horas límite de forma intradía.

3.3 TOPOLOGÍA DE REDES

La Topología de Redes (TR) es una metodología propia de la física estadística que tiene por objeto entender y analizar la estructura y funcionamiento de redes complejas. Este análisis consiste en trazar y medir las relaciones y los flujos dentro de un grupo de agentes. Así definidos, los nodos de una red representan agentes (por ejemplo, instituciones financieras, personas, ordenadores), mientras que los enlaces muestran relaciones o flujos entre nodos (por ejemplo, intercambio de efectivo, mensajes, información). La principal ventaja del análisis de redes es que proporciona un análisis tanto visual como matemático de las relaciones, a partir del cual pueden obtenerse respuestas a preguntas clave sobre las características y el funcionamiento de la red (Espinosa-Vega, 2014).

En la Ilustración 3.3 se muestra una red conformada por un grupo de 10 amigos (nodos) que se comunican entre sí (intercambian mensajes, representados por enlaces). La persona llamada Diane habla con hasta seis personas del grupo, mientras que Heather sólo habla con tres, esto puede llevar a concluir que Diane es más importante que Heather a la hora de garantizar que los mensajes lleguen a todos los miembros del grupo. Pero para explotar al máximo la información recopilada -y comprender adecuadamente la dinámica del grupo- es necesaria una herramienta que pueda estructurar estas relaciones. La topología de redes permite responder a preguntas importantes como, por ejemplo, la importancia relativa de un agente dentro del grupo (su popularidad), la velocidad a la que un mensaje puede llegar a todos los miembros del grupo o los posibles fallos de comunicación que pueden hacer que un mensaje no llegue nunca a un agente determinado.

Ilustración 3.3. Red cometa



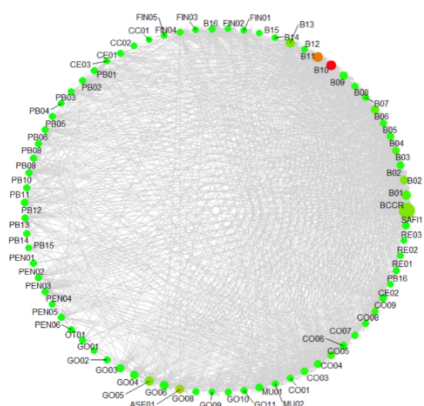
Fuente: Espinosa-Vega (2014)

Si en las relaciones de una red la dirección de las conexiones o vínculos es determinante, entonces estas se representan por flechas y la red se conoce dirigida o dígrafo. Pero adicionalmente si en las conexiones que conforman la red es fundamental la intensidad de la relación, sea que se consideren redes dirigidas o no, entonces se habla de redes ponderadas o con peso (Cepeda, 2018).

De igual forma se tiene que un sistema de pagos está constituido por nodos o participantes, que son aquellas entidades que lo conforman y realizan transacciones entre sí, donde estas últimas se conocen como conexiones o vínculos, las cuales varían de acuerdo con su dirección (origen-destino) y su magnitud (monto o cantidad). Con base en esta caracterización es posible estudiar las propiedades de la red, que se observan a través de diferentes parámetros (Machado, y otros, 2010).

En la Ilustración 3.4 se muestra la red conformada por los 55 participantes del SINPE que realizaron transferencias a través de los servicios de liquidación bruta en tiempo real (LBTR) en colones durante diciembre de 2018. Aún sin considerar como ponderadores el volumen o valor de éstas, la complejidad de la red que se conforma justifica el empleo de la física estadística como marco teórico para este tipo de análisis.

Ilustración 3.4. Red transacciones de servicios LBTR del SINPE en colones en diciembre de 2018.



Fuente: Banco Central de Costa Rica (2019)

En TR existen mediciones de la estructura de la red tales como el tamaño (cantidad de nodos) y número de conexiones. Asimismo, se pueden establecer mediciones de las propiedades de los vértices (participantes de la red), la más básica es quizás el “grado” que corresponde al número de vínculos que un nodo mantiene con los demás integrantes en una red. Como en este trabajo el objetivo de emplear la TR es generar mediciones que sirvan como covariables dentro de la RNA, las mediciones generadas van a corresponder al segundo grupo, es decir, a propiedades de los vértices, en este caso de las entidades bancarias como nodos de la red de pagos del SINPE.

En la Tabla 3.3 se muestran las definiciones de algunas mediciones relacionadas con las propiedades de los vértices o medidas de centralidad.

Tabla 3.3. Propiedades de los vértices (centralidad)

Medida	Definición
Centralidad de grado (<i>degree</i>) (k_i, k_i^{in}, k_i^{out})	El grado de un nodo corresponde al número de vínculos que este mantiene con los demás integrantes en una red. En una red dirigida, el número de conexiones de un nodo determina el grado de entrada si este opera como destino o de salida si es originador.
Centralidad de intensidad (<i>strenght</i>) (s_i, s_i^{in}, s_i^{out})	Es el grado ponderado ya sea por el monto o volumen de transacciones.
Centralidad del eigenvector (<i>eigenvector centrality</i>) (e_i)	La importancia de un vértice es la suma ponderada de la importancia de sus vértices adyacentes, y así sucesivamente (<i>feedback centrality</i>). Calcular la centralidad eigenvectorial de un nodo es un poco más complicado que obtener el grado. Intuitivamente, se debe tener en cuenta que “en lugar de conceder un punto por cada vecino de la red que tiene un nodo [como lo hace el grado], la centralidad eigenvectorial concede un número de puntos proporcional a las puntuaciones de centralidad de los vecinos.”
<i>Authority</i> y hub centrality (a_i y h_i) del algoritmo HITS	Es un ajuste a la centralidad de eigenvector (<i>Hypertext Induced Topic Search</i>). Provee dos medidas interrelacionadas de importancia “global”: una como receptor global (<i>authority</i>) y otra como distribuidor (<i>hub</i>) global. Hay dos fuentes de importancia: <ul style="list-style-type: none"> • Importancia como receptor: recibe conexiones de vértices importantes.

Medida	Definición
	<ul style="list-style-type: none"> • Importancia como distribuidor: envía conexiones a vértices importantes.
Centralidad de intermediación (<i>betweenness</i>)	La centralidad de intermediación busca medir cuán importante es el nodo para las conexiones entre el resto de los nodos. Intuitivamente, podríamos considerar que un nodo es más importante si los demás en la red “lo necesitan” para conectarse entre sí.

Fuente: Urdinez y Labrín (2021) y León (2017).

3.4 ANÁLISIS DE COMPONENTES PRINCIPALES

3.4.1 DEFINICIÓN

El análisis de componentes principales (en español ACP, en inglés, PCA) comprende un procedimiento matemático que transforma un conjunto de variables correlacionadas de respuesta en un conjunto menor de variables no correlacionadas llamadas *componentes principales* (Johnson, 2000).

Si los datos se sitúan en un espacio p -dimensional, se puede utilizar el ACP para determinar la dimensionalidad real de los datos y cuando, esta dimensionalidad es menor que p , las variables originales se pueden reemplazar por un número menor de variables subyacentes, sin que se pierda información. Entonces, se puede usar una menor cantidad de variables en los siguientes análisis. Un mayor detalle de la determinación de los componentes se muestra en el Anexo C.

Las nuevas variables o componentes principales se caracterizan por: 1) no están correlacionadas; 2) el primer componente principal explica tanto de la variabilidad en los datos como sea posible; y 3) cada componente subsiguiente toma en cuenta tanto de la variabilidad restante como sea posible.

3.4.2 SELECCIÓN DE LA CANTIDAD


Al utilizar la técnica de ACP para fines de reducción o simplificación de los datos, surge la necesidad de decidir el número de componentes principales que se deben retener.

Existen diferentes criterios para llegar a este número, la escogencia de uno u otro depende del juicio y gusto del investigador y también si se utiliza la matriz de varianzas y covarianzas o la matriz de correlación como punto de partida.

Cuando se utiliza la matriz de correlación como punto de partida, la significancia de las raíces características no es posible evaluarla debido a problemas teóricos en el desarrollo de las pruebas estadísticas correspondientes. Las dos reglas prácticas que se utilizan son:

- a. Retener solamente aquellos componentes cuyas raíces características λ_i son mayores a 1. La explicación que se da es que cualquier componente que merezca ser retenido, debe explicar más varianza que cualquiera de las variables estandarizadas (que tienen varianzas iguales a 1).
- b. Emplear la prueba gráfica (“*scree test*”) que consiste en construir un gráfico cuyas ordenadas son las raíces características de los componentes y las abscisas el orden sucesivo de extracción de los componentes. Se trata luego de ubicar un punto o “codo”, donde la curva descendente se convierte en una recta descendente. Se retienen entonces un número de componentes igual a la abscisa donde comienza el codo, por ejemplo, en la Ilustración 3.5 la cantidad de componentes seleccionada sería 2.

Ilustración 3.5. Ejemplo Scree Plot



Fuente: AI Assurance (2023)


3.5 REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales (RNA) son modelos matemáticos y computacionales inspirados en sistemas biológicos, adaptados y simulados en computadoras; han surgido como un intento de desarrollar modelos que emulen las características del cerebro humano. Las RNA están compuestas por un conjunto de elementos simples (neuronas) que se interconectan masivamente en paralelo y con organización jerárquica. Asimismo, las redes neuronales artificiales conforman modelos que permiten describir muchos fenómenos del mundo real y que pueden ser comparados y aplicados con los modelos estadísticos en problemas de predicción, clasificación y agrupamiento (Menacho, 2014).

Tal y como se mencionó previamente, las RNA se encuentran dentro de las técnicas de aprendizaje supervisado, es decir, tienen como meta aprender del patrón de comportamiento de los datos a partir de ellos mismos. Específicamente en el caso de las RNA, la red aprende a partir del patrón de comportamiento de las entradas (variables independientes) y salidas (variable dependiente) ajustando los conectores (o pesos sinápticos) representados usualmente como vector w .

El tipo de red que se va a utilizar en este trabajo es el procedimiento Perceptrón Multicapa (MLP por sus siglas en inglés). La estructura subyacente de una MLP es un grafo dirigido, es decir, consiste en nodos y uniones dirigidas, en este contexto llamadas neuronas y sinapsis. Las neuronas están organizadas en capas, que generalmente están completamente conectadas por sinapsis. La capa de entrada consiste en todas las covariables representadas en neuronas separadas y la capa de salida consiste en las variables de respuesta. Las capas intermedias se denominan capas ocultas, ya que no son directamente observables. La capa de entrada y las capas ocultas incluyen una neurona constante relacionada con las sinapsis de intercepto, es decir, sinapsis que no están directamente influenciadas por ninguna covariable (Günther & Fritsch, 2010). La Ilustración 3.6 da un ejemplo de una red neuronal con una capa oculta que consta de tres neuronas ocultas. Esta red neuronal modela la relación entre las dos covariables A y B y la variable de respuesta Y.

Ilustración 3.6. Ejemplo de una red neuronal con dos neuronas de entrada (A y B), una neurona de salida (Y) y una capa oculta que consta de tres neuronas ocultas



Fuente: Günter y Fritsh (2010)

A cada una de las sinapsis, se asocia un peso que indica el efecto de la neurona correspondiente, y todos los datos pasan a la red neuronal como señales. Las señales son procesadas primero por la llamada función de integración que combina todas las señales entrantes y segundo por la llamada función de activación que transforma la salida de la neurona. La representación matemática del modelo se presenta en el Anexo B.

En este trabajo el objetivo del uso de la metodología de RNA es el de clasificación fuera de la muestra. Por tanto, al entrenar la red neuronal se debe evitar el “sobreajuste”, que se refiere a un modelo que modela los datos de entrenamiento demasiado bien. Esto ocurre cuando un modelo aprende el detalle, incluyendo el ruido en los datos de entrenamiento en la medida en que tiene un impacto negativo en el rendimiento del modelo en datos nuevos. Esto significa que el ruido o las fluctuaciones aleatorias en los datos de entrenamiento son recogidos y aprendidos por el modelo. El problema es que estos conceptos no se aplican a los datos nuevos y afectan negativamente a la capacidad de los modelos para generalizar (González, 2018).

Con el fin de evitar el sobreajuste se va a aplicar el enfoque de “entrenamiento-prueba” que consiste en descomponer la serie de datos. Una parte servirá para el entrenamiento del modelo de RNA y la otra permitirá probarlo para la validación. Por lo general, se reserva entre un 70% y 80 % de los datos de la serie para el entrenamiento. El 20-30 % restante se explotará en la etapa de validación.

En síntesis, la primera parte de este trabajo tuvo como objetivo la generación de series estadísticas considerando los indicadores propuestos por el Comité de Supervisión Bancaria de Basilea (*BCBS*, 2013) para dar seguimiento a la liquidez intradía de los participantes de un sistema de pagos. Además, se construyeron indicadores que permiten caracterizar los vértices de la red de pagos y de los principales mercados de negociación que operan en el SINPE.

Considerando ambas monedas, los métodos descritos en el párrafo anterior dan como resultado un total de 78 series de indicadores como potenciales covariables en el modelo de reconocimiento de patrones. Es por este motivo que se realiza una reducción de variables aplicando la técnica de análisis en componentes principales para optimizar el rendimiento en el ajuste de la red neuronal.

4 ANÁLISIS DE RESULTADOS

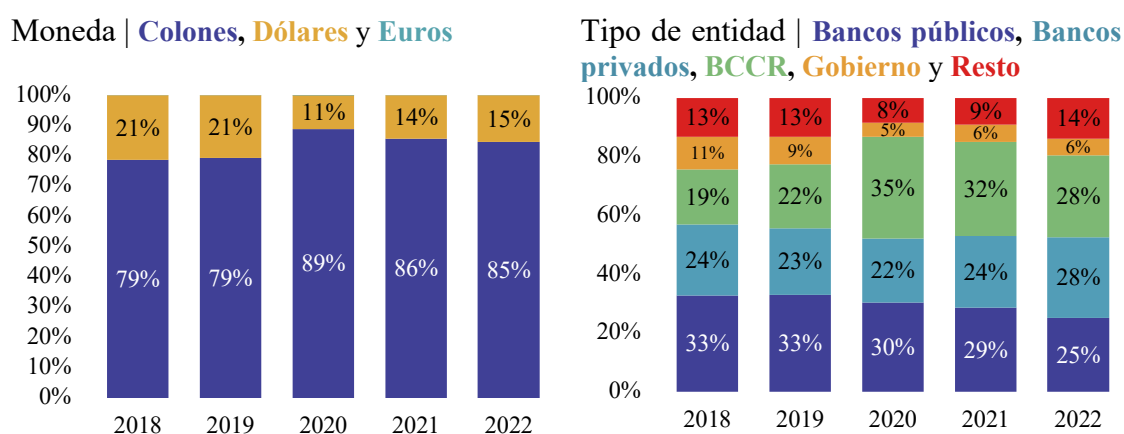
4.1 RESULTADOS INDICADORES DE HÁBITOS DE PAGO

De acuerdo con el BCCR durante el 2022 el SINPE movilizó un total de ₡593,5 billones de colones equivalente a 13,4 veces el valor del PIB. Los mercados de negociación representaron un 66,0% del valor movilizado en SINPE, destacando el Mercado Integrado de Liquidez (MIL) como el de mayor volumen transado (57,8%).

Producto de lo anterior, es que al analizar la composición de dicho monto por monedas se puede observar que alrededor de un 85% de los pagos fueron realizados en colones, la importancia de esta moneda dentro de los montos liquidados se ha mantenido en el tiempo (ver Figura 4.1). En segundo lugar, en importancia se encuentran los pagos en dólares, cuyo aporte ronda el 15%, cabe señalar que los montos liquidados en euros no alcanzan ni el 1%, por lo cual se excluyeron del análisis de la presente investigación.

Figura 4.1. SINPE: Monto de los pagos liquidados según moneda y tipo de entidad. 2018-2022

(cifras expresadas en billones de colones)



Fuente: Elaboración propia con datos del SINPE

Los montos movilizados por las entidades que conforman el Sistema Bancario Nacional (SBN) superan el 50% de los montos movilizados en el SINPE. El monto liquidado por estas entidades en conjunto con el realizado por la autoridad monetaria alcanza el 80% del total liquidado durante el 2022.

Tal y como se estableció en la sección 1.3.2, uno de los objetivos secundarios planteados en este trabajo de investigación fue el de ‘establecer un conjunto de indicadores sobre hábitos de fondeo, momento y concentración de pagos’. Asimismo, en el apartado 3.2 se hizo referencia a una serie de indicadores propuestos por el BCBS (2013) para el seguimiento de liquidez intradía.

A continuación, se muestra el resultado del cálculo de estos indicadores para las entidades del SBN para el periodo definido. El propósito en esta sección es mostrar la evidencia de la construcción de los insumos para el modelo de reconocimiento de patrones más que realizar un análisis detallado del comportamiento de las series de estos indicadores.

Como parte del análisis exploratorio previo a la modelación y con el propósito de realizar una comparación entre entidades en el comportamiento de las series de cada indicador presentado en esta sección se estimaron los siguientes estadísticos descriptivos para cada entidad: promedio, mediana, percentil 25, percentil 75, desviación estándar y coeficiente de variación. Una vez calculados estos estadísticos se procedió a realizar un análisis de conglomerados de k medias con el fin de poder establecer cuáles entidades tienen un comportamiento similar. Los resultados de este análisis se presentan en el Apéndice C.

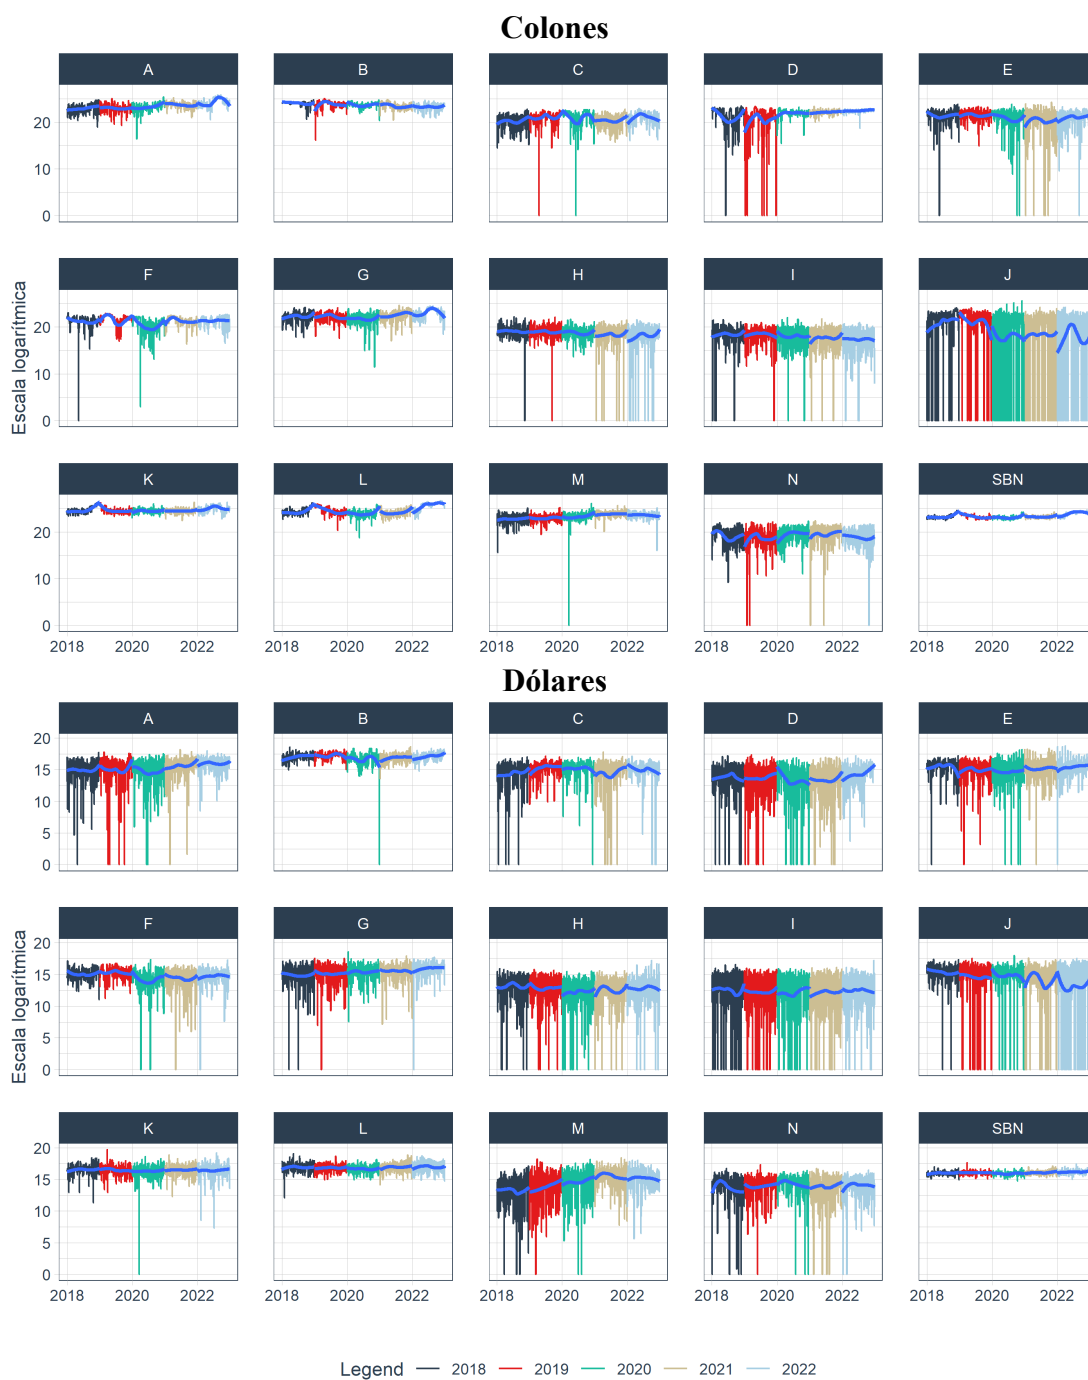
4.1.1 REQUERIMIENTO MÁXIMO DIARIO DE LIQUIDEZ

Tal y como se explicó anteriormente, el objetivo de este indicador es controlar el saldo neto de todos los pagos realizados y recibidos durante el día en la cuenta de fondos con el banco central. La posición negativa neta más grande, es decir, el mayor saldo acumulado neto entre los pagos enviados y recibidos representa el saldo que una entidad requiere al inicio del día para poder cumplir con las obligaciones de pago de la jornada.

En la Figura 4.2 se muestra el resultado de cálculo de este indicador por entidad, las escalas se muestran en términos logarítmicos debido a la variabilidad del rango de las series. El indicador toma el valor de 0, para aquellos días cuya entidad no alcanzó una posición neta negativa durante la sesión, es decir, el neto acumulado siempre fue positivo. Entidades como

la A, G, J, K y la L, muestran un incremento en este indicador en colones durante el 2022, principalmente durante el primer semestre. Por otra parte, en dólares las entidades A, E y M muestran una tendencia similar.

Figura 4.2. SBN: Montos diarios de la mayor salida neta en las cuentas de fondos en el BCCR por banco origen y moneda de liquidación. 2018-2022



Fuente: Elaboración propia con datos del SINPE

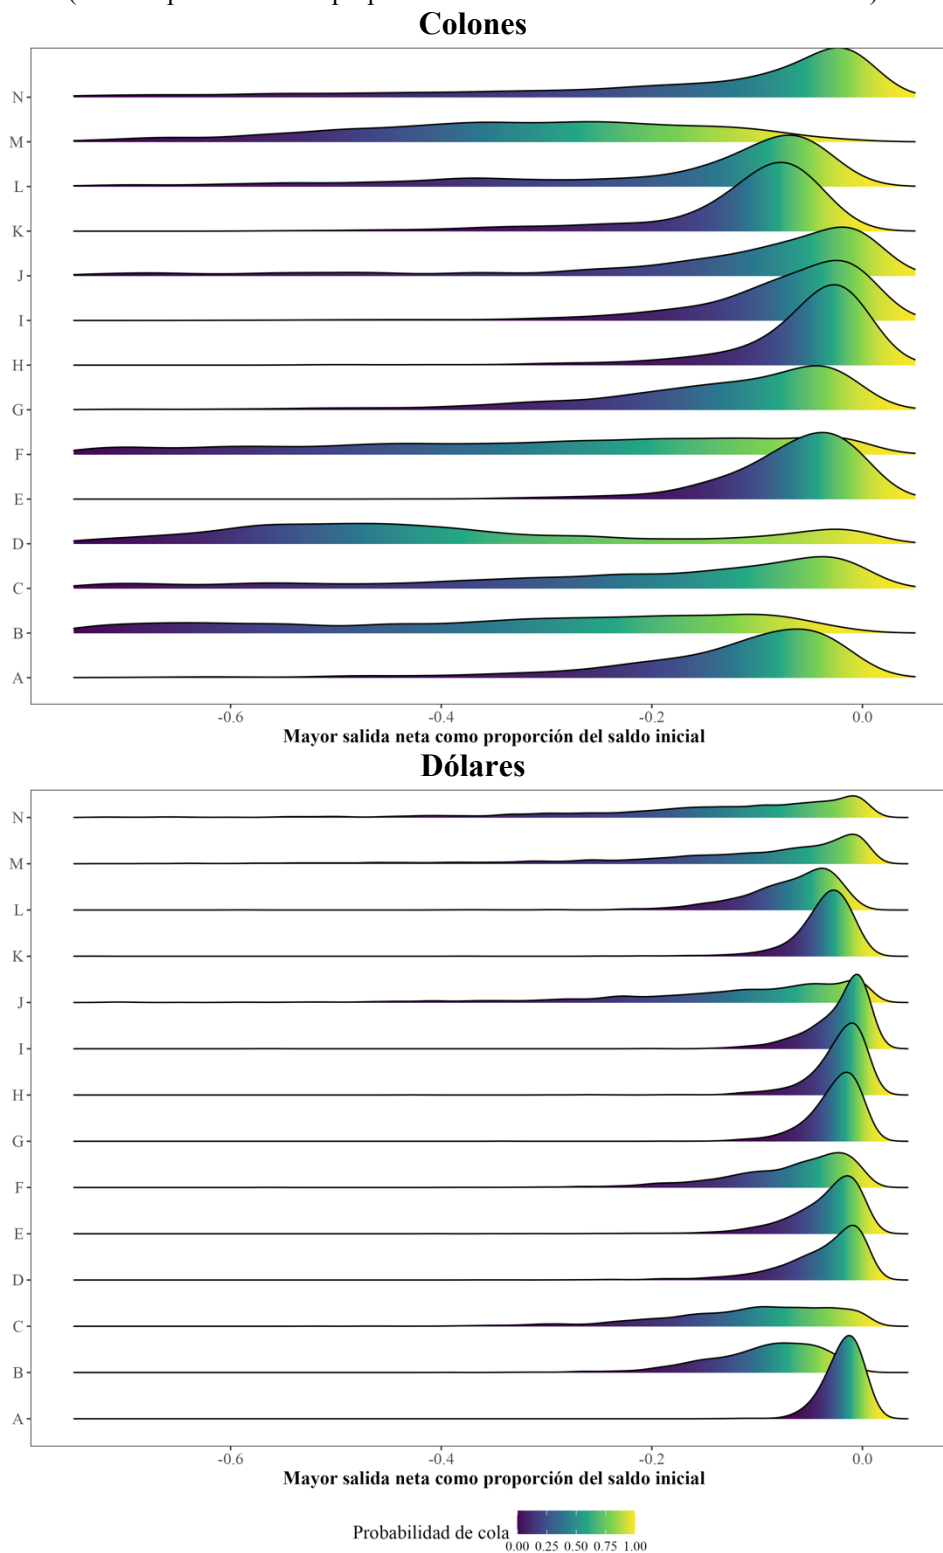
En cuanto al análisis comparativo utilizando las medidas de tendencia central y volatilidad de las series analizadas las entidades K y L muestran un comportamiento similar tanto en colones como en dólares, lo mismo que las C, F y G; por otra parte, I, J y N se tienden a comportar similar en colones, mientras que D, E, H, I y M forman un subgrupo en dólares (ver un mayor detalle en la Figura C.1 del Apéndice C). Estas diferencias y similitudes en el comportamiento del indicador entre entidades, puede ser de suma importancia a la hora de utilizarlo como covariable dentro del modelo de RNA. Las entidades ubicadas dentro de un mismo agrupamiento o conglomerado requieren de información adicional a la de este indicador que permita caracterizarlas individualmente.

Al analizar las distribuciones del monto de la mayor salida neta como proporción del saldo inicial en la Figura 4.3 se observa que, con una alta probabilidad las entidades bancarias pueden atender sus obligaciones de pago con un 25% o menos de su saldo en la cuenta de fondos en el BCCR. En colones, aunque la mayoría de las entidades presenta una situación similar a la mostrada en dólares, existen entidades bancarias como la B, D, F y M que con una mayor probabilidad de ocurrencia llegan a utilizar más del 50% del saldo en la cuenta para realizar pagos durante el día.

Las regiones de las distribuciones de alta probabilidad de ocurrencia coincidentes entre entidades dificultan la clasificación de estas únicamente con base en este indicador, por lo que esto demuestra la necesidad de contemplar un conjunto mayor de indicadores para establecer el patrón único de cada entidad.

Figura 4.3. SBN: Distribución de los montos diarios de la mayor salida neta en las cuentas de fondos en el BCCR por banco origen y moneda de liquidación. 2018-2022

(cifras expresadas como proporción del saldo inicial en la cuenta de fondos)



Fuente: Elaboración propia con datos del SINPE

Por otra parte, en la serie de mayor entrada neta en colones A, B, K, M y L muestran un incremento a partir de agosto del 2019, alcanzando los máximos durante los primeros meses de la pandemia en concordancia con la política monetaria expansiva del BCCR durante esta época. Por su parte, la serie en dólares no muestra una tendencia hacia el alza o la baja, pero sí una mayor volatilidad (ver Figura 4.4). Los días que el indicador toma el valor de 0 son aquellos que en términos netos acumulados las cuentas solo mostraron salidas de las cuentas de fondos, este comportamiento se refleja principalmente en las transacciones en dólares.

Figura 4.4. SBN: Montos diarios de la mayor entrada neta en las cuentas de fondos en el BCCR por banco destino y moneda de liquidación. 2018-2022

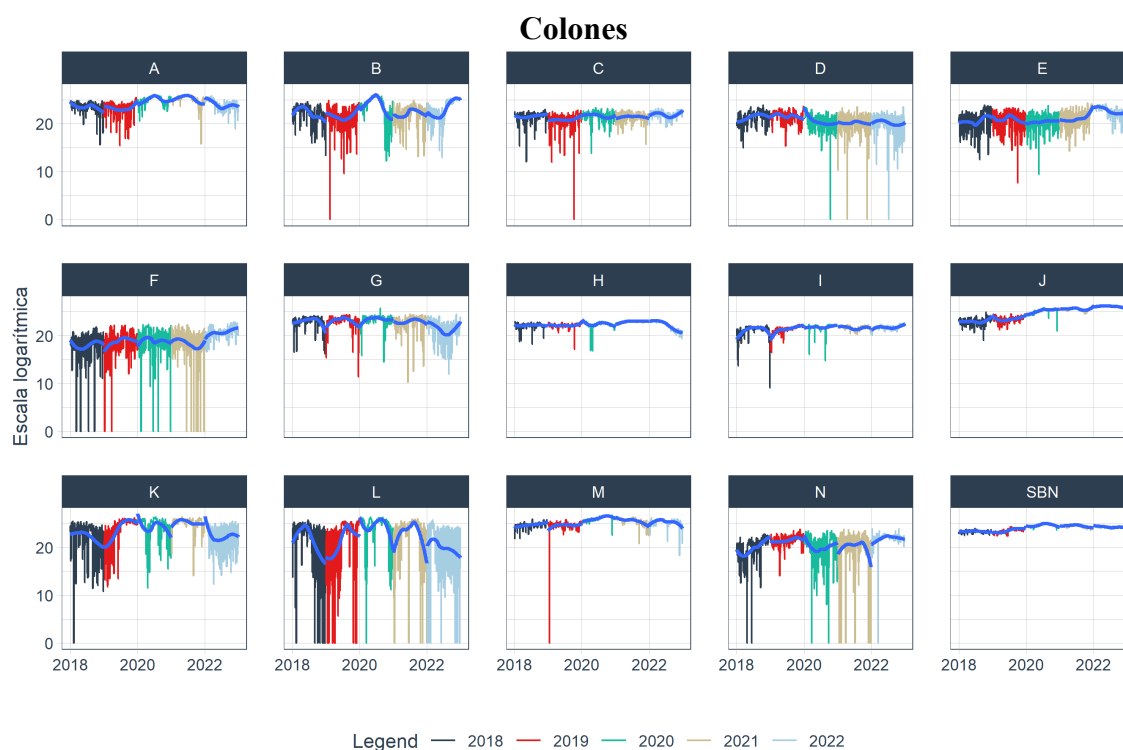
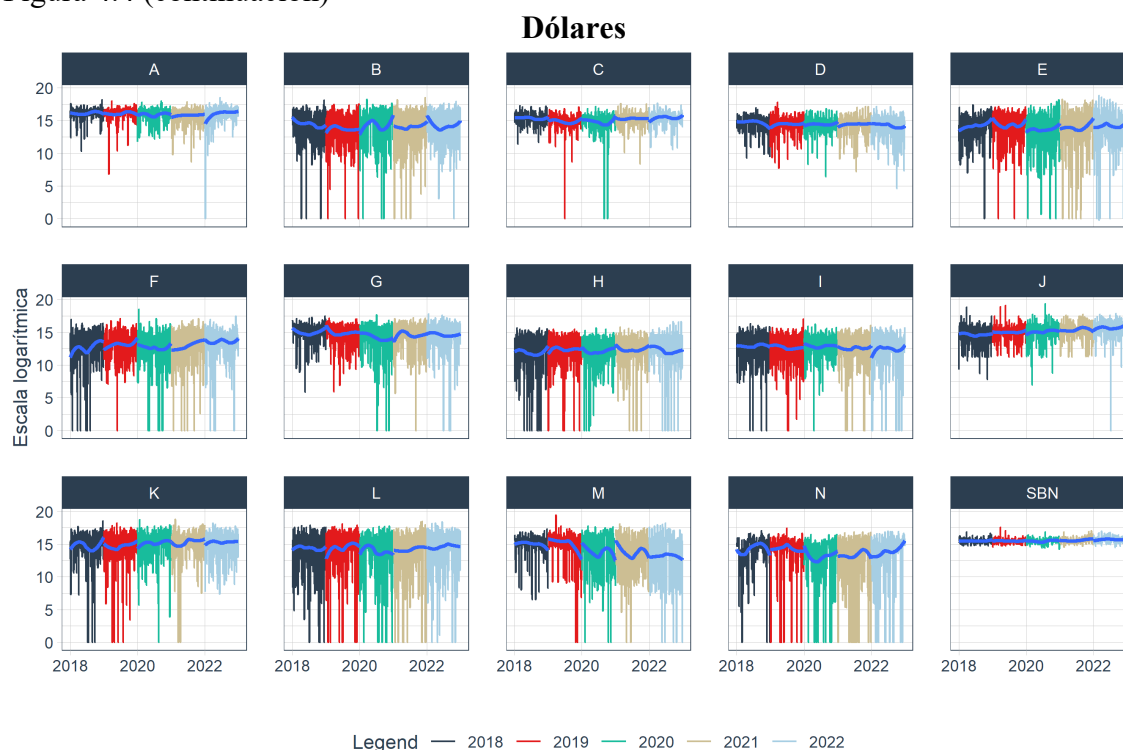


Figura 4.4 (continuación)

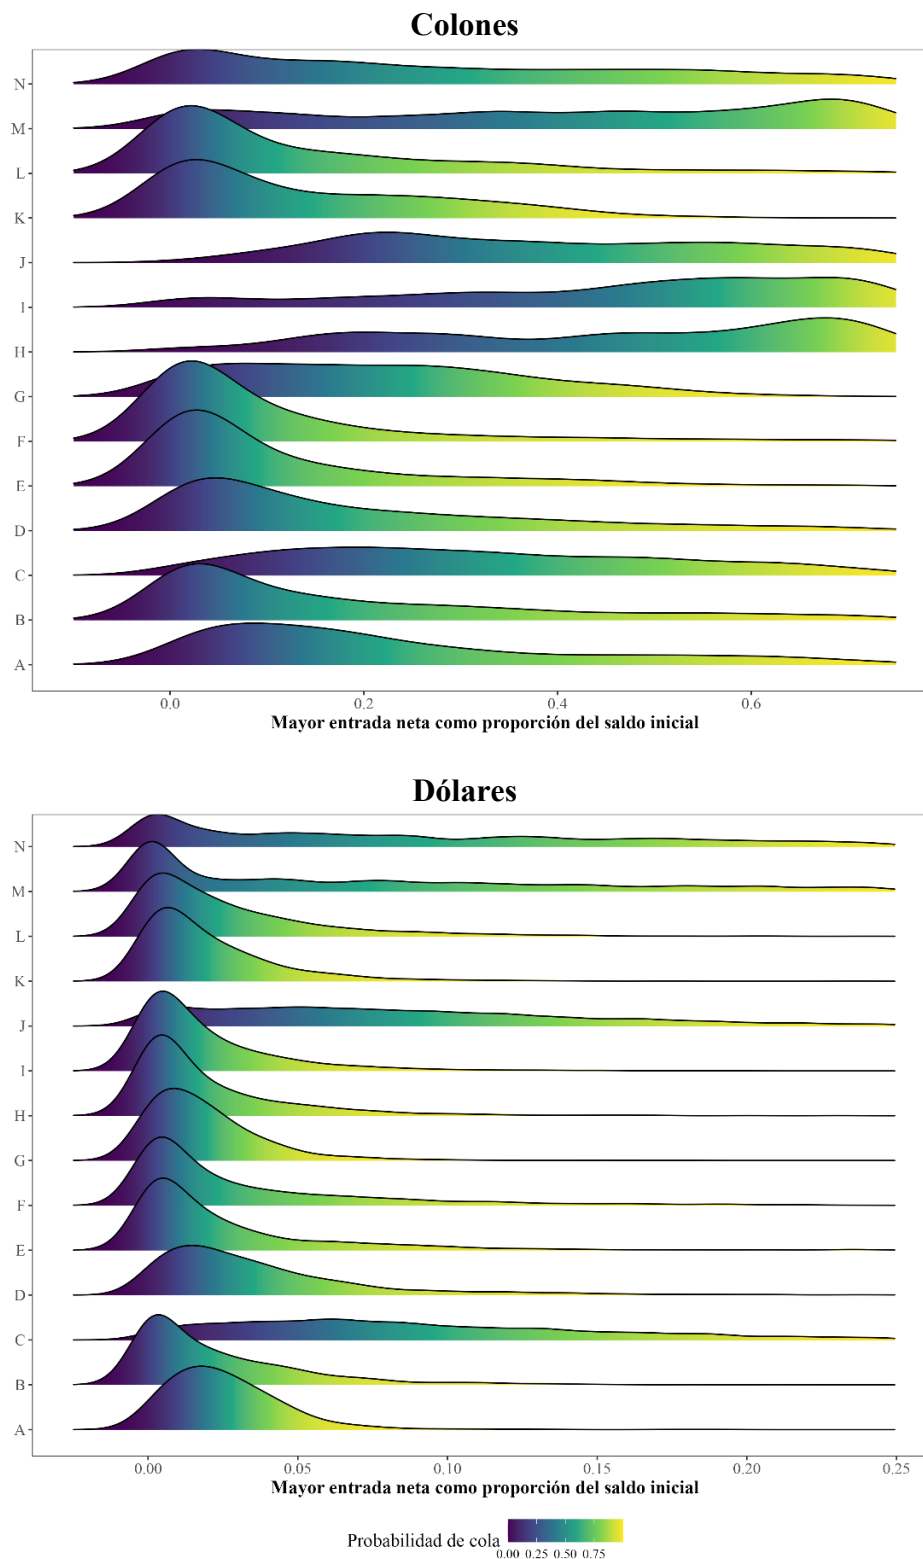


Fuente: Elaboración propia con datos del SINPE

En colones, la entidad M muestra un comportamiento muy disímil al resto de las entidades (ver Figura C.2 en Apéndice C), mientras que en dólares es la entidad A la que se aleja más del resto de las entidades. El resto de las entidades se ubican en tres agrupamientos, lo cual es indicativo de que esta variable permite diferenciar a las entidades que se ubican en grupos distintos, pero no las que se ubican dentro del mismo grupo, lo cual nuevamente confirma la necesidad de un enfoque multivariable para lograr una mejor identificación del patrón único para cada entidad bancaria.

Por otro lado, en relación con los montos de la mayor entrada neta como proporción del saldo inicial, los valores observados en colones muestran una mayor dispersión, tal y como se muestra en la Figura 4.5. En el caso de las entidades H, I, J y M, más de la mitad de los días observados la entrada neta en colones duplicó el saldo al inicio del día en la cuenta de fondos en el BCCR.

Figura 4.5. SBN: Distribución de los montos diarios de la mayor entrada neta en las cuentas de fondos en el BCCR por banco destino y moneda de liquidación. 2018-2022
(cifras expresadas como razón del saldo inicial en la cuenta de fondos)



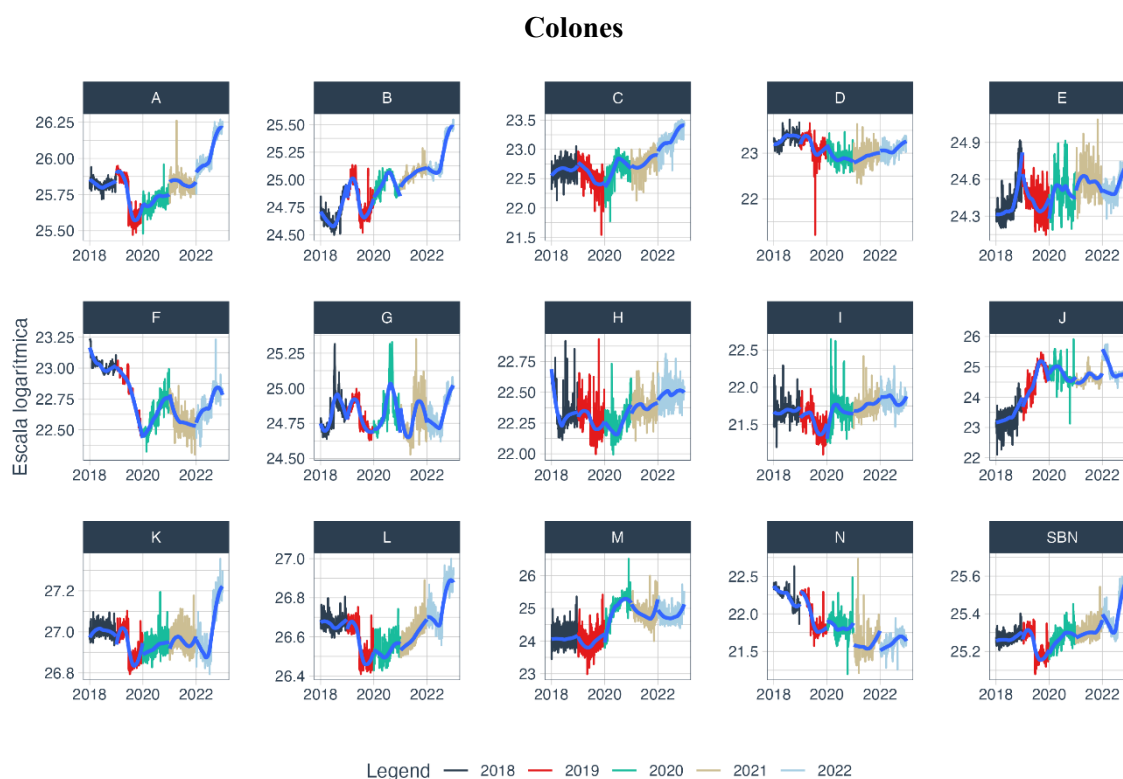
Fuente: Elaboración propia con datos del SINPE

4.1.2 SALDO INICIAL EN LA CUENTA DE RESERVA

Las entidades bancarias mantienen cuentas de reserva en el Banco Central que les permite participar en las liquidaciones del SINPE siempre que al cierre del horario bancario⁶ las entidades cumplan con el requerimiento de encaje mínimo legal. Para cada entidad es posible abrir una única cuenta por moneda (colones, dólares y euros).

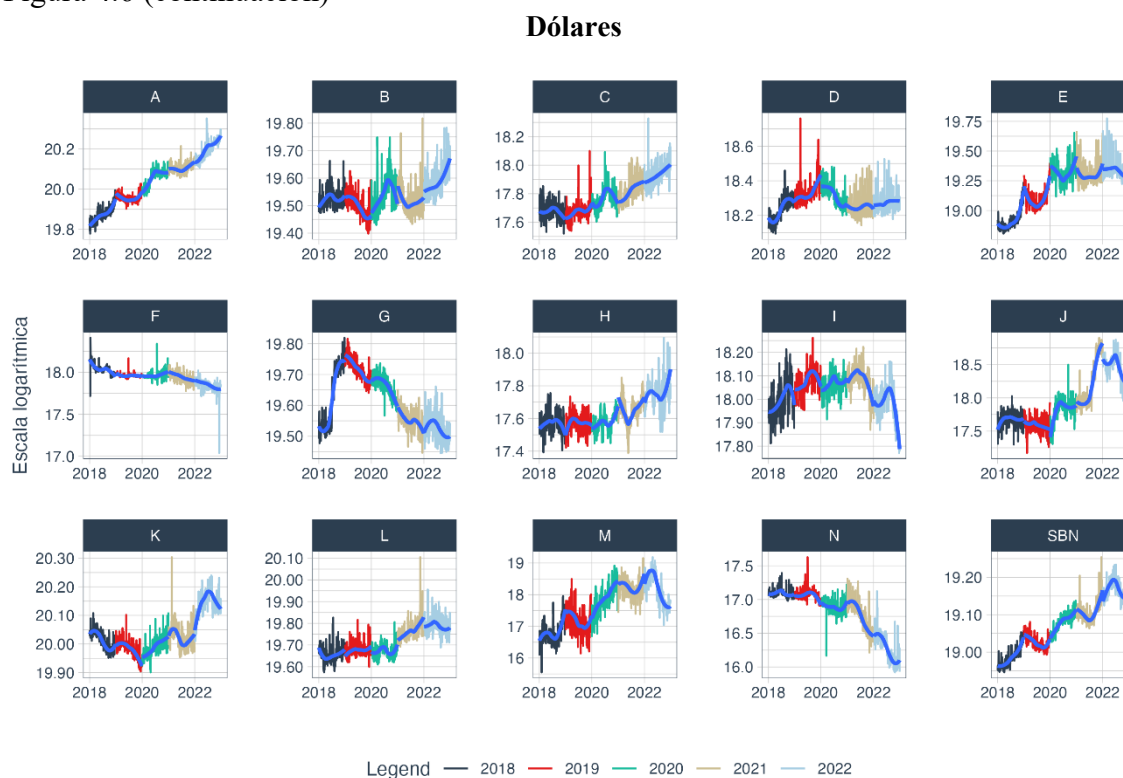
En la Figura 4.6 se muestra el comportamiento de los saldos diarios al inicio del día durante el periodo de análisis. Las escalas de los gráficos se expresan en escala logarítmica. Además de las diferencias en magnitud puede observarse en la figura que no todas las series muestran una tendencia similar.

Figura 4.6. SBN: Saldo inicial en las cuentas de fondos en el BCCR por banco y moneda. Cifras diarias 2018-2022



⁶ Horario comprendido entre las siete horas y las dieciocho horas de un mismo día hábil, utilizado por el BCCR para el cálculo del encaje mínimo legal.

Figura 4.6 (continuación)



Fuente: Elaboración propia con datos del SINPE

Al comparar los estadísticos descriptivos entre entidades, en colones se identifican tres agrupamientos de entidades y en dólares cuatro. Las entidades J y M son similares tanto en colones como en dólares, además en colones las entidades K y L tienen un comportamiento similar entre ellas mientras que en dólares un segundo conjunto está conformado por las entidades A y K (ver Figura C.3 en el Apéndice C)

4.1.3 PAGOS ENVIADOS Y RECIBIDOS

En la Figura 4.7 se muestra el tercer indicador que corresponde a la magnitud de los pagos enviados y recibidos por moneda. Debido a la alta volatilidad entre días, paralelamente a las series se muestran dos líneas suavizadas que corresponden a la magnitud de los pagos enviados y recibidos, cuando estas dos líneas muestran una separación, es un reflejo de que en términos netos la entidad presenta un aumento o una disminución por los flujos de pagos. Por ejemplo, entidades como la E, G tienen un efecto neto casi nulo en ambas monedas. Como la mayoría de la actividad en el SINPE es entre entidades del SBN es de esperar en el agregado una alta coincidencia entre el monto enviado y el recibido del sector.

Nuevamente, tanto la magnitud como las diferencias en las tendencias son las características de este indicador que le van a permitir al modelo de reconocimiento de patrones aumentar su poder predictivo. En el caso de colones se identificaron cuatro agrupamientos de entidades según pagos enviados y cinco para el comportamiento de los pagos recibidos, en dólares la cantidad de conglomerados se reduce a tres tanto en pagos enviados como recibidos (ver Figura C.4 del Apéndice C). Es importante señalar que un número mayor de agrupamientos significa un mayor poder discriminatorio de la variable para identificar un patrón único para cada entidad.

Figura 4.7. SBN: Pagos enviados y recibidos en las cuentas de fondos en el BCCR por banco y moneda. Cifras diarias 2018-2022

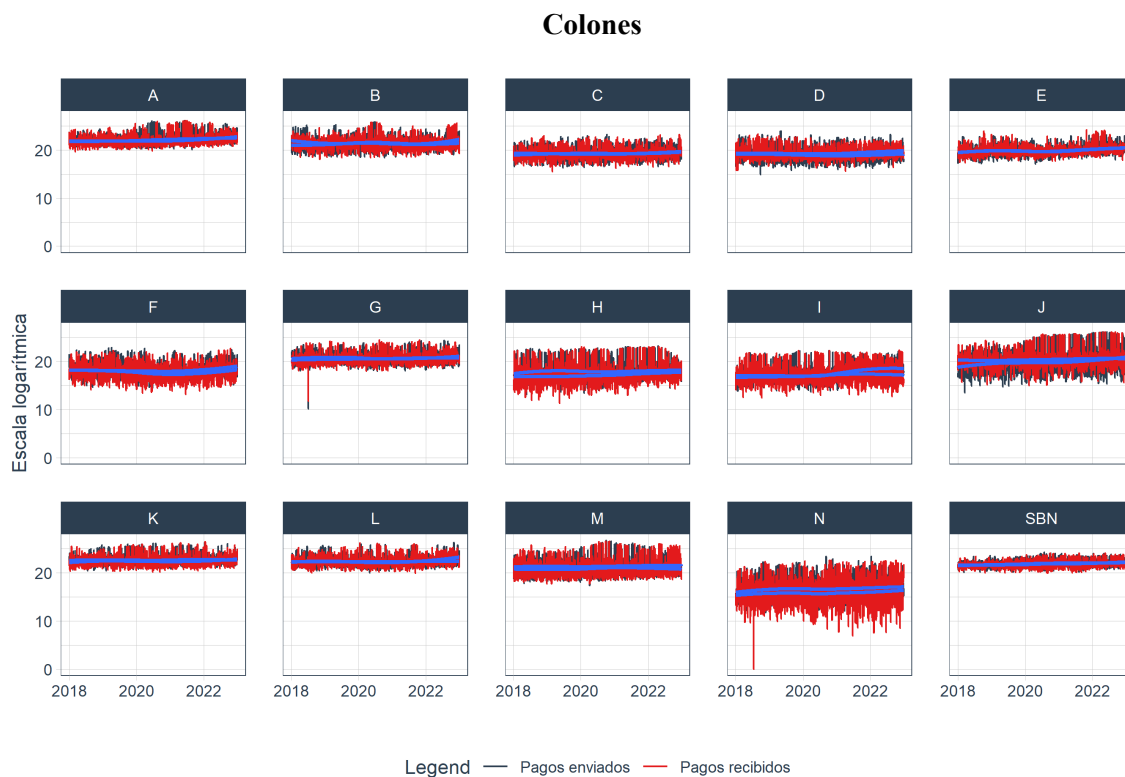


Figura 4.7 (continuación)

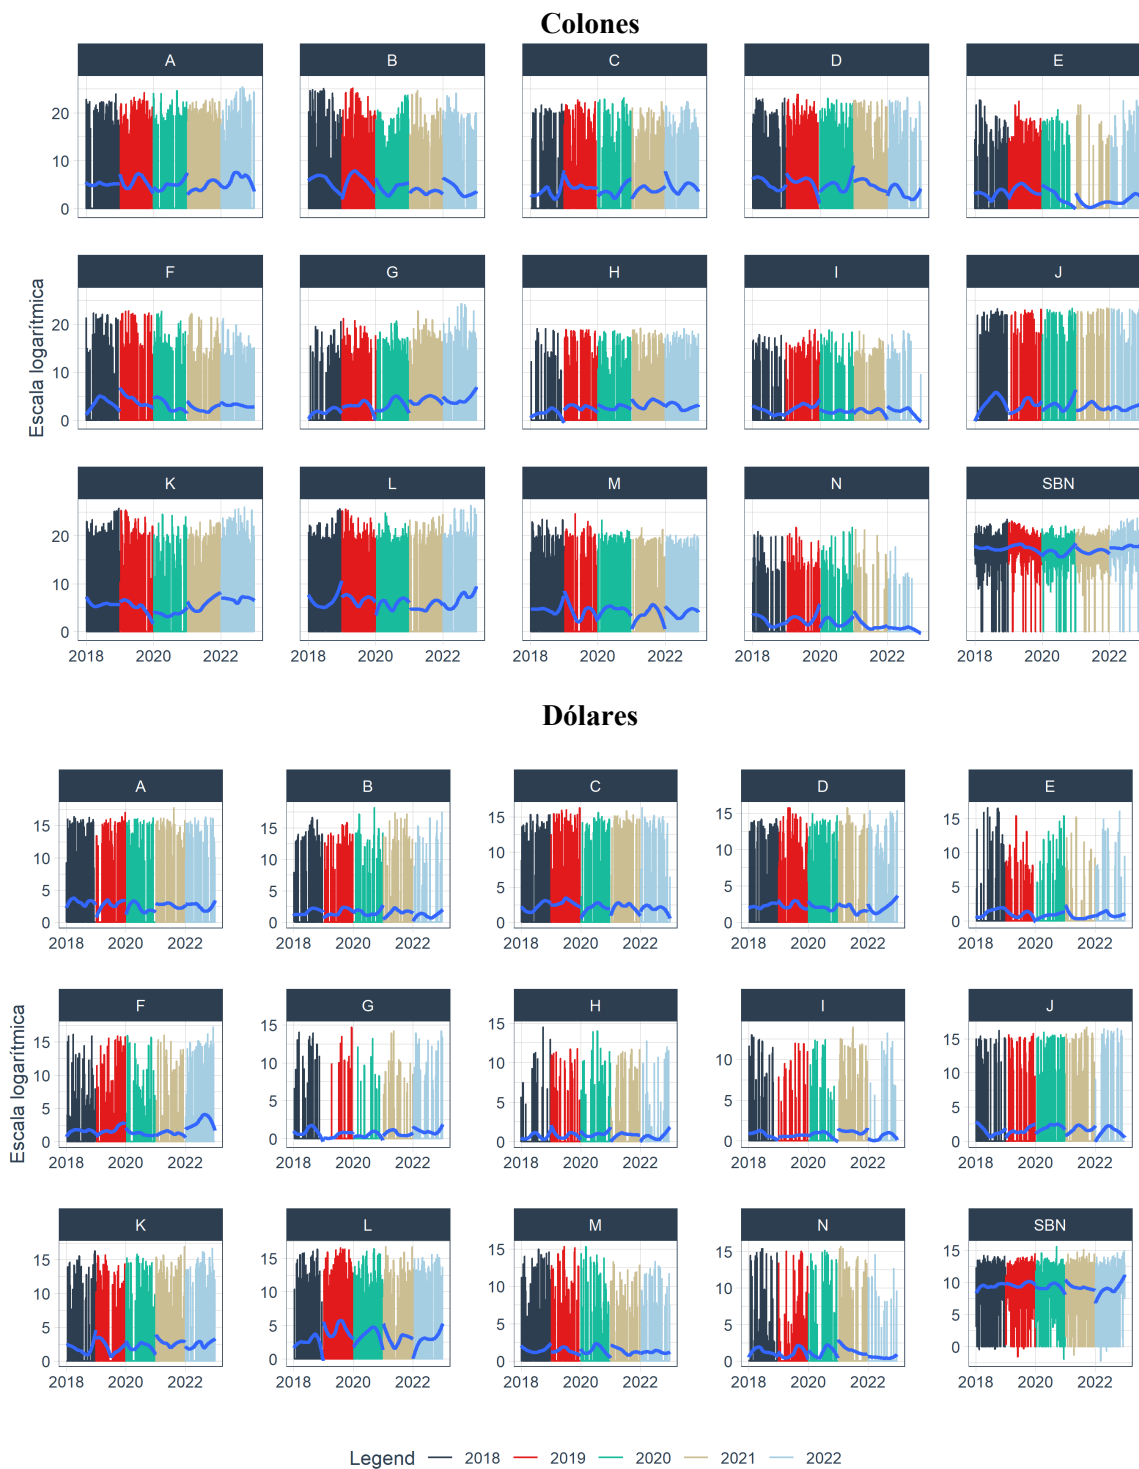


Fuente: Elaboración propia con datos del SINPE

4.1.4 OBLIGACIONES A HORAS ESPECÍFICAS Y OTRAS OBLIGACIONES CRÍTICAS

Para la construcción de este indicador se utilizaron los pagos realizados en los servicios del SINPE indicados en la Tabla 3.2. Como el dato corresponde a “obligaciones” únicamente se incluyen los montos en los que la entidad bancaria es un “pagador neto”. Por ejemplo, mientras que la entidad “H” es un pagador neto en colones es un “receptor neto en “dólares”, por otra parte, la entidad “D” es mayoritariamente pagador neto tanto en colones como en dólares (ver Figura 4.8).

Figura 4.8. SBN: Montos liquidados en servicios de liquidación neta por banco origen y moneda. Cifras diarias 2018-2022



Fuente: Elaboración propia con datos del SINPE

4.1.5 HORA DE LOS PAGOS INTRADÍA

Este indicador corresponde a la hora promedio ponderada por monto en que una entidad envía y recibe los pagos. Este indicador refleja la dependencia de una entidad de los flujos de pagos entrantes para poder cumplir con sus obligaciones de pago. En la Figura 4.9 se muestran los valores correspondientes a este indicador.

Cuando la hora promedio de los pagos enviados es menor que la hora promedio de los pagos recibidos, es decir, la serie de pagos enviados se ubica persistentemente en un nivel inferior a la de pagos recibidos, es reflejo que la entidad tiene una menor dependencia de los pagos recibidos para cumplir con las propias obligaciones de pago. Los retrasos de los pagos de una entidad pueden provocar a su vez atrasos en los pagos realizados por otras entidades.

En colones las entidades B, K, L, M muestran una brecha entre ambas series, en el caso de estas entidades, en promedio envían los pagos antes de la hora en que los reciben, es decir, para estas entidades no hay una dependencia de los flujos de pago entrantes para cumplir con sus obligaciones de pago, este comportamiento se mantiene en dólares para B y para L, es decir son entidades con suficiente liquidez en ambas monedas. Por el contrario, en colones la entidad J, envía los pagos a una hora posterior a la que recibe los flujos de pago entrantes, en dólares se refleja este comportamiento para la entidad D.

Adicionalmente, el análisis de conglomerados muestra que la entidad J tiene un comportamiento muy distinto al resto tanto en colones como en dólares y en pagos enviados como recibidos. Las entidades H, C y D tienen un comportamiento similar en el envío de pagos en ambas monedas. Estos indicadores permiten agrupar las entidades entre cuatro y cinco conglomerados, lo cual a nivel exploratorio es una señal de que este indicador tiene un comportamiento menos uniforme entre entidades (ver Figura C.6 del Apéndice C).

Figura 4.9. SBN: Hora promedio de los pagos enviados y recibidos por banco y moneda. Cifras diarias 2018-2022



Fuente: Elaboración propia con datos del SINPE

4.1.6 DISTRIBUCIÓN HORARIA

Finalmente, dentro del grupo de indicadores utilizado para caracterizar los hábitos de pago de las entidades se muestra el porcentaje de pagos acumulado a ciertas horas específicas, 7:00 horas (apertura del horario bancario), 12:00 horas (posterior a la liquidación de vencimientos del MIL 11:00 y la liquidación de VISA y Master Card), 15:00 horas (posterior a la liquidación de vencimientos de deuda), 18:00 horas (cierre de horario bancario) y 22:00 horas (posterior a la liquidación de las cámaras de compensación).

En la Figura 4.10 se muestra el resultado de este indicador, destacando un comportamiento similar entre grupos de entidades y monedas. Estos indicadores permiten agrupar las entidades entre cuatro y cinco conglomerados, destaca la entidad J con un comportamiento diferenciado entre el resto de las entidades (ver Figura C.7 del Apéndice C).

Figura 4.10. SBN: Porcentaje acumulado de pagos enviados según hora por banco y moneda. Cifras diarias 2018-2022

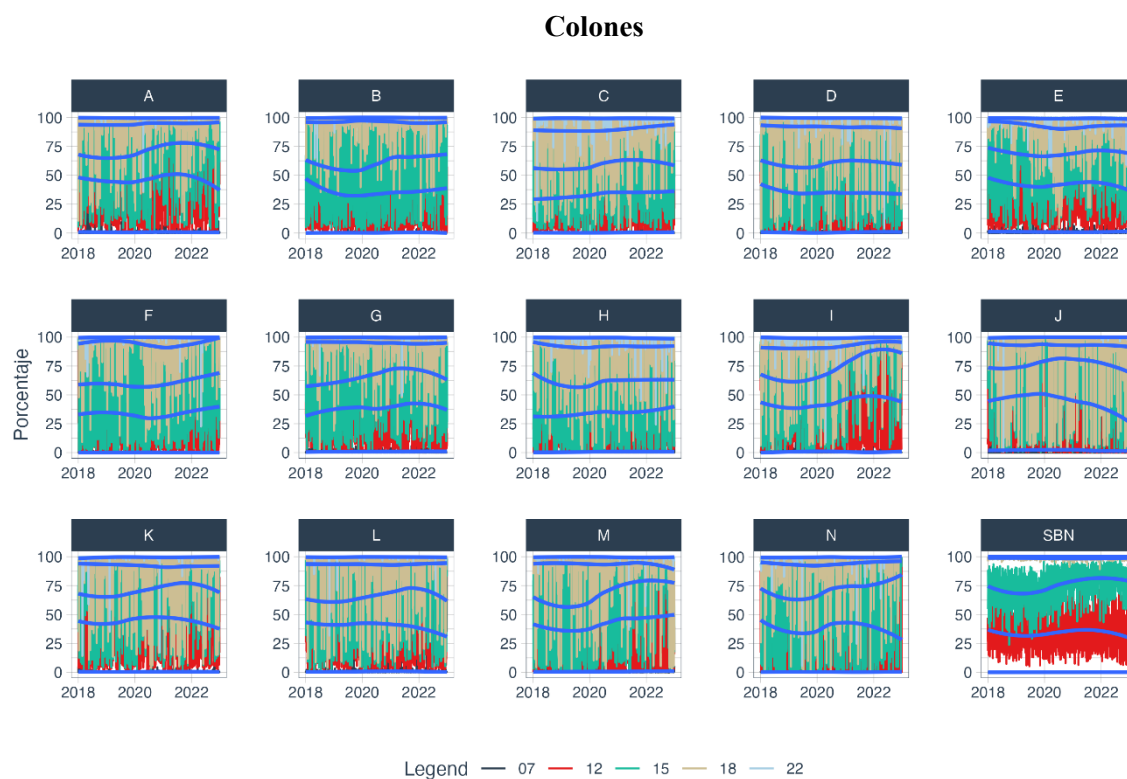
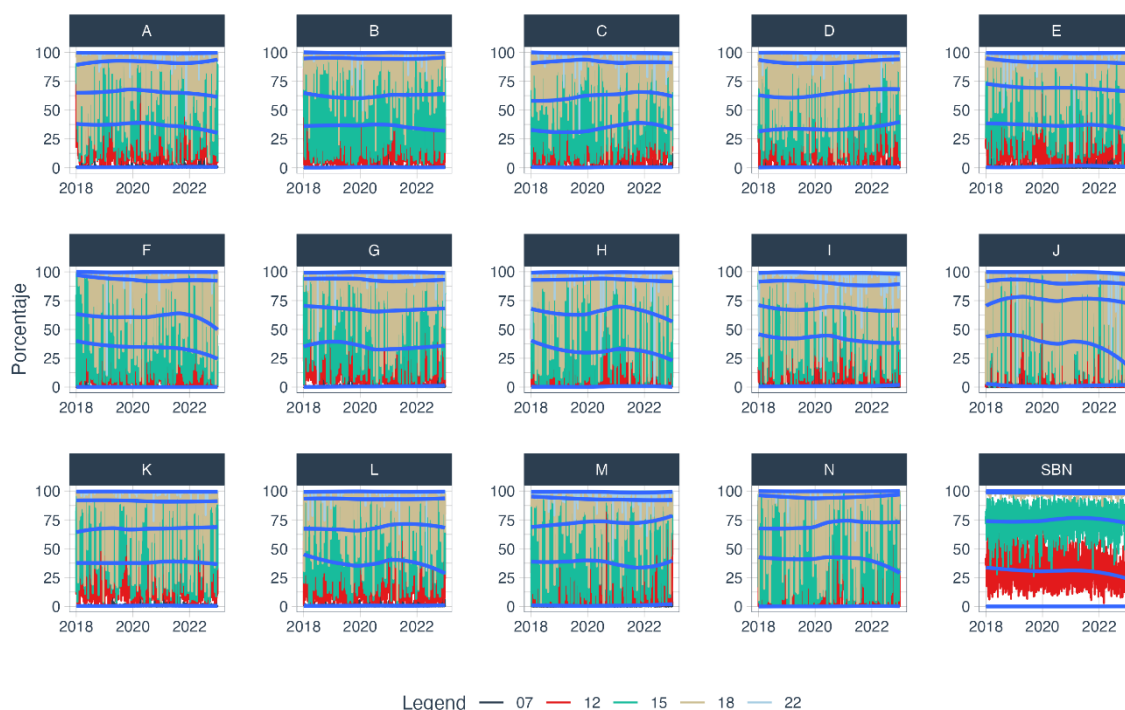


Figura 4.10 (continuación)

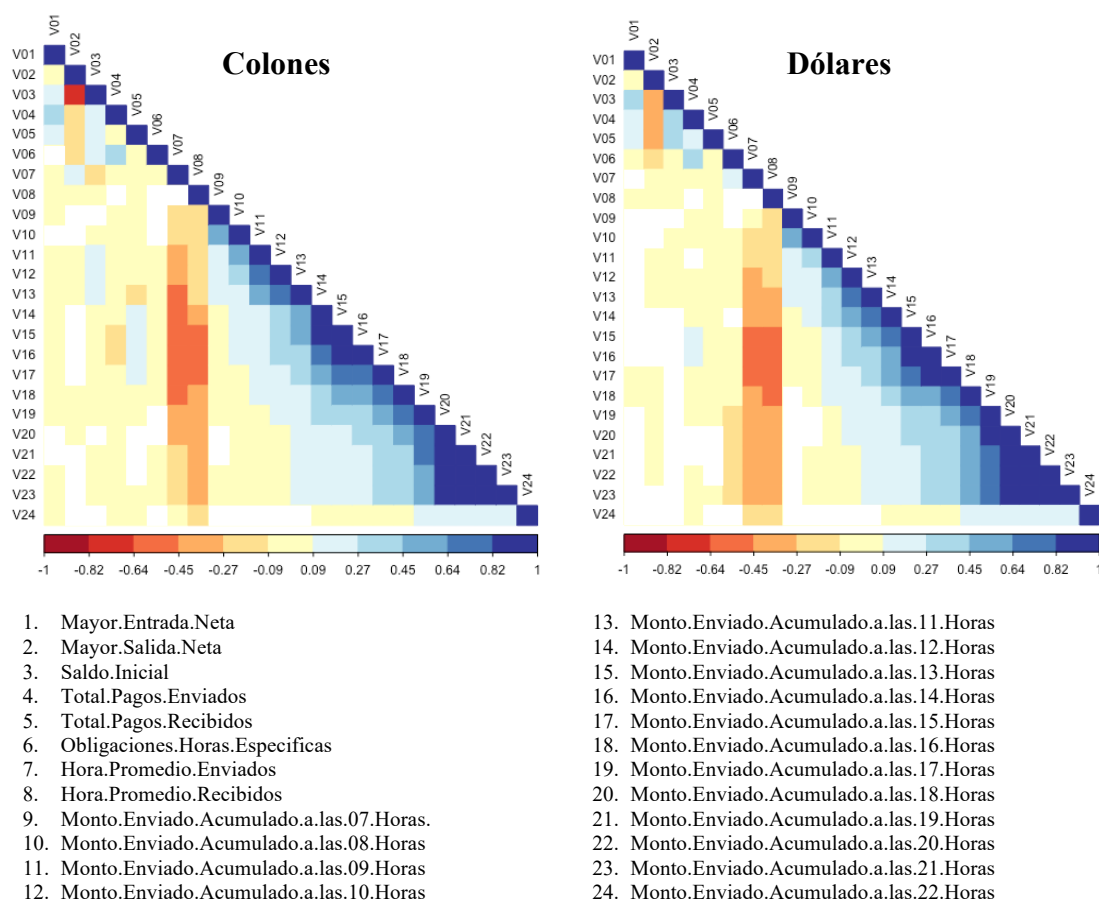
Dólares

Fuente: Elaboración propia con datos del SINPE

4.1.7 CORRELACIONES ENTRE VARIABLES DE HÁBITOS DE PAGO

Cuando alguna de las variables consideradas está altamente correlacionada con alguna de las otras variables, es recomendable incorporar solo una de ellas para evitar aumentar el peso de dicha característica, ya que ambas variables entregan la misma información. Para evitar este sesgo, calculamos la correlación simple entre el conjunto de indicadores tanto en colones como en dólares (Figura 4.11). Como se puede observar, en el caso de colones, el monto de la mayor salida neta está correlacionado negativamente con el saldo inicial. En ambas monedas, las variables de los montos acumulados entre las 11 y las 16 horas están correlacionados con la hora promedio de los pagos enviados y recibidos, del mismo modo, los montos acumulados entre las 17 y 21 horas están correlacionados positivamente entre sí, por lo que podrían suprimirse del análisis las variables de montos acumuladas sin perder información del modelo y reducir el conjunto de variables a 8 por cada moneda.

Figura 4.11. Matriz de correlaciones variables hábitos de pago por moneda



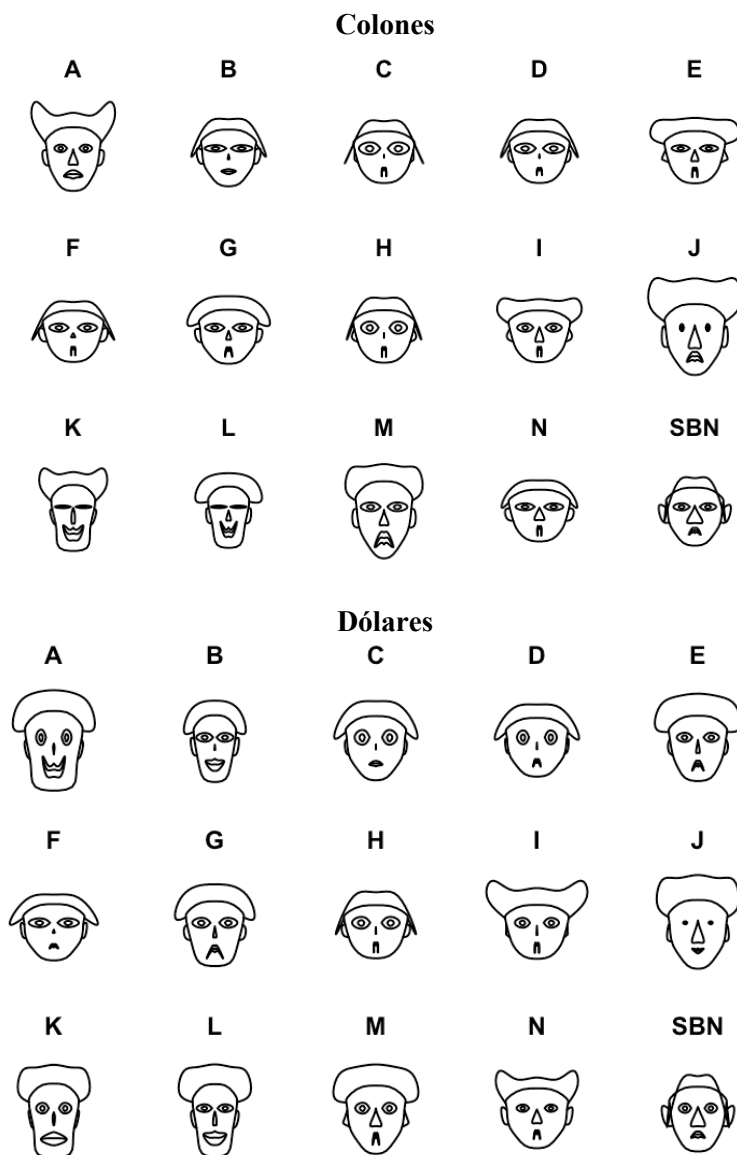
Fuente: Elaboración propia con datos del SINPE

Como un elemento más del análisis exploratorio para este primer conjunto de variables se utilizó la representación de caras de Chernoff. Inventadas por Herman Chernoff, este tipo de ilustración permite visualizar datos multivariados en la forma de un rostro humano. Las partes individuales, tales como ojos, oídos, boca y nariz representan los valores de las variables por su forma, tamaño, ubicación y orientación. La idea detrás de usar estos rostros se basa en que los seres humanos pueden reconocer fácilmente la cara y notar pequeños cambios sin dificultad (Escuela de Arquitectura y Diseño, Pontificia Universidad Católica de Valparaíso, 2024).

Tal y como se muestra en la Figura 4.12 tanto en colones como en dólares, las entidades C, D, F y H tienen un aspecto similar en varias características, lo mismo sucede con K y L. Esta

representación gráfica permite adelantar que este conjunto de variables no es suficiente para la discriminación entre entidades con un aspecto similar.

Figura 4.12. SBN: Caras de Chernoff para variables de hábitos de pago. Promedios sobre cifras diarias 2018-2022



1. **Altura de la cara:** Mayor.Entrada.Neta
2. **Anchura de la cara:** Mayor.Salida.Neta
3. **Forma de la cara (redonda o delgada):** Saldo.Inicial
4. **Altura de la boca:** Total.Pagos.Enviados
5. **Anchura de la boca:** Total.Pagos.Recibidos
6. **Curva de Sonrisa:** Obligaciones.Horas.Especificas
7. **Altura de ojos:** Hora.Promedio.Enviados
8. **Anchura de ojos:** Hora.Promedio.Recibidos

9. **Altura de pelo:** Monto.Enviado.Acumulado.a.las.07.Horas
10. **Ancho de pelo:** Monto.Enviado.Acumulado.a.las.10.Horas
11. **Estilo de pelo:** Monto.Enviado.Acumulado.a.las.12.Horas
12. **Altura de nariz:** Monto.Enviado.Acumulado.a.las.15.Horas
13. **Anchura de nariz:** Monto.Enviado.Acumulado.a.las.16.Horas
14. **Altura de orejas:** Monto.Enviado.Acumulado.a.las.18.Horas
15. **Anchura de orejas:** Monto.Enviado.Acumulado.a.las.22.Horas

Fuente: Elaboración propia con datos del SINPE

4.2 RESULTADOS ANÁLISIS DE TOPOLOGÍA DE REDES

4.2.1 RED SERVICIOS DE LIQUIDACIÓN BRUTA EN TIEMPO REAL (LBTR)

Las transacciones de pagos que en adelante se consideran, conforman una red dirigida donde los nodos corresponden a los participantes del SINPE y el sentido de las flechas representa el débito que se hace a la cuenta de fondos de una entidad origen y el crédito a la respectiva cuenta de una entidad destino. El peso de las flechas en esta red puede estar dado tanto por la cantidad, como por el monto de las transacciones que entre los nodos se realizan, para el caso en particular se utilizó el monto como ponderador.

Tal y como se muestra en el Cuadro 4.1 la red de servicios de LBTR pasó de un promedio de 70 participantes en el 2018 a 118 en el 2022. El incremento durante este periodo ha sido impulsado en gran medida por la autorización de nuevos participantes entre los que destacan fondos de pensión, fondos de inversión y proveedores de servicios de pago que incluyen a las *Fintech*.

Algunos autores catalogan las redes, de acuerdo con el número de nodos, en: pequeñas hasta 100 nodos, medianas entre 100 y 1.000 nodos y grandes aquellas que superan los 1.000 nodos (Cepeda, 2018). Por tanto, según el dato más reciente presentado, la red de pagos de LBTR es considerada como una red de tamaño medio.


**Cuadro 4.1. Estadísticas básicas de la red de servicios de LBTR por moneda.
Promedios diarios y desviaciones estándar 2018-2022**

Indicador	2018	2019	2020	2021	2022
Número de participantes (Nodos)	70±1,5	76±3,4	89±3,4	102±5,3	118±7,9
Colones					
Número de conexiones	658±37,5	750±66,1	920±75,0	1.029±63,7	1.108±72,8
Densidad (%)	13,7±0,9	13,2±0,8	11,6±0,8	10,1±1,2	8,1±0,9
Grado promedio	9,4±0,5	9,9±0,6	10,3±0,7	10,1±0,7	9,4±0,6
Dólares					
Número de conexiones	431±31,2	473±35,0	506±37,3	565±39,5	619±40,2
Densidad (%)	9,0±0,7	8,4±0,7	6,4±0,5	5,5±0,6	4,5±0,5
Grado promedio	6,2±0,4	6,2±0,4	5,7±0,4	5,6±0,4	5,3±0,4

Fuente: Elaboración propia con datos del SINPE

Adicionalmente, se observa que para el 2022 el número de parejas origen-destino diarias resultantes de las transacciones de pago fluctuó entre 1.035 y 1.181 en colones y; 579 y 659 en dólares con un valor promedio de 1.108 y 619 respectivamente.

Figura 4.13. Red transacciones de servicios de LBTR del SINPE en colones a diciembre de cada año. 2018-2022.



Fuente: Elaboración propia con datos del SINPE

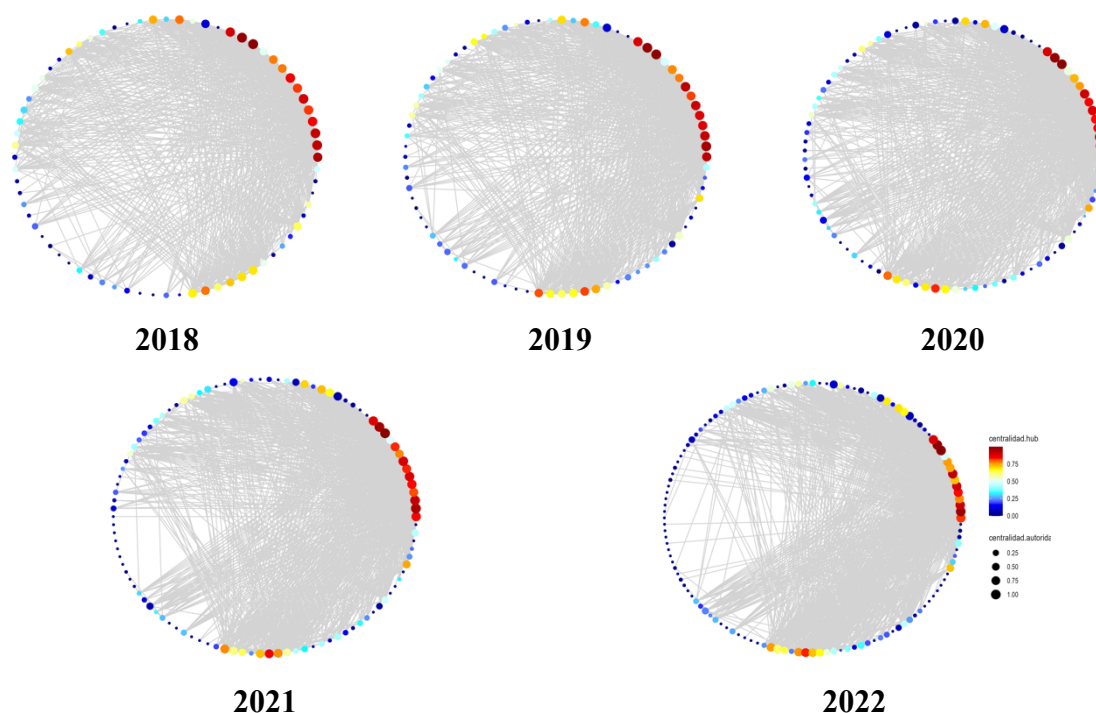
El indicador de densidad o conectividad muestra que de las duplas posibles de entidad origen-destino, para el 2022 únicamente se concretaron en promedio un 8,1% en colones y un 4,5% en dólares⁷. Este indicador disminuyó en alrededor de 6 puntos porcentuales en colones y 4 puntos porcentuales en dólares durante los años 2018 y 2022, debido a que los participantes que se han ido integrando a la red de pagos tienen una menor interacción en el SINPE con el resto de los participantes. En la Figura 4.13 y en la Figura 4.14 se puede apreciar esta menor densidad particularmente al lado izquierdo de los grafos que es donde se ubican los

⁷ Baek et al (2014) encuentran en el BOK-Wire+ de Corea una densidad del 18,1% (122 nodos), en el LVTS de Canadá de 69,2% (14 nodos), en el TOP de Países Bajos 7,0% (155 nodos) y de 0,3% (5.086 nodos) en el Fedwire de Estados Unidos.

participantes del sector pensiones (en dirección de las manecillas del reloj aproximadamente entre las 8 y las 10).

En cuanto al grado, o la cantidad de entidades con las que en promedio interactúa cada participante, durante el periodo comprendido entre el 2018 y 2022 osciló entre 9 y 10 en colones y; entre 5 y 6 para dólares.

Figura 4.14. Red transacciones de servicios de LBTR del SINPE en dólares a diciembre de cada año. 2018-2022.



Fuente: Elaboración propia con datos del SINPE

Asimismo, en la Figura 4.13 y la Figura 4.14 se representa la importancia de los participantes como entidad origen (en escala de color del nodo según el indicador de centralidad Hub) y su importancia como entidad destino (está representado por el tamaño del nodo según el indicador de Autoridad), siendo las entidades bancarias (ubicadas en el primer cuadrante del gráfico) las que tienen una mayor importancia tanto como origen y destino dentro de la red de servicios de LBTR. En importancia según tipo de entidad también destacan algunas cooperativas o mutuales (en dirección de las manecillas del reloj aproximadamente entre las

5 y las 7) y con la menor participación en los servicios de LBTR los puestos de bolsa, entidades del gobierno y entidades del sector pensiones (fondos de pensión y Operadoras de Pensiones Complementarias OPC).

Adicionalmente, se obtuvieron las correlaciones entre los indicadores que caracterizan cada uno de los vértices (entidades), encontrando casi en la totalidad de indicadores correlaciones que superan 0,65. Por lo cual, esto es indicio de que se pueden obtener grandes beneficios de la técnica de ACP para reducir el comportamiento de estas 10 variables en unos pocos componentes (ver Cuadro 4.2).

Cuadro 4.2. Correlaciones entre los indicadores de propiedad en los vértices para la red de transacciones de servicios de LBTR por moneda

Colones											Dólares										
	V01	V02	V03	V04	V05	V06	V07	V08	V09	V10		V01	V02	V03	V04	V05	V06	V07	V08	V09	V10
V01	1,00										V01	1,00									
V02	0,99	1,00									V02	0,98	1,00								
V03	0,99	0,96	1,00								V03	0,98	0,93	1,00							
V04	0,78	0,78	0,77	1,00							V04	0,73	0,73	0,70	1,00						
V05	0,76	0,76	0,74	0,96	1,00						V05	0,69	0,69	0,65	0,96	1,00					
V06	0,75	0,75	0,74	0,98	0,88	1,00					V06	0,72	0,72	0,70	0,96	0,84	1,00				
V07	0,67	0,68	0,64	0,80	0,84	0,72	1,00				V07	0,58	0,59	0,54	0,67	0,73	0,55	1,00			
V08	0,90	0,93	0,86	0,67	0,67	0,64	0,63	1,00			V08	0,93	0,95	0,86	0,67	0,63	0,66	0,57	1,00		
V09	0,89	0,90	0,87	0,69	0,67	0,66	0,64	0,95	1,00		V09	0,89	0,85	0,90	0,61	0,55	0,62	0,48	0,87	1,00	
V10	0,37	0,35	0,38	0,16	0,15	0,16	0,10	0,29	0,29	1,00	V10	0,49	0,48	0,49	0,30	0,27	0,31	0,19	0,45	0,44	1,00

1. Grado	6. Intensidad de salida
2. Grado de entrada	7. Centralidad del vector propio
3. Grado de salida	8. Centralidad Autoridad
4. Intensidad	9. Centralidad Hub
5. Intensidad de entrada	10. Centralidad de intermediación

Fuente: Elaboración propia con datos del SINPE

4.2.2 RED MERCADO INTEGRADO DE LIQUIDEZ (MIL)

El Mercado Integrado de Liquidez (MIL) es el servicio por medio del cual el BCCR controla la liquidez del sistema financiero, y los demás participantes realizan operaciones financieras para administrar posiciones de liquidez de corto plazo. Las operaciones de calce del MIL constituyen una red dirigida donde los nodos corresponden a las entidades participantes del MIL y el sentido de las flechas muestra la posición de la entidad como acreedor o como deudor de fondos. El peso de las flechas en esta red se determinó por el monto de los calces entre nodos.

La cantidad de participantes en el MIL rondó los 32 durante el periodo comprendido entre 2018 y 2021 y se ubicó entre 33 y 45 para el 2022. Las OPC y fondos de pensión son los principales participantes que se sumaron a este mercado. No obstante, la red del MIL todavía sigue siendo catalogada como una red de tamaño pequeño.

**Cuadro 4.3. Estadísticas básicas de la red de MIL por moneda.
Promedios diarios y desviaciones estándar 2018-2022**


Indicador	2018	2019	2020	2021	2022
Número de participantes (Nodos)	32,0±1,2	32,7±0,8	31,5±1,1	32,1±1,3	38,8±5,8
Colones					
Número de conexiones	41,4±6,0	42,0±5,6	34,1±6,1	33,8±4,6	51,4±10,9
Densidad (%)	4,2±0,5	4,1±0,6	3,6±0,7	3,4±0,5	3,6±0,6
Grado promedio	1,3±0,2	1,3±0,2	1,1±0,2	1,1±0,1	1,3±0,2
Dólares					
Número de conexiones	12,2±3,8	12,7±3,4	10,3±3,7	10,0±3,2	13,1±5,0
Densidad (%)	1,2±0,4	1,2±0,3	1,1±0,4	1,0±0,3	0,9±0,3
Grado promedio	0,4±0,1	0,4±0,1	0,3±0,1	0,3±0,1	0,3±0,1

Fuente: Elaboración propia con datos del SINPE

El indicador de densidad o conectividad muestra que de las duplas posibles de entidad acreedor-deudor, para el 2022 únicamente se concretaron en promedio un 3,6% en colones y un 0,9% en dólares⁸. Al igual que en la red de servicios de LBTR, el incremento en la cantidad de participantes se ha traducido en redes menos densas, por cuanto los nuevos participantes interactúan poco con otros participantes y en el caso particular del MIL en colones, muchas entidades únicamente interactúan con el BCCR. Este indicador disminuyó en alrededor de 0,6 puntos porcentuales en colones y 0,3 puntos porcentuales en dólares durante los años 2018 y 2022, (ver Figura 4.15 y Figura 4.16).

⁸ León et al (2014) estimaron la densidad del mercado de liquidez colombiano en un 7%.

Figura 4.15. Red negociaciones en MIL colones a diciembre de cada año. 2018-2022.



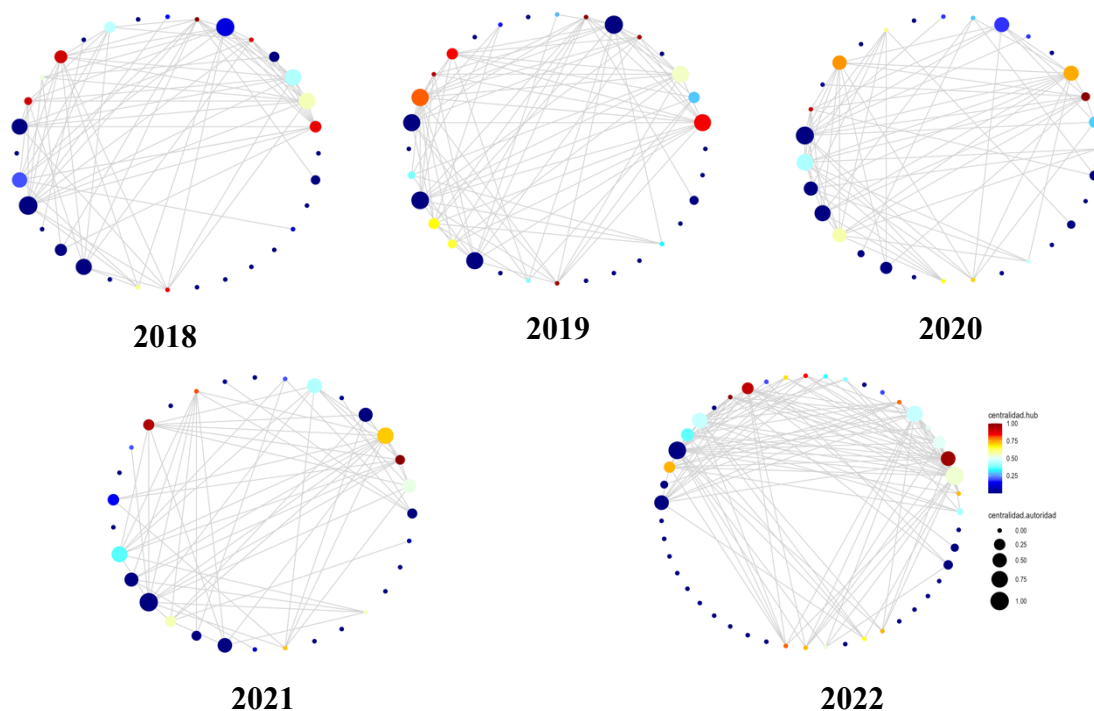
Fuente: Elaboración propia con datos del SINPE

El objetivo de la participación del Banco Central en el MIL es evitar presiones sobre la tasa de interés de las negociaciones efectuadas a un día plazo. Para ello el Banco suministra al sistema financiero la liquidez necesaria en caso de que este se encuentre escaso de recursos o bien drena recursos si el sistema muestra un exceso. En línea con lo anterior, durante el periodo de análisis puede observarse un aumento en el índice *hub* (índice de importancia como acreedor) del BCCR en los periodos de escasez de liquidez y un incremento en el índice de autoridad (índice de importancia como deudor) ante los excesos de liquidez. En la Figura 4.15 esto se refleja con una tonalidad más roja en escasez de liquidez y una más azul y un nodo de mayor tamaño en épocas de excesos de liquidez.

La Figura 4.16 es reflejo de la menor profundidad del MIL en dólares. En términos generales muestra una mayor interacción entre bancos y puestos de bolsa, por cuanto la participación del Banco Central en esta moneda es más reducida. Debido a que las tasas de negociación en el MIL son en promedio inferiores a las de los mercados que opera la Bolsa Nacional de Valores (BNV), los puestos de bolsa se caracterizan por tener altos valores en el indicador

de autoridad (deudor y mayor diámetro del nodo), mientras que los bancos muestran mayores valores en el indicador de *hub* (acreedores y tonalidades de los nodos naranjas y rojos).

Figura 4.16. Red negociaciones en MIL dólares a diciembre de cada año. 2018-2022.



Fuente: Elaboración propia con datos del SINPE

Al igual que en la red de transacciones de servicios de LBTR se obtuvieron las correlaciones entre los indicadores que caracterizan cada uno de los vértices (entidades). Al corresponder las cifras a un mercado de negociación existen correlaciones positivas entre aquellos indicadores que reflejan la importancia en una misma posición (ya sea como deudor o como acreedor) y correlaciones negativas entre indicadores que muestran la importancia entre posturas en el mercado opuestas, es decir, la entidad que tiene un buen posicionamiento como acreedor, tiene uno bajo como deudor y viceversa (ver Cuadro 4.4).

Cuadro 4.4. Correlaciones entre los indicadores de propiedad en los vértices para la red de negociaciones del MIL por moneda

Colones											Dólares										
	V01	V02	V03	V04	V05	V06	V07	V08	V09	V10		V01	V02	V03	V04	V05	V06	V07	V08	V09	V10
V01	1,00										V01	1,00									
V02	0,80	1,00									V02	0,67	1,00								
V03	0,32	-0,31	1,00								V03	0,68	-0,09	1,00							
V04	0,30	0,10	0,34	1,00							V04	0,74	0,53	0,47	1,00						
V05	0,59	0,69	-0,16	0,33	1,00						V05	0,55	0,80	-0,05	0,71	1,00					
V06	0,04	-0,23	0,43	0,89	-0,13	1,00					V06	0,48	-0,08	0,72	0,68	-0,04	1,00				
V07	0,33	0,39	-0,08	0,14	0,49	-0,08	1,00				V07	0,16	0,15	0,06	0,10	0,11	0,03	1,00			
V08	0,72	0,92	-0,32	0,07	0,65	-0,23	0,34	1,00			V08	0,56	0,87	-0,11	0,42	0,66	-0,10	0,10	1,00		
V09	0,09	-0,41	0,80	0,33	-0,22	0,45	-0,10	-0,44	1,00		V09	0,52	-0,11	0,81	0,40	-0,07	0,64	0,02	-0,12	1,00	
V10	0,46	0,41	0,09	0,11	0,35	-0,05	0,32	0,32	0,02	1,00	V10	0,40	0,36	0,18	0,30	0,32	0,09	0,33	0,24	0,08	1,00

1. Grado	6. Intensidad de salida
2. Grado de entrada	7. Centralidad del vector propio
3. Grado de salida	8. Centralidad Autoridad
4. Intensidad	9. Centralidad Hub
5. Intensidad de entrada	10. Centralidad de intermediación

Fuente: Elaboración propia con datos del SINPE

4.2.3 RED MERCADO DE MONEDAS EXTRANJERAS (MONEX)

El Mercado de Monedas Extranjeras (Monex) lo organiza el BCCR y constituye el medio por el cual sus participantes negocian entre sí operaciones de compra y de venta de divisas. Dicho mercado cuenta con dos canales de acceso:

- **Servicio Monex-SINPE:** dirigido y utilizado por las entidades autorizadas que realizan intermediación cambiaria en el país con fines lucrativos (como un negocio habitual).
- **Servicio Monex-Central Directo:** dirigido y utilizado por personas físicas y jurídicas que requieren satisfacer necesidades propias de transacción de divisas. Quienes participen en este servicio no podrán negociar operaciones que constituyan intermediación cambiaria.

Las operaciones de calce del Monex constituyen una red dirigida donde los nodos corresponden a las entidades participantes del Monex que entran por cualquiera de los dos canales de acceso, es decir, tanto intermediarios cambiarios como personas físicas y jurídicas que participan en el mercado. En esta red el sentido de las flechas muestra la posición de la entidad como vendedor o como comprador de divisas, actualmente solo se negocian dólares en este mercado. El peso de las flechas en esta red se determinó por el monto de los calces que entre nodos.

Tal y como se muestra en el Cuadro 4.5 la cantidad promedio del total de participantes en el Monex pasó de alrededor 490 en el año 2018 a alrededor de 700 en el año 2022, para esos años la cantidad de intermediarios cambiarios dentro de ese total de participantes pasó de 43 a 88 entidades, de ese incremento 34 corresponden a OPC y fondos de pensiones. La cantidad de participantes en el Monex permite catalogar a esta red como una red de tamaño mediano.

También puede observarse que el número de parejas comprador-vendedor diarias resultantes de los calces pasó de fluctuar entre 72 y 118 en el 2018 a fluctuar entre 93 y 150 en el 2022.

**Cuadro 4.5. Estadísticas básicas de la red de Monex.
Promedios diarios y desviaciones estándar 2018-2022**

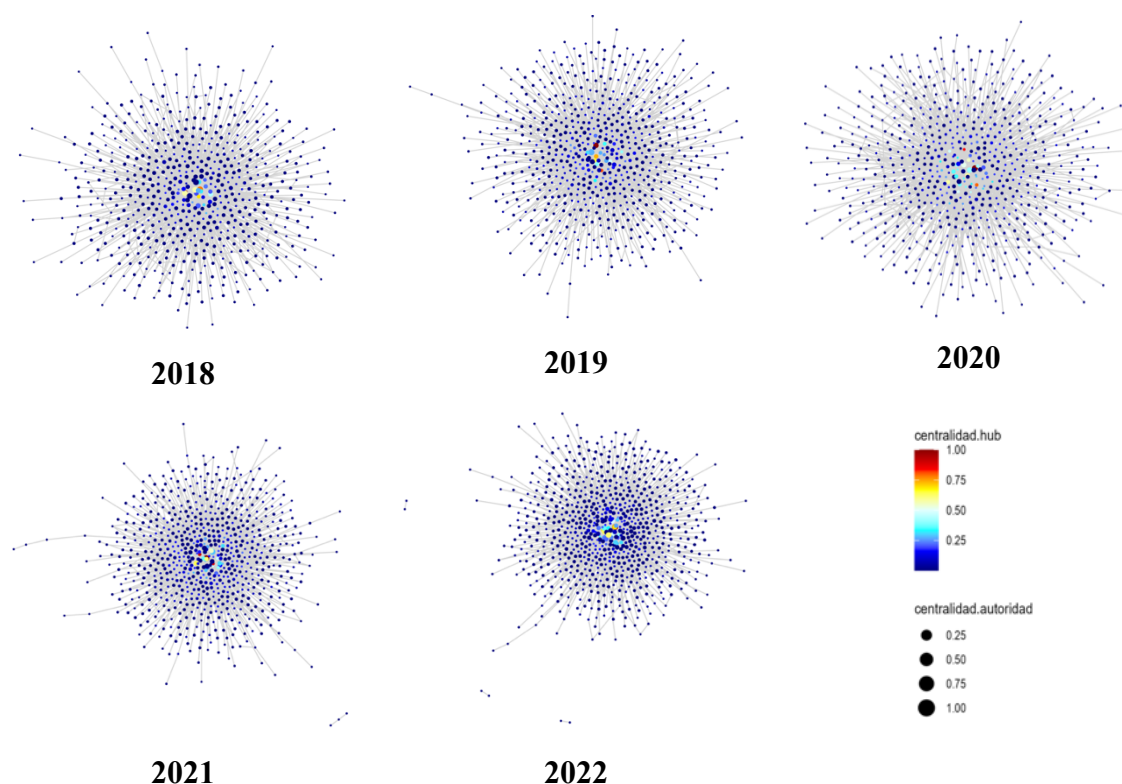
Indicador	2018	2019	2020	2021	2022
Número de participantes (Nodos)	490,7±50,0	566,5±36,1	553,9±39,3	621,0±37,9	699,1±42,3
Número de conexiones	94,3±22,8	99,6±23,6	94,0±23,1	107,2±24,9	123,1±30,4
Densidad (%)	1,7±0,4	1,5±0,3	1,6±0,4	1,5±0,3	1,4±0,3
Grado promedio	1,2±0,1	1,2±0,1	1,2±0,1	1,2±0,1	1,3±0,1

Fuente: Elaboración propia con datos del SINPE

El indicador de densidad o conectividad muestra que de las duplas posibles de entidad vendedor-comprador, para el 2022 únicamente se concretaron en promedio un 1,4⁹. Este indicador se ha mantenido estable durante el periodo analizado.

⁹ Pérez et al (2015) estimaron la densidad del mercado cambiario colombiano de 46 participantes en un 69%.

Figura 4.17. Red negociaciones en Monex a diciembre de cada año. 2018-2022.



Fuente: Elaboración propia con datos del SINPE

Las entidades que tienen una mayor importancia tanto como compradores como vendedores continúan siendo los intermediarios cambiarios, particularmente entidades bancarias y el Banco Central y corresponden con los nodos que están ubicados en el centro de las redes representadas en la Figura 4.17. Por el contrario, en los bordes de la red se ubican aquellos participantes que realizaron un único calce durante las sesiones del mes utilizado para la construcción de los gráficos. Asimismo, puede apreciarse tanto en diciembre del 2021 y como en diciembre de 2022, que existen pares de participantes que únicamente interactuaron entre ellos.

Finalmente, se estimaron las correlaciones entre los indicadores que caracterizan cada uno de los vértices (entidades) de la red de Monex. Al igual que en el MIL existen correlaciones positivas entre aquellos indicadores que reflejan la importancia en una misma posición (ya sea como comprador o vendedor). Las magnitudes observadas son muestras de que el ACP

podría traer beneficios en cuanto a la reducción de la dimensionalidad de los datos para construir el modelo de detección de patrones (Cuadro 4.6).

Cuadro 4.6. Correlaciones entre los indicadores de propiedad en los vértices para la red de negociaciones del Monex

	V01	V02	V03	V04	V05	V06	V07	V08	V09	V10
V01	1,00									
V02	0,73	1,00								
V03	0,75	0,09	1,00							
V04	0,53	0,17	0,61	1,00						
V05	0,42	0,65	-0,02	0,30	1,00					
V06	0,37	-0,10	0,64	0,91	-0,12	1,00				
V07	0,20	0,29	0,02	0,06	0,27	-0,05	1,00			
V08	0,57	0,85	0,00	0,14	0,68	-0,14	0,31	1,00		
V09	0,56	-0,03	0,84	0,56	-0,11	0,63	-0,02	-0,13	1,00	
V10	0,66	0,58	0,41	0,16	0,27	0,05	0,23	0,42	0,25	1,00

- | | |
|--------------------------|-----------------------------------|
| 1. Grado | 6. Intensidad de salida |
| 2. Grado de entrada | 7. Centralidad del vector propio |
| 3. Grado de salida | 8. Centralidad Autoridad |
| 4. Intensidad | 9. Centralidad Hub |
| 5. Intensidad de entrada | 10. Centralidad de intermediación |

Fuente: Elaboración propia con datos del SINPE

4.3 RESULTADOS ANÁLISIS DE COMPONENTES PRINCIPALES

4.3.1 ACP INDICADORES DE HÁBITOS DE PAGO

Inicialmente se parte de un conjunto de datos de 16 variables y 17.556 observaciones que corresponden a la información de las 14 entidades bancarias para los días hábiles del periodo comprendido entre 2018 y 2022. A los indicadores calculados en la sección ‘4.1 RESULTADOS INDICADORES DE HÁBITOS DE PAGO’ se adicionaron los indicadores propuestos por Heijmans y Heuver (2011) que en la actualidad son calculados diariamente por el Departamento de Estabilidad Financiera del Banco Central que corresponden a:

- **Posición de EML:** saldo depositado de encaje mínimo legal respecto al monto requerido, en monto y como porcentaje del requerimiento.
- **Posición neta en los mercados de liquidez:** saldo de operaciones vigentes en los mercados de liquidez (MIL del BCCR, REPO y MEDI administrados por la Bolsa Nacional de Valores). Se estima como el saldo vigente de las inversiones menos el saldo vigente de las captaciones.

- **Monto neto de las transferencias de clientes en el SINPE:** monto de los pagos recibidos menos el monto de los pagos enviados para los servicios de Pagos Inmediatos (PIN) y Débito en Tiempo Real (DTR).
- **Garantías depositadas en el SINPE:** saldo de las garantías depositadas en el Fideicomiso del SINPE, así como el porcentaje de estas garantías comprometido por captaciones en el MIL.

Adicional a estos indicadores se contempló el monto de la custodia de la deuda del Sistema de Anotación en Cuenta por considerarse que es un indicador que va a ayudar a discriminar o clasificar estadísticamente a las entidades.

Tabla 4.1. Variables de hábitos de pago incorporadas para el Análisis de Componentes Principales

Indicadores propuestos por Basel Committee on Banking Supervision (2013)	Indicadores propuestos por Heijmans y Heuver, (2011)
1. Mayor.Entrada.Neta	9. Posicion.EML.Porcentual
2. Mayor.Salida.Neta	10. Posicion.EML.Monto
3. Saldo.Inicial	11. Posicion.Neto.Mercados.Liquidez
4. Total.Pagos.Enviados	12. Monto.Neto.Transferencias.Clientes
5. Total.Pagos.Recibidos	13. Uso.Garantias.Sinpe
6. Obligaciones.Horas.Especificas	14. Saldo.Aportado.Garantias.Sinpe"
7. Hora.Promedio.Enviados	15. Monto.Custodia.SAC
8. Hora.Promedio.Recibidos	16. Porcentaje.Custodia.SAC

4.3.1.1 Colones

Para el análisis en colones se utilizaron los indicadores del 1 al 16 indicados en la Tabla 4.1. Dado que las variables contempladas para el análisis se miden en escalas con amplitudes o unidades diferentes, esto produce varianzas muy distintas entre ellas. Esto influye en la composición de los componentes principales extraídos dándole un mayor peso a aquellas variables con varianzas muy grandes. Por tanto, para evitar esta situación se realiza el ACP sobre variables estandarizadas, es decir restando su promedio y dividiéndolas por su desviación estándar, de forma tal que tengan promedio igual a 0 y varianza igual a 1.


En el Cuadro 4.7 se muestran los eigenvalores obtenidos luego de aplicar el ACP. Según estos resultados los primeros 5 componentes son los que tienen eigenvalores mayores a 1, y explican un 66% de la variabilidad contenida en los 16 indicadores considerados.

Cuadro 4.7. Resultados ACP de indicadores de hábitos de pago en colones: Eigenvalores

Componente	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada	Componente	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada
1	4,53	28,33	28,33	9	0,75	4,70	88,03
2	2,50	15,64	43,97	10	0,66	4,12	92,15
3	1,32	8,22	52,18	11	0,56	3,51	95,66
4	1,13	7,05	59,23	12	0,38	2,35	98,01
5	1,04	6,50	65,73	13	0,20	1,26	99,28
6	0,99	6,17	71,90	14	0,07	0,41	99,69
7	0,93	5,81	77,71	15	0,04	0,27	99,96
8	0,90	5,62	83,33	16	0,01	0,04	100,00

Fuente: Elaboración propia

En la Figura 4.18 se muestran las puntuaciones de los 2 primeros componentes principales, los cuales explican un 44% de la variabilidad de los datos. Adicionalmente se añadió el color correspondiente al código de entidad bancaria, destacando que, aun contemplando únicamente los 2 primeros componentes, en la mayoría de los casos estos permiten agrupar las observaciones correspondientes a cada entidad bancaria. En el Apéndice C se muestra un mayor detalle de los resultados.

Figura 4.18. Resultados ACP de indicadores de hábitos de pago en colones: Puntajes de los 2 primeros componentes principales (PC)

Fuente: Elaboración propia

4.3.1.2 Dólares

Para el análisis en dólares se utilizaron los indicadores del 1 al 12 indicados en la Tabla 4.1. El Cuadro 4.8 resume los eigenvalores obtenidos luego de aplicar el ACP a los indicadores de dólares. A dos decimales los primeros 5 componentes son los que tienen eigenvalores

iguales o mayores a 1, y explican un 60% de la variabilidad contenida en los 12 indicadores considerados.


Cuadro 4.8. Resultados ACP de indicadores de hábitos de pago en dólares: Eigenvalores

Componente	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada	Componente	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada
1	2,24	18,68	18,68	7	0,91	7,60	75,97
2	1,57	13,09	31,77	8	0,72	6,03	82,00
3	1,25	10,41	42,18	9	0,65	5,41	87,42
4	1,14	9,51	51,69	10	0,55	4,62	92,04
5	1,04	8,64	60,33	11	0,51	4,22	96,26
6	0,97	8,05	68,38	12	0,45	3,74	100,00

Fuente: Elaboración propia

En la Figura 4.19 se muestran las puntuaciones de los 2 primeros componentes principales para los indicadores en dólares, los cuales explican un 38% de la variabilidad de los datos. Es posible observar que, aunque existen traslapes entre los valores correspondientes a las entidades bancarias, también se logra apreciar que con estos 2 componentes se muestran agrupamientos correspondientes a observaciones de una misma entidad, lo que sugiere la necesidad de técnicas que consideren relaciones no lineales para hacer la segregación de las observaciones entre entidades.

Figura 4.19. Resultados ACP de indicadores de hábitos de pago en dólares: Puntajes de los 2 primeros componentes principales (PC)



Fuente: Elaboración propia

4.3.2 ACP INDICADORES DE REDES

Adicionalmente, para los indicadores construidos a partir del análisis de topología de redes se realizó un ACP para cada conjunto de indicadores correspondientes a cada red según se detalla en la Tabla 4.2 para un total de 10 indicadores en cada caso.

Tabla 4.2. Variables de análisis de redes incorporadas para el Análisis de Componentes Principales

Indicador	LBTR		MIL		Monex
	CRC	USD	CRC	USD	
1. Grado	x	x	x	x	x
2. Grado.entrada	x	x	x	x	x
3. Grado.salida.	x	x	x	x	x
4. Intensidad	x	x	x	x	x
5. Intensidad.entrada	x	x	x	x	x
6. Intensidad.salida	x	x	x	x	x
7. Centralidad.del.vector.propio	x	x	x	x	x
8. Centralidad.Autoridad.	x	x	x	x	x
9. Centralidad.Hub.	x	x	x	x	x
10. Centralidad.de.intermediación	x	x	x	x	x

Tal y como se muestra en el Cuadro 4.9 para cada una de las 5 redes construidas entre 2 y 3 componentes logran explicar al menos el 78% de la variabilidad de los 10 indicadores considerados. Para efectos de análisis se eligen aquellos componentes cuyo eigenvalor es mayor a la unidad.

Cuadro 4.9. Resultados ACP de redes: Eigenvalores

Componente	LBTR CRC			LBTR USD			MONEX		
	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada
1	7,44	74,44	74,44	7,19	71,86	71,86	4,13	41,30	41,30
2	1,19	11,93	86,37	1,21	12,15	84,01	2,91	29,11	70,41
3	0,69	6,94	93,31	0,67	6,66	90,66	1,02	10,20	80,61
4	0,33	3,30	96,61	0,50	4,99	95,65	0,86	8,55	89,16
5	0,17	1,71	98,31	0,17	1,69	97,34	0,43	4,29	93,45
6	0,09	0,92	99,23	0,13	1,34	98,68	0,36	3,57	97,02
7	0,07	0,69	99,92	0,11	1,15	99,83	0,16	1,56	98,57
8	0,01	0,08	100,00	0,02	0,17	100,00	0,14	1,43	100,00
9	0,00	0,00	100,00	0,00	0,00	100,00	0,00	0,00	100,00
10	0,00	0,00	100,00	0,00	0,00	100,00	0,00	0,00	100,00

Cuadro 4.9 (continuación)

Componente	MIL CRC			MIL USD		
	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada	Eigenvalor	Porcentaje de varianza	Porcentaje de varianza acumulada
1	3,91	39,14	39,14	4,16	41,60	41,60
2	2,74	27,41	66,55	2,78	27,78	69,38
3	1,17	11,66	78,21	1,16	11,60	80,98
4	0,85	8,48	86,69	0,63	6,33	87,30
5	0,65	6,46	93,15	0,59	5,89	93,20
6	0,39	3,93	97,08	0,35	3,48	96,68
7	0,20	2,03	99,10	0,22	2,18	98,86
8	0,09	0,90	100,00	0,11	1,14	100,00
9	0,00	0,00	100,00	0,00	0,00	100,00
10	0,00	0,00	100,00	0,00	0,00	100,00

Fuente: Elaboración propia

Al igual que en los casos anteriores, la Figura 4.20 muestra el poder discriminatorio entre entidades al contemplar los 2 primeros componentes principales para cada red construida. Puede observarse que si bien hay traslapes entre entidades también cada uno de los conjuntos de indicadores permite segregar al menos parcialmente los datos correspondientes a cada entidad bancaria.

Figura 4.20. Resultados ACP indicadores por red: Puntajes de los 2 primeros componentes principales (PC)

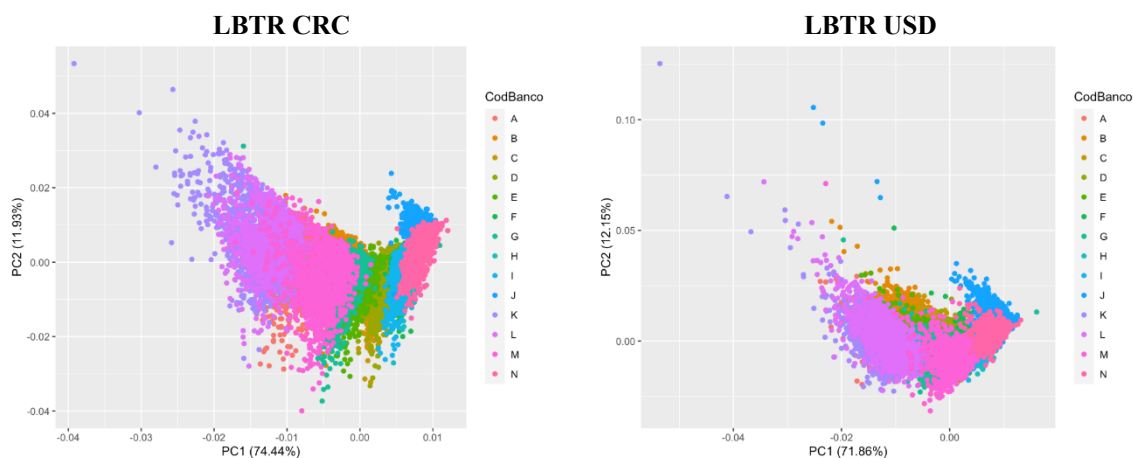
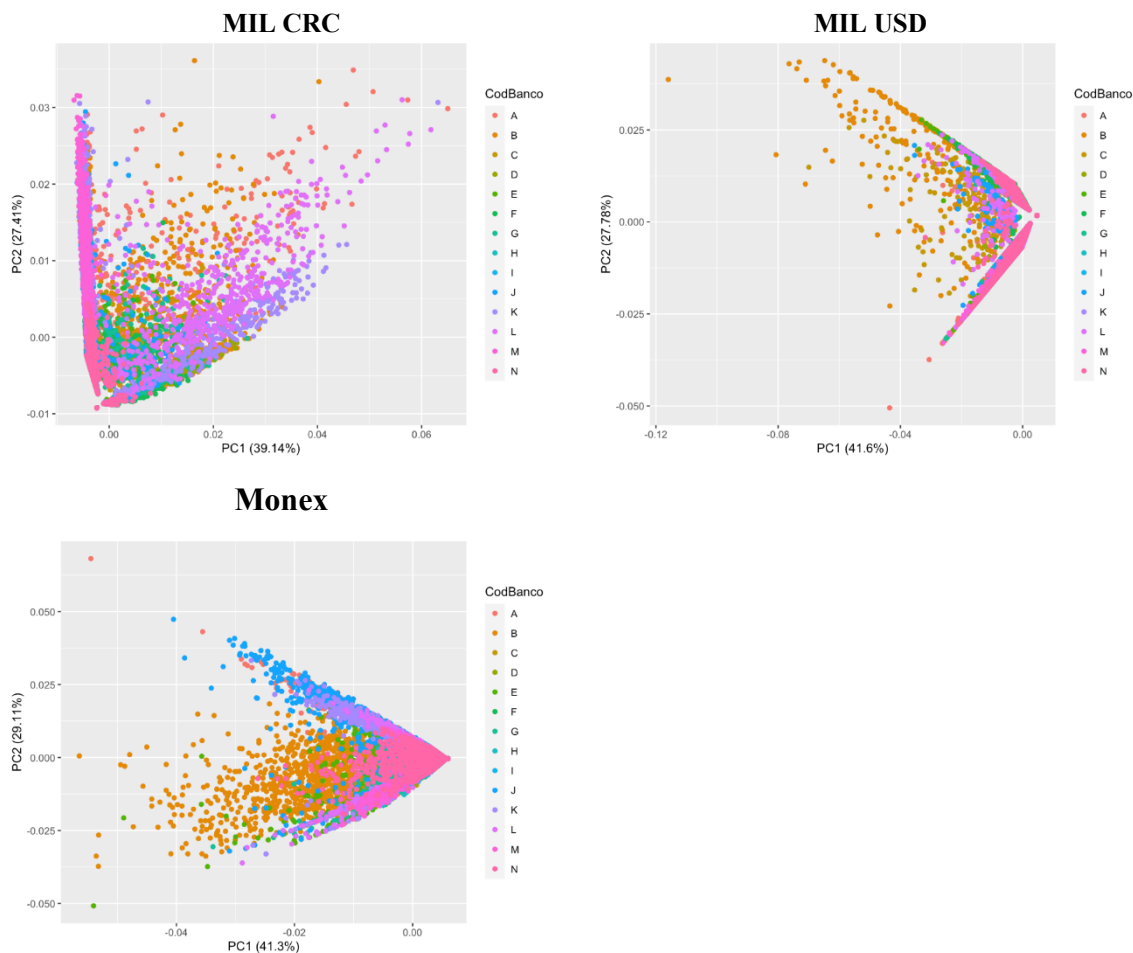


Figura 4.20 (continuación)



Fuente: Elaboración propia

4.4 RESULTADOS REDES NEURONALES ARTIFICIALES

Con el fin de reducir la dimensionalidad de los datos, el ejercicio de reconocimiento de patrones se realizó sobre los 23 componentes principales seleccionados según se indicó en la Tabla 4.1 y la Tabla 4.2. De tal forma que se logró una reducción de 78 variables a 23.

Asimismo, como los resultados de las redes neuronales artificiales dependen de los parámetros de inicialización (León et al, 2020), se ejecutaron 100 procesos de entrenamiento independientes para varias selecciones del número de neuronas en la capa oculta. Los resultados obtenidos no dependen sólo de los valores iniciales de los pesos, sino también de

la partición aleatoria del conjunto de datos de entrenamiento y de prueba para evitar el sobreajuste.

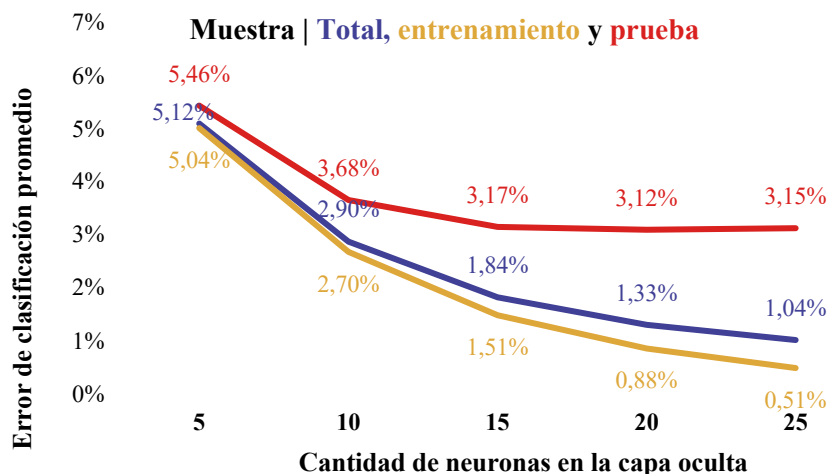
En el Cuadro 4.10 y Figura 4.21 se muestra el error medio de clasificación obtenido para cada conjunto de datos: muestra total, muestra de entrenamiento y muestra de prueba. El error medio de clasificación más bajo en el conjunto de prueba un 3,12%, se obtuvo con 20 neuronas en la capa oculta, esto es consistente con la recomendación de algunos autores de seleccionar una cantidad de neuronas que se ubique entre la cantidad de covariables (23 componentes principales en ese caso) y la cantidad de categorías de la variable a predecir (14 entidades bancarias).

Cuadro 4.10. Error medio de clasificación y desviación estándar para diferentes elecciones del número de neuronas en la capa oculta según conjunto de datos - calculado sobre 100 procesos de entrenamiento diferentes -

Conjunto de datos	Neuronas				
	5	10	15	20	25
Total	5,12±0,43	2,90±0,17	1,84±0,23	1,33±0,14	1,04±0,08
Entrenamiento	5,04±0,46	2,70±0,18	1,51±0,23	0,88±0,13	0,51±0,06
Prueba	5,46±0,52	3,68±0,35	3,17±0,38	3,12±0,35	3,15±0,33

Fuente: Elaboración propia


Figura 4.21. Error promedio de clasificación para diferentes elecciones del número de neuronas en la capa oculta según conjunto de datos - calculado sobre 100 procesos de entrenamiento diferentes -



Fuente: Elaboración propia

Adicionalmente, en la Figura 4.22 se muestra la distribución de los errores de clasificación obtenidos para cada una de las 100 iteraciones para los números de neuronas seleccionados. Para mostrar esta distribución se utilizaron gráficos de “cajas y bigotes”, en este tipo de figura la mediana está representada por la línea en el medio de la caja, los extremos de la caja se definen mediante el percentil 25 y 75 y los “bigotes” muestran el valor máximo y el mínimo observado, cuando hay valores extremos. Como era de esperar, para el número más bajo de neuronas el error de clasificación es mayor y más disperso. En los datos de prueba la mediana se estabiliza a partir de las 15 neuronas, no obstante, las simulaciones de 20 neuronas mostraron una menor dispersión respecto a las de 15 neuronas.

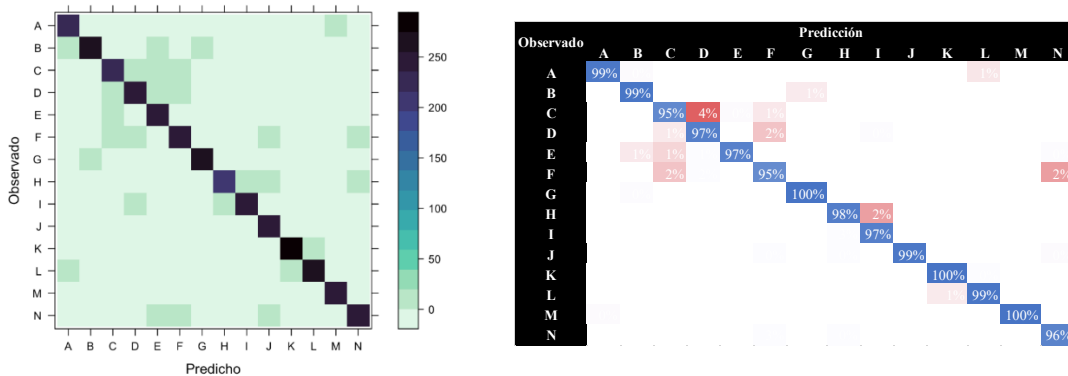
Figura 4.22. Distribución del error de clasificación para diferentes elecciones del número de neuronas en la capa oculta - calculado sobre 100 procesos de entrenamiento diferentes -



Fuente: Elaboración propia

Finalmente, en la Figura 4.23 se muestra la matriz de confusión correspondiente al error de clasificación más bajo obtenido en las simulaciones correspondientes a una red con una capa oculta y 20 neuronas. Como se espera de un buen clasificador, la mayoría de las predicciones coinciden con la clasificación objetivo en la diagonal de la matriz de confusión, mientras que unas pocas están fuera de la diagonal. La totalidad de las entidades muestran un porcentaje de acierto superior al 94%, demostrando que el modelo alcanza un buen grado de generalización para todos los bancos de la muestra.

Figura 4.23. Matriz de confusión y porcentaje de acierto en datos de prueba -el error de clasificación más bajo se consiguió en una ejecución con 20 neuronas-



Fuente: Elaboración propia

5 CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

- Como lo señala Schinasi (2004) un sistema financiero está en un rango de estabilidad cuando es capaz de facilitar el desempeño de una economía, y de disipar desequilibrios financieros que surgen en forma endógena o como resultado de serios eventos adversos no anticipados. Por tanto, la estabilidad financiera implica múltiples dimensiones que varían en importancia según las circunstancias y, por ende, requiere desarrollar metodologías que consideren el análisis conjunto de múltiples indicadores para obtener una perspectiva holística de la estabilidad del sistema financiero.
- Al estar basados en la interacción entre sus participantes, los sistemas de pagos conforman redes expuestas a diversos riesgos, siendo uno de los más importantes el riesgo sistémico. La incidencia que ello tiene sobre la estabilidad financiera y la transmisión de la política monetaria son algunas de las razones que explican el interés de los bancos centrales por promover los objetivos de seguridad y eficiencia en los sistemas de pagos.
- En línea con lo anterior, la aplicación de técnicas de aprendizaje automático basadas en datos a los sistemas de pagos representa una innovación significativa en los enfoques de supervisión y vigilancia del sistema financiero. La información generada por estos sistemas no solo presenta una frecuencia considerablemente mayor —diaria o incluso intradiaria— en comparación con fuentes tradicionales como los estados financieros o los reportes remitidos por las entidades a los supervisores, sino que, al estar generalmente administrados por los bancos centrales y sustentarse en registros transaccionales, esta información se considera objetiva y menos susceptible a manipulación por parte de las entidades supervisadas.
- Considerada como una plataforma de importancia sistémica, el SINPE en el 2022, movilizó un monto equivalente a 13,4 veces el valor del PIB, destacando los mercados de negociación que representaron el 66% del valor liquidado. Alrededor del 85% del valor de los pagos fue en colones, seguidos por dólares (15%). Además, las entidades

del Sistema Bancario Nacional en conjunto con el BCCR realizaron un 80% de los pagos del 2022.

- En cuanto a los indicadores de hábitos de pagos, se encontraron diferencias entre entidades bancarias tanto en magnitud, como en tendencia. Además, se identificaron correlaciones relevantes entre múltiples variables, lo cual justifica la aplicación de técnicas de reducción de dimensionalidad como el Análisis en Componentes Principales (ACP), permitiendo sintetizar la información sin una pérdida sustancial de varianza explicativa. El monitoreo continuo de estos indicadores constituye una herramienta eficaz para la supervisión del riesgo de liquidez, con la ventaja de operar sobre datos de alta frecuencia y, por ende, con un rezago mínimo en la detección de cambios de tendencia.
- La Topología de Redes (TR) es una metodología propia de la física estadística que tiene por objeto entender y analizar la estructura y funcionamiento de sistemas representados mediante redes. Aplicada al sistema financiero costarricense, permitió caracterizar a la red de pagos de liquidación bruta en tiempo real (LBTR) y la red Monex como redes de tamaño medio (entre 100 y 1.000 participantes); mientras que la red correspondiente al Mercado Integrado de Liquidez (MIL) es considerada una red pequeña (menos de 100 nodos). Las métricas de densidad y grado promedio revelan diferencias estructurales entre las redes analizadas. En términos de centralidad, las entidades bancarias ocupan una posición dominante, seguidas por cooperativas y mutuales, lo que permite inferir su relevancia sistémica dentro de las redes analizadas.
- La versatilidad de la TR la convierte en una herramienta de alto valor para la autoridad monetaria, los entes supervisores y las propias entidades financieras, dada su capacidad para fortalecer los procesos de monitoreo y gestión de riesgos. Entre sus principales aplicaciones destacan:
 - Análisis de la transmisión de la política monetaria: la TR permite analizar en detalle las interacciones entre los participantes de los mercados de dinero. Esta

metodología no solo posibilita la identificación de los agentes más centrales dentro de la red —a través de métricas como la centralidad de grado o intermediación—, sino también de aquellos cuya función es estructuralmente crítica, es decir, que no pueden ser fácilmente reemplazados sin afectar la conectividad o eficiencia del sistema (León, Machado, & Sarmiento, 2014). Esta capacidad analítica resulta especialmente útil para comprender los canales de transmisión de la política monetaria y su grado de difusión dentro del sistema financiero.

- Evaluación de la estabilidad financiera: a través del análisis de las posiciones activas y pasivas entre entidades financieras y otros sectores económicos, esta metodología permite identificar canales potenciales de contagio y diseñar pruebas de tensión más robustas, fortaleciendo así las herramientas macroprudenciales (Espinosa-Vega, 2014).
- Vigilancia del sistema de pagos: en su rol de vigilante del sistema de pagos, el Banco Central puede emplear modelos de red para identificar participantes críticos dentro del SINPE. A través del análisis de métricas de centralidad es posible evaluar el impacto potencial que tendría la desconexión o el fallo de un nodo relevante sobre la continuidad operativa del sistema (Cepeda, 2018) y (Machado, et al., 2010). Esta evaluación resulta fundamental no solo para la gestión del riesgo sistémico, sino también para el fortalecimiento de la resiliencia operativa ante amenazas cibernéticas y fallos técnicos.
- Supervisión prudencial y alerta temprana de riesgos: el monitoreo de cambios en la posición o comportamiento de los participantes en las redes de pagos o negociación puede generar alertas tempranas ante posibles riesgos de solvencia o liquidez. Como lo señalan algunos estudios, las entidades financieras no suelen volverse insolventes de forma repentina, sino que muestran previamente patrones de comportamiento anómalos (Heijmans & Heuver, 2011).

- Prevención de riesgos operativos y reputacionales: esta metodología también puede utilizarse dentro de los procesos de Conozca a su cliente (KYC), con el fin de identificar relaciones atípicas, patrones de comportamiento sospechosos o transacciones inusuales, contribuyendo así a la prevención del lavado de activos.
- Las redes neuronales artificiales (RNA) son modelos matemáticos y computacionales inspirados en sistemas biológicos, adaptados y simulados en computadoras; han surgido como un intento de desarrollar modelos que emulen las características del cerebro humano. Las RNA se encuentran dentro de las técnicas de aprendizaje supervisado, es decir, tienen como meta aprender del patrón de comportamiento de los datos a partir de ellos mismos.
- En este trabajo se construyó una parametrización de una red neuronal artificial que representa los patrones de pago en el SINPE de las entidades que conforman el Sistema Bancario Nacional. El tipo de características utilizadas fueron indicadores de concentración de los pagos, manejo de la liquidez, saldos de custodia de deuda anotada en cuenta, así como la centralidad de la red de servicios de LBTR en ambas monedas y negociaciones en los mercados MIL y Monex.
- Luego de seleccionado el conjunto de indicadores, el análisis en componentes principales permitió reducir el conjunto de 78 variables a 23 componentes. Utilizando 100 procesos de entrenamiento y prueba, la robustez del modelo construido se alcanzó después de 15 neuronas. El modelo de RNA con una capa oculta y 20 neuronas, alcanzó el error más bajo de clasificación (3,12%) en la muestra de prueba. La matriz de confusión mostró un alto porcentaje de acierto (superior al 94%) para todas las entidades bancarias, indicando que el modelo es generalizable a datos fuera de la muestra de entrenamiento.

- Para la implementación de esta metodología como sistema de alerta temprana, una vez que la red ha sido entrenada y se han establecido sus métricas de desempeño (por ejemplo, porcentaje de acierto), es posible evaluar su efectividad ante nuevas observaciones. Si, tras introducir nuevos datos, se observa una disminución significativa en el desempeño del modelo para una entidad en particular, tal variación puede indicar una desviación respecto a su perfil histórico, lo que justifica su monitoreo más detallado por parte del supervisor.

- La metodología de redes neuronales ofrece una nueva perspectiva para la supervisión de sistemas financieros, especialmente en la detección de comportamientos no deseados. Particularmente, se han aplicado con éxito en diversas áreas como las siguientes:
 - Análisis macroeconómico y predicción de crisis: Las redes neuronales han sido utilizadas para construir modelos de alerta temprana, que permiten anticipar eventos de crisis financiera a partir de variables como la cuenta corriente respecto al PIB, el crecimiento económico, la inflación, los niveles de deuda pública y los precios de activos (acciones e inmuebles) (Holopainen & Sarlin, 2016). Estas herramientas permiten identificar patrones no lineales complejos que pueden pasar desapercibidos mediante métodos econométricos tradicionales.

 - Reconocimiento de patrones de instituciones financieras: El modelo presentado puede extenderse al análisis de balances contables de las entidades financieras (León, Moreno, & Cely, 2017), los cuales se encuentran disponibles públicamente a través de plataformas automatizadas vía API. Esto permite construir sistemas de monitoreo continuo que podrían ser aprovechados tanto por los entes supervisores como por las propias entidades financieras para sus procesos internos de gestión de riesgos y calificación de emisores.

- Detección de anomalías en sistemas de pago: La aplicación de técnicas de aprendizaje no supervisado sobre los datos transaccionales del SINPE puede permitir la identificación en tiempo real de comportamientos atípicos o señales tempranas de tensión financiera, como posibles ‘corridas bancarias electrónicas’ o ataques cibernéticos en entidades específicas (Trieplets, Daniels, & Heijmans, 2017) y (Sabetti & Heijmans, 2019).

5.2 RECOMENDACIONES

- Algunos autores señalan la importancia de este tipo de modelos como herramienta de control para la detección de anomalías, particularmente, un cambio considerable en la capacidad del modelo para clasificar una institución financiera es una señal de un cambio en su comportamiento dentro del sistema de pagos. No obstante, la evaluación del modelo propuesto como sistema de alerta temprana va más allá del alcance de la presente investigación.
- La implementación de esta metodología en forma periódica puede venir a complementar la labor de seguimiento que se realiza hoy en día a las entidades bancarias, por lo que es aconsejable la valoración por parte del área encargada en el Banco Central. Debido a que la fuente primaria de información es el SINPE, el cálculo periódico de los indicadores y el ajuste de la RNA se puede realizar utilizando consultas al lago de datos institucional y los cálculos subsiguientes mediante el software estadístico R, así como el establecimiento de un esquema periódico de validación y recalibración del modelo para evitar el deterioro de su desempeño predictivo. Este proceso incluso puede ser ejecutado en forma automática mediante el “Programador de Tareas” del Windows.
- Dado que el SINPE ha sido reconocido internacionalmente como una infraestructura de pagos de alto nivel —por su cobertura, capacidad de liquidación en tiempo real y trazabilidad transaccional— se recomienda fortalecer su aprovechamiento como fuente de información en el ámbito de la supervisión financiera. En particular, se

sugiere desarrollar herramientas adicionales de monitoreo automatizado y análisis de datos en tiempo real como paneles de indicadores que permitan, por un lado, robustecer la supervisión regular del sistema de pagos y, por otro, contribuir a la evaluación dinámica de la estabilidad financiera a través de pruebas de tensión, redes de interconexión entre participantes y detección temprana de anomalías operativas o cambio de patrones.

- Dadas las vulnerabilidades mostradas por entidades no bancarias durante el 2024, una tarea pendiente es la ampliación de la aplicación de esta metodología a todas las entidades que conforman el sistema financiero nacional y que son participantes del SINPE. Esto además permitiría una primera aproximación a la valoración de la metodología como sistema de alerta temprana.

En conjunto, las conclusiones y recomendaciones de este trabajo resaltan el potencial que ofrece la integración de metodologías cuantitativas como la topología de redes y el aprendizaje automático específicamente el análisis de redes neuronales, en los procesos de supervisión financiera. Su implementación práctica no solo fortalece la vigilancia operativa del sistema de pagos, sino que abre nuevas posibilidades para la gestión proactiva del riesgo sistémico en el contexto costarricense y nuevos trabajos de investigación.

REFERENCIAS BIBLIOGRÁFICAS

- AI Assurance. (2023). *Scree Plot*. Retrieved from ScienceDirect: <https://www.sciencedirect.com/topics/mathematics/scree-plot>
- Aydin, N., Sahin, N., Deveci, M., & Pamucar, D. (2022, diciembre 15). Prediction of financial distress of companies with artificial neural networks and decision trees models. *Machine Learning with Applications, Volume 10*. doi:<https://doi.org/10.1016/j.mlwa.2022.100432>
- Baek, S., Soramäki, K., & Jaeho, Y. (2014, febrero 25). Network Indicators for Monitoring Intraday Liquidity in BOK-Wire+. *Working Papers Economic Research Institute, Bank of Korea*(2014-1). doi:<http://dx.doi.org/10.2139/ssrn.2580597>
- Banco Central de Costa Rica. (2019, septiembre 05 y 06). Aplicaciones del análisis de redes en la evaluación de la estabilidad financiera. *Presentación realizada en IX Reunión de Estabilidad Financiera. Organizada por Centro de Estudios Monetarios Latinoamericanos (CEMLA). Montevideo, Uruguay.*
- Banco Central de Costa Rica. (2023). *Memoria anual 2022*. Retrieved from https://www.bccr.fi.cr/publicaciones/DocMemoriaAnual/Memoria_Anual_2022.pdf
- Banco Central de Costa Rica. (n.d.). *Sistema de pagos: Información General*. Retrieved julio 03, 2023, from Banco Central de Costa Rica: <https://www.bccr.fi.cr/sistema-de-pagos/informaci%C3%B3n-general>
- Banco Central Europeo. (24 de mayo de 2017). *Guía rápida sobre políticas macroprudenciales*. Recuperado el 02 de mayo de 2023, de Banco Central Europeo: <https://www.ecb.europa.eu/ecb/educational/explainers/tell-me-more/html/macprudentialpolicies.es.html>
- Bank of Finland. (2023). *Financial System*. Recuperado el 30 de agosto de 2023, de Bank of Finland: <https://www.suomenpankki.fi/en/financial-stability/the-financial-system-in-brief/>
- Basel Committee on Banking Supervision. (2013, abril 11). *Monitoring indicators for intraday liquidity management*. Retrieved from Bank for International Settlements: <https://www.bis.org/publ/bcbs248.htm>

- BBC. (2022, octubre 10). *Premio Nobel de Economía 2022: Ben S. Bernanke, Douglas W. Diamond y Philip H. Dybvig son los ganadores*. Retrieved from BBC News Mundo: <https://www.bbc.com/mundo/noticias-63200325>
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Clarendon Press.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Cepeda, F. (2018). La topología de redes como herramienta de seguimiento en el sistema de pagos de alto valor en Colombia. *Borradores de Economía Banco de la República*(No. 513). Retrieved from <https://www.banrep.gov.co/es/topologia-redes-herramienta-seguimiento-el-sistema-pagos-alto-valor-colombia>
- Cerdas, A. M., & Melegatti, C. (2014). *El sistema financiero costarricense en los últimos 25 años: sistema de pagos*. Retrieved agosto 30, 2023, from Academia de Centroamérica: <https://www.academiaca.or.cr/otras-publicaciones/sistema-de-pagos/>
- Comité de Sistemas de Pago y Liquidación (CPSS-BIS). (2003, marzo). *Glosario de términos utilizados en los sistemas de pago y liquidación*. Retrieved from Banco de Pagos Internacionales: https://www.bis.org/cpmi/publ/d00b_es.pdf
- Escuela de Arquitectura y Diseño, Pontificia Universidad Católica de Valparaíso. (2024, 07 15). *Chernoff Faces*. Retrieved from Casiopea de Escuela de Arquitectura y Diseño, PUCV: https://wiki.ead.pucv.cl/Chernoff_Faces
- Espinosa-Vega, M. A. (2014, diciembre 23). Introduction to the Network Analysis Approach to Stress Testing. (L. L. Ong, Ed.) *A Guide to IMF Stress Testing: Methods and Models*. doi:10.5089/9781484368589.071
- European Central Bank. (2005). *Assessing financial stability: conceptual boundaries and challenges*. ECB Financial Stability Review, Frankfurt. Recuperado el 30 de agosto de 2023, de https://www.ecb.europa.eu/pub/financial-stability/fsr/html/all_releases.en.html
- Fondo Monetario Internacional. (s.f.). *Solidez del Sistema Financiero*. Recuperado el 02 de mayo de 2023, de Fondo Monetario Internacional: <https://www.imf.org/es/About/Factsheets/Financial-System-Soundness>
- Freixas, X., Laeven, L., & Peydró, J. L. (2015). *Systemic Risk, Crises, and Macroprudential Regulation*. The MIT Press. Retrieved from <https://www.jstor.org/stable/j.ctt17kk82g>

- González, L. (2018, noviembre 16). *Sobreajuste y Subajuste en Machine Learning*. Retrieved junio 29, 2023, from Apreande IA: <https://aprendeia.com/sobreajuste-y-subajuste-en-machine-learning/>
- Günther, F., & Fritsch, S. (2010, junio). neuralnet: Training of Neural Networks. *The R Journal*, Vol. 2/1, p.p. 30-38. Retrieved from <https://journal.r-project.org/archive/2010/RJ-2010-006/RJ-2010-006.pdf>
- Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (2014). *Neural Network Design* (2nd ed.). Oklahoma State University. Retrieved from <https://hagan.okstate.edu/NNDesign.pdf>
- Heijmans, R., & Heuver, R. (agosto de 2011). Is this Bank Ill? The Diagnosis of Doctor TARGET2. *De Nederlandsche Bank Working Paper*(No. 316). doi:10.2139/ssrn.1945139
- Holopainen, M., & Sarlin, P. (2016, mayo). Toward Robust Early-Warning Models: A Horse Race, Ensembles and Model Uncertainty. *ECB Working Paper*(No 1900). Retrieved from <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1900.en.pdf>
- Johnson, D. E. (2000). *Métodos multivariados aplicados al análisis de datos*. International Thomson Editores.
- Leinonen, H., & Soramäki, K. (2003, octubre 01). Simulating Interbank Payments and Securities Settlement Mechanism with the Bof-Pss2 Simulator. *Bank of Finland Research Discussion Paper*(No. 23). Retrieved from https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3016759
- León, C. (2017, junio 19 al 24). Introducción al análisis de redes. *Misión de Asistencia Técnica | CAPTAC-RD San José Costa Rica*.
- León, C., Machado, C. L.a., & Sarmiento, M. (2014). Identifying central bank liquidity super-spreaders in interbank funds networks. *Borradores de Economía Banco de la República*.(No. 816). Retrieved from <https://www.banrep.gov.co/en/borrador-816>
- León, C., Moreno, J. F., & Cely, J. (2017, febrero). Whose Balance Sheet is this? Neural Networks for Banks' Pattern Recognition. *CentER Discussion Paper Series*(No. 2017-009). doi:<http://dx.doi.org/10.2139/ssrn.2922516>
- León, C., Paolo, B., Acero, O., & Gage, G. &. (2020). Pattern recognition of financial institutions' payment behavior. *Latin American Journal of Central Banking*.

- Machado, C., León, C., Sarmiento, M., Cepeda, F., Orlando, C., & Cely, J. (2010). Riesgo sistémico y estabilidad del sistema de pagos de alto valor en Colombia: análisis bajo topología de redes y simulación de pagos. *Borradores de Economía Banco de la República Colombia*(No. 627).
- Maloo, J. (2018, junio 21). *Machine Learning For Beginners From Zero Level*. Retrieved junio 13, 2023, from Medium: <https://medium.com/@maloojinesh/machine-learning-for-beginners-from-zero-level-8be5b89bf77c>
- Menacho, C. (2014, diciembre 30). Modelos de regresión lineal con redes neuronales. *Anales Científicos*, 75 (2). doi:<https://doi.org/10.21704/ac.v75i2.961>
- Mishkin, F. (2016). *The Economics of Money, Banking and Financial Markets* (11th ed.). Columbia University: Pearson.
- Ortiz-Cevallos, L. (2020, septiembre). Propuesta de un indicador de riesgo sistémico para el triángulo norte de Centroamérica. *Documento de Trabajo Secretaría Ejecutiva del Consejo Monetario Centroamericano*(No 3). Retrieved from <https://www.secmca.org/wp-content/uploads/2020/09/PROPUESTA-DE-UN-INDICADOR-DE-RIESGO-SIST%3%89MICO-PARA-EL-TRI%3%89INGULO-NORTE-DE-CENTROAM%3%89RICA.pdf>
- Ponce, J., & Tubio, M. (2010). Estabilidad financiera: conceptos básicos. *Documentos de trabajo 2010004*, Banco Central del Uruguay. .
- Sabetti, L., & Heijmans, R. (2019, abril). Shallow or deep? Detecting anomalous flows in the Canadian Automated Clearing and Settlement System using an autoencoder. *De Nederlandsche Bank Working Paper*(No. 681). doi:<http://dx.doi.org/10.2139/ssrn.3581595>
- Schinasi, G. J. (2004, octubre 01). Defining financial stability. *IMF Working Papers, Volume 2004*(Issue 187). doi:<https://doi.org/10.5089/9781451859546.001>
- Triepels, R., Daniels, H., & Heijmans, R. (2017). Anomaly Detection in Real-Time Gross Settlement Systems. (SciTePress, Ed.) *Proceedings of the 19th International Conference on Enterprise Information Systems (ICEIS 2017)*, 1, 433-441. doi:10.5220/0006333004330441
- Urdinez, F., & Andrés, y. L.n. (2021). *AnalizaR Datos Políticos*. CRC Press. Retrieved from <https://arcruz0.github.io/libroadp/>

Yong Hu, J. S. (2022). Research on Credit Risk Evaluation of Commercial Banks Based on Artificial Neural Network Model. *Procedia Computer Science*, 199, 1168-1176. doi:<https://doi.org/10.1016/j.procs.2022.01.148>.

APÉNDICES

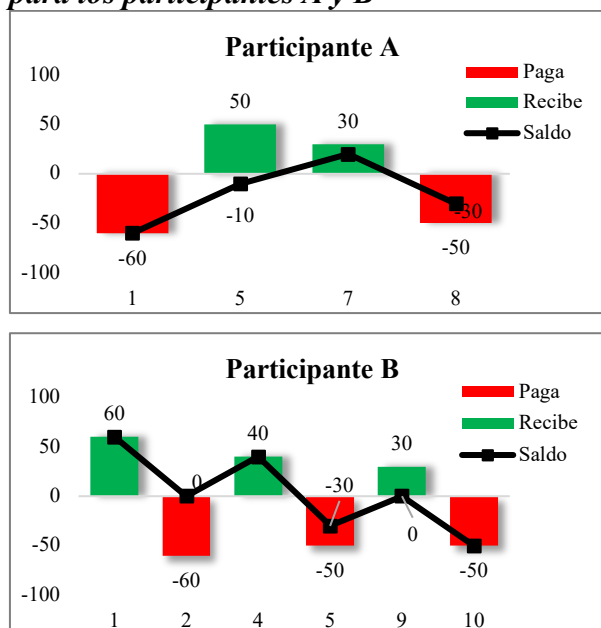
APÉNDICE A. EJEMPLOS DE TIPOS DE LIQUIDACIÓN

En el Cuadro A.1. y la Figura A.1. se muestra un ejemplo hipotético de 10 órdenes de pago entre 4 participantes (A, B, C y D) cuya liquidación se realiza en forma individual o bruta. Se llama Liquidación Bruta en Tiempo Real (LBTR o RTGS por sus siglas en inglés) a la liquidación continua (en tiempo real) de transferencias de fondos o de valores de forma individual, es decir, de una en una, sin neteo (CPSS-BIS, 2003).

Cuadro A.1. Ejemplo 1 de órdenes de pago

Nº	Entidad Origen	Entidad Destino	Monto
1	A	B	60
2	B	C	60
3	C	D	10
4	D	B	40
5	B	A	50
6	D	C	60
7	D	A	30
8	A	C	50
9	C	B	30
10	B	D	50

Figura A.1. Flujos de pago y saldo acumulado para los participantes A y B



Fuente: Elaboración propia

En el Cuadro A.2 se vuelven a presentar las órdenes de pago mostradas previamente, pero esta vez se representan en forma de un cuadro de doble vía. Asimismo, se muestran 2 ejemplos de cómo opera un sistema de compensación bilateral frente a uno de compensación multilateral.

Cuadro A.2. Ejemplo 2 de órdenes de pago Resultado del neteo

Origen	Destino				Total
	A	B	C	D	
A		60	50		110
B	50		60	50	160
C		30		10	40
D	30	40	60		130
Total	80	130	170	60	440

Bilateral A, B

A paga a B: 60 y B paga a A: 50

⇒ A paga 10 a B

Multilateral A

A: Paga 110 y Recibe 80.

Neteo: $110 - 80 = A$ paga 30

Fuente: Elaboración propia

APÉNDICE B. RESUMEN DE LAS PRINCIPALES CARACTERÍSTICAS DE LAS REDES CONSTRUIDAS EN ALGUNOS ESTUDIOS QUE UTILIZAN INFORMACIÓN DE SISTEMAS DE PAGO

Referencia	Información utilizada	Algoritmo	Capas ocultas	Numero de neuronas
Triepels et al (2017)	Alrededor de dos millones de pagos de clientes que se liquidaron entre enero y octubre de 2014 entre los veinte bancos holandeses más grandes agregados en 8.561 intervalos de tiempo de 15 minutos cada uno	Red neuronal prealimentada (<i>feed-forward</i> en inglés)	Dos capas: una capa oculta y una de salida	160
León et al (2016)	Datos del balance mensual de 25 cuentas de los bancos colombianos de 2000 a 2014	Red neuronal propagación hacia atrás (<i>backpropagation</i>)	Dos capas: una capa oculta y una de salida	15
León et al (2020)	113 características que corresponden a su contribución a los pagos, hábitos de fondeo, momento de pagos, concentración de pagos, centralidad en la red de pagos, e impacto sistémico debido a la imposibilidad de pagar.	Red neuronal prealimentada (<i>feed-forward</i> en inglés)	Dos capas: una capa oculta y una de salida	70
Sabetti y Heijman (2020)	Valor bruto bilateral entre 11 participantes del sistema de pagos canadiense (110 variables cada uno de los 11 participantes interactúa con los otros 10)	Red neuronal propagación hacia atrás (<i>backpropagation</i>)	Una capa oculta	40

**APÉNDICE C. RESULTADOS GRÁFICOS DEL ANÁLISIS DE
CONGLOMERADOS DE K MEDIAS UTILIZANDO COMO VARIABLES LOS
ESTADÍSTICOS DESCRIPTIVOS DE LAS SERIES DE LOS INDICADORES DE
HÁBITOS DE PAGO**

Figura C.1 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'mayor salida neta' por moneda

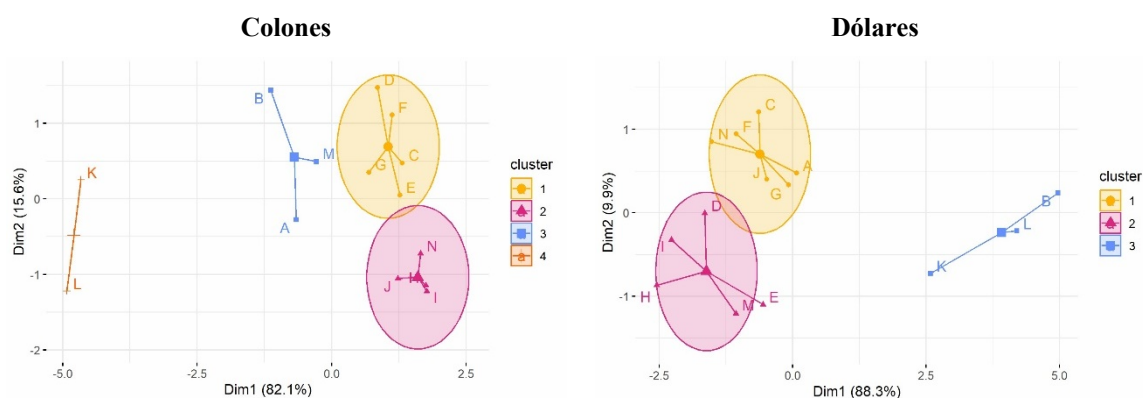


Figura C.2 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'mayor entrada neta' por moneda




Figura C.3 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'saldo inicial' por moneda

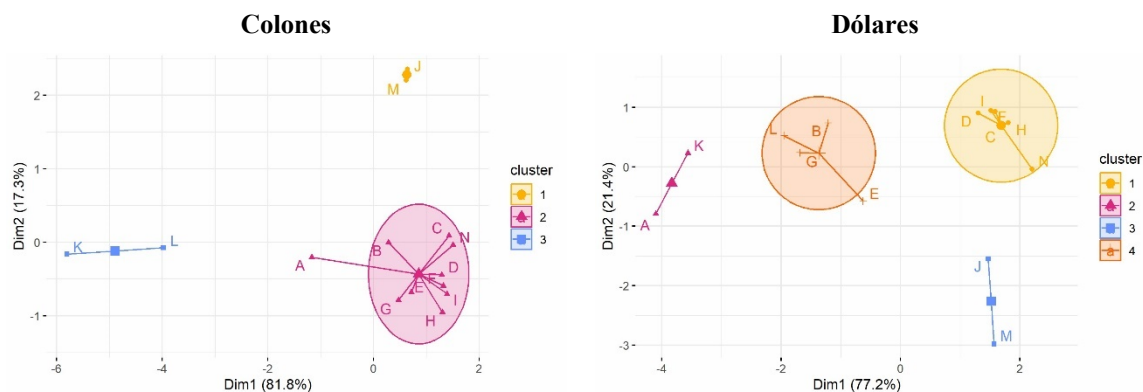


Figura C.4 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'pagos enviados' y 'pagos recibidos' por moneda

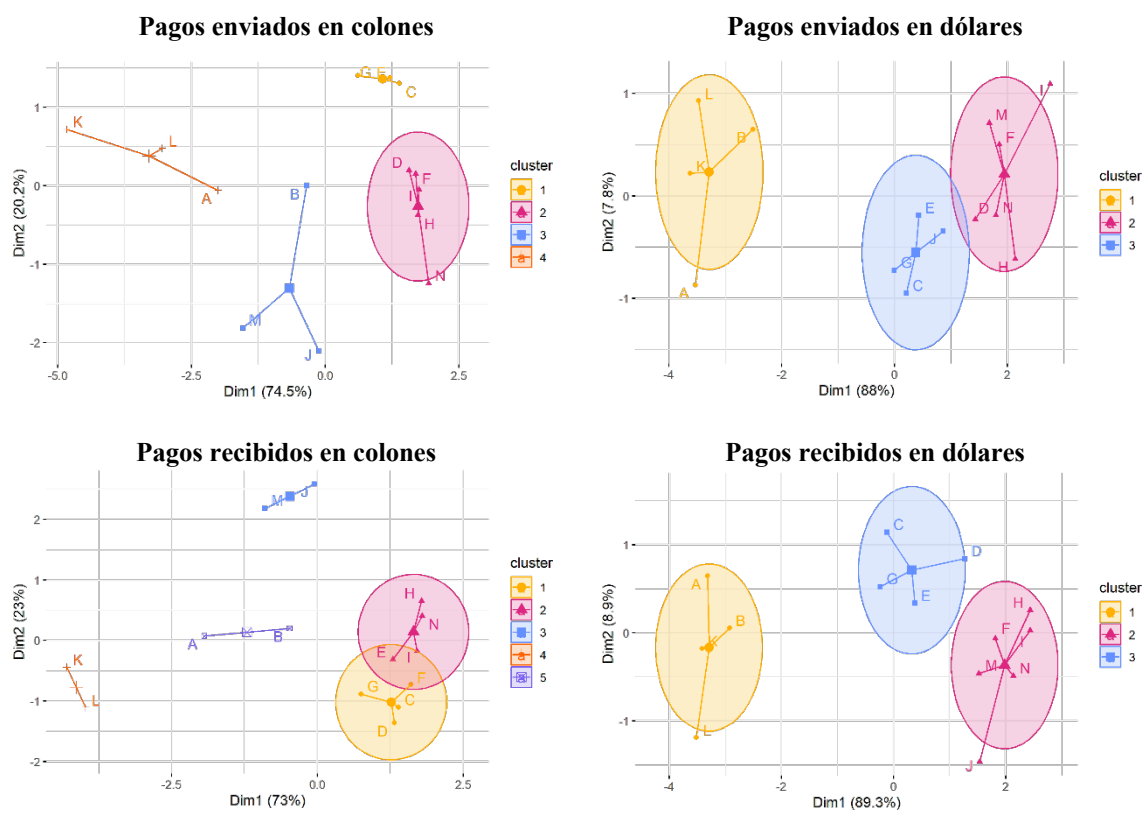


Figura C.5 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'obligaciones a horas específicas' por moneda

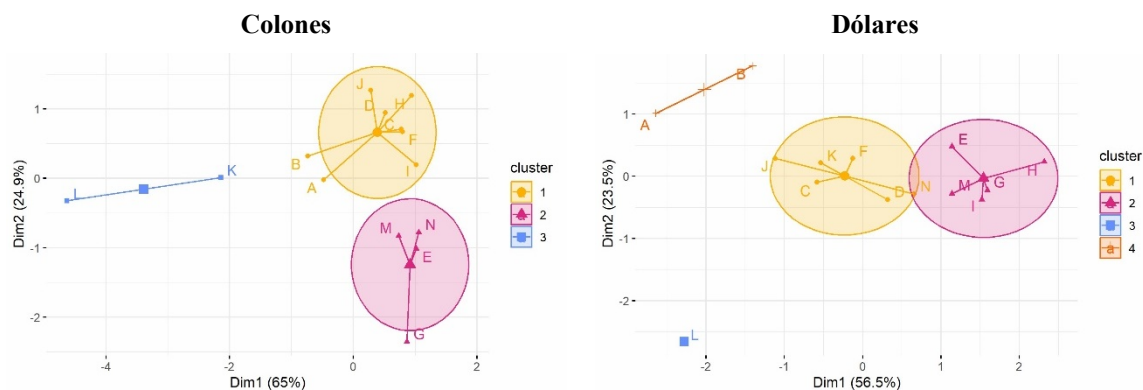


Figura C.6 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'hora promedio de pagos enviados' y 'hora promedio de pagos recibidos' por moneda

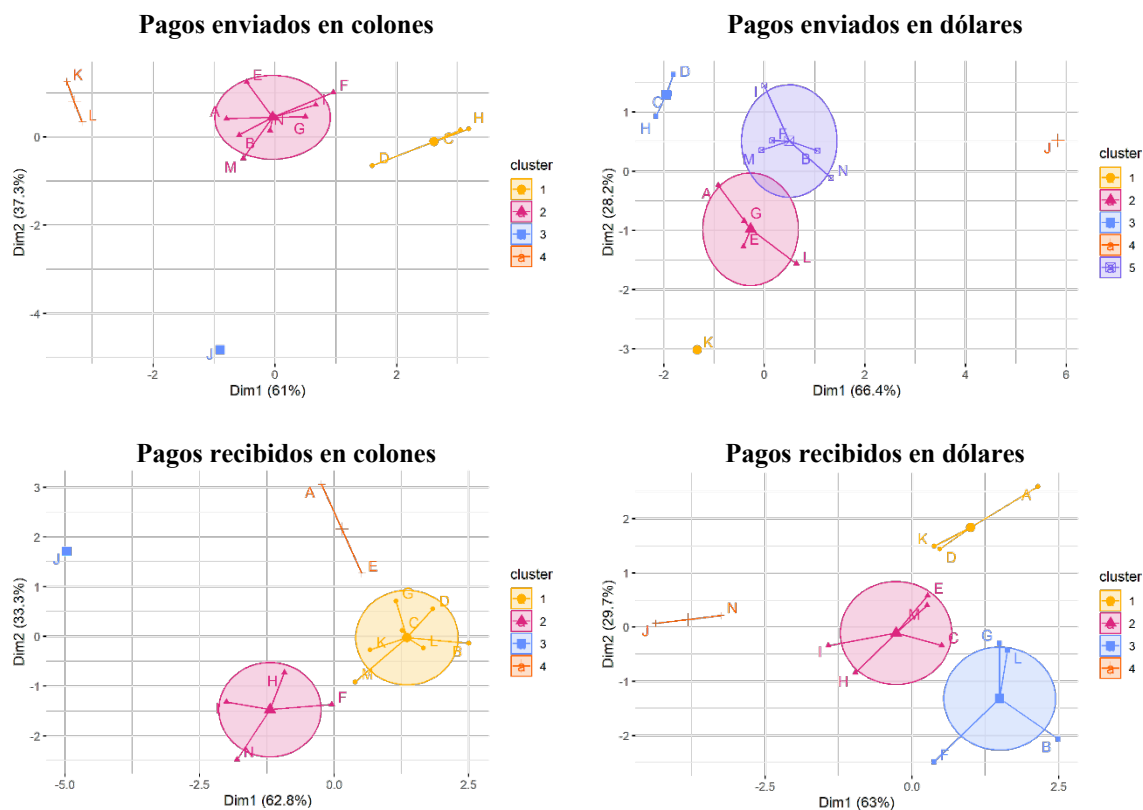
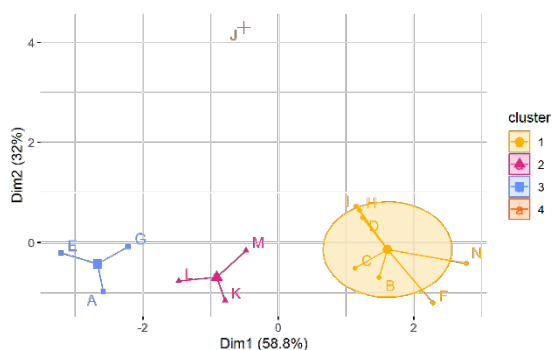



Figura C.7 Resultados del análisis de conglomerados de k medias de los estadísticos descriptivos de la serie 'monto enviado acumulado' por moneda y hora


Monto enviado acumulado en colones a las 7:00



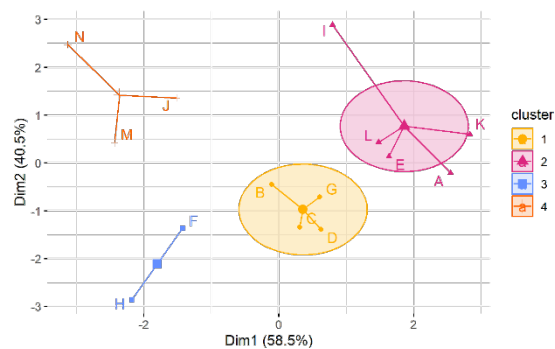
Monto enviado acumulado en dólares a las 7:00




Monto enviado acumulado en colones a las 12:00




Monto enviado acumulado en dólares a las 12:00



Monto enviado acumulado en colones a las 18:00



Monto enviado acumulado en dólares a las 18:00




APÉNDICE D. RESULTADOS DEL ANÁLISIS EN COMPONENTES PRINCIPALES (ACP)

ACP indicadores de hábitos de pago en colones

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10	Dim.11
Variance	4.532	2.502	1.315	1.128	1.040	0.987	0.930	0.898	0.752	0.659	0.562
% of var.	28.327	15.639	8.219	7.048	6.501	6.168	5.811	5.615	4.703	4.116	3.510
Cumulative % of var.	28.327	43.966	52.185	59.233	65.734	71.902	77.713	83.329	88.031	92.148	95.658
	Dim.12	Dim.13	Dim.14	Dim.15	Dim.16						
Variance	0.377	0.202	0.066	0.043	0.007						
% of var.	2.354	1.263	0.412	0.271	0.041						
Cumulative % of var.	98.013	99.275	99.688	99.959	100.000						



correlations variables - dimensions


	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Mayor.Entrada.Neta.CRC	0.38254632	0.80385196	0.046161173	0.04399791	-0.012205619
Mayor.Salida.Neta.CRC	-0.69223885	0.34800157	-0.171123009	0.25517424	0.099979567
Saldo.Inicial.CRC	0.96120625	-0.07768327	-0.088868371	0.01703295	0.023258519
Total.Pagos.Enviados.CRC	0.30790044	0.23260863	0.675989315	0.22957972	0.156777627
Total.Pagos.Recibidos.CRC	0.29200074	0.21216516	0.084652189	-0.03246682	-0.572780313
Obligaciones.Horas.Especificas.CRC	0.17639576	-0.10431315	0.788404173	0.05004917	0.013195267
Hora.Promedio.Enviados.CRC	-0.21028583	-0.01141706	0.094002196	0.43277081	0.309701831
Hora.Promedio.Recibidos.CRC	0.06538065	-0.18658468	-0.002014313	-0.13639475	0.680726892
Posicion.EML.Porc.CRC	-0.02488673	0.25771927	0.075743070	-0.67380685	0.238916606
Posicion.EML.Absoluta.CRC	-0.05162434	0.60604042	0.151683846	-0.46613266	-0.001206742
Posicion.Mercados.Liquidez.CRC	0.19811240	0.90410450	-0.084511597	0.14838489	0.059922244
Neto.Transferencias.Clientes.CRC	-0.27384728	0.13875947	0.136872347	0.21089473	-0.098760224
Uso.Garantias.Sinpe	-0.08819698	-0.53053194	0.294165341	-0.22974111	-0.188495937
Saldo.Aportado.Garantias.Sinpe	0.88412474	-0.16141018	-0.065844693	0.05160293	-0.004741679
Monto.Custodia	0.95280754	-0.05071564	-0.135086757	0.05062887	0.074748180
Porcentaje.Custodia	0.95306411	-0.05927450	-0.132113251	0.04902439	0.075660050

contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Mayor. Entrada. Neta. CRC	3.22887214	25.824081080	1.620356e-01	0.17166051	1.432317e-02
Mayor. Salida. Neta. CRC	10.57291453	4.839886000	2.226761e+00	5.77404229	9.610415e-01
Saldo. Inicial. CRC	20.38524595	0.241172442	6.005528e-01	0.02572681	5.200963e-02
Total. Pagos. Enviados. CRC	2.09171927	2.162341871	3.474853e+01	4.67383451	2.363131e+00
Total. Pagos. Recibidos. CRC	1.88126813	1.798957334	5.449205e-01	0.09347289	3.154248e+01
Obligaciones. Horas. Especificas. CRC	0.68652931	0.434861385	4.726662e+01	0.22212638	1.674002e-02
Hora. Promedio. Enviados. CRC	0.97566970	0.005209321	6.719435e-01	16.60818708	9.221619e+00
Hora. Promedio. Recibidos. CRC	0.09431512	1.391312456	3.085393e-04	1.64968730	4.455182e+01
Posicion. EML. Porc. CRC	0.01366527	2.654400892	4.362571e-01	40.26031303	5.487977e+00
Posicion. EML. Absoluta. CRC	0.05880195	14.678304832	1.749586e+00	19.26750058	1.400066e-04
Posicion. Mercados. Liquidez. CRC	0.86597650	32.667055035	5.431119e-01	1.95247573	3.452199e-01
Neto. Transferencias. Clientes. CRC	1.65462526	0.769481112	1.424584e+00	3.94400759	9.377429e-01
Uso. Garantias. Sinpe	0.17162883	11.248530580	6.580210e+00	4.68040823	3.416045e+00
Saldo. Aportado. Garantias. Sinpe	17.24685340	1.041200937	3.296843e-01	0.23613213	2.161643e-03
Monto. Custodia	20.03056263	0.102791346	1.387657e+00	0.22730172	5.371813e-01
Porcentaje. Custodia	20.04135199	0.140413376	1.327240e+00	0.21312321	5.503676e-01

ACP indicadores de hábitos de pago en dólares**Eigenvalues**

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10	Dim.11
Variance	2.242	1.571	1.249	1.142	1.037	0.966	0.912	0.724	0.650	0.555	0.507
% of var.	18.683	13.089	10.406	9.513	8.639	8.046	7.597	6.030	5.413	4.622	4.224
Cumulative % of var.	18.683	31.773	42.178	51.691	60.330	68.376	75.974	82.003	87.416	92.038	96.262
	Dim.12										
Variance	0.449										
% of var.	3.738										
Cumulative % of var.	100.000										



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Mayor.Entrada.Neta.USD	0.49646268	0.61356535	-0.167281690	0.22189524	0.052239624
Mayor.Salida.Neta.USD	-0.65199786	0.26106942	-0.091582502	0.37618588	-0.025933398
Saldo.Inicial.USD	0.74250611	-0.09484553	-0.133530101	-0.10196921	0.094883233
Total.Pagos.Enviados.USD	0.63917562	-0.17153530	0.413894568	0.02990327	-0.251348554
Total.Pagos.Recibidos.USD	0.57066132	0.04260205	-0.136891653	-0.21115680	0.268271141
Obligaciones.Horas.Especificas.USD	0.30568302	-0.12282017	0.666567563	0.40295744	-0.164800904
Hora.Promedio.Enviados.USD	-0.08976443	0.01859185	0.306702308	0.49803453	0.524903704
Hora.Promedio.Recibidos.USD	0.04603517	-0.09327510	0.009370619	-0.19537859	0.663241987
Posicion.EML.Porc.USD	-0.20012767	0.53541929	0.423142006	-0.39085608	-0.060456097
Posicion.EML.Absoluta.USD	-0.02599223	0.70036071	0.296679358	-0.32687846	0.005629988
Posicion.Mercados.Liquidez.USD	0.17771807	0.09553517	-0.369192841	0.09475795	-0.374869700
Neto.Transferencias.Clientes.USD	0.33010898	0.52480338	-0.250223108	0.42159781	0.048164573


contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Mayor.Entrada.Neta.USD	10.99357626	23.96766309	2.240987264	4.31317620	0.263248009
Mayor.Salida.Neta.USD	18.96086352	4.33926365	0.671687985	12.39670298	0.064875967
Saldo.Inicial.USD	24.59041386	0.57271394	1.427910296	0.91083411	0.868448277
Total.Pagos.Enviados.USD	18.22242520	1.87331603	13.718986433	0.07833187	6.094215279
Total.Pagos.Recibidos.USD	14.52521738	0.11554871	1.500709078	3.90581221	6.942452583
Obligaciones.Horas.Especificas.USD	4.16781466	0.96038070	35.582046639	14.22392914	2.619896837
Hora.Promedio.Enviados.USD	0.35939688	0.02200641	7.533150802	21.72801862	26.578121669
Hora.Promedio.Recibidos.USD	0.09452469	0.55390529	0.007032004	3.34391450	42.433517599
Posicion.EML.Porc.USD	1.78640545	18.25122678	14.338867607	13.38242931	0.352569888
Posicion.EML.Absoluta.USD	0.03013373	31.22824552	7.048833192	9.35995648	0.003057595
Posicion.Mercados.Liquidez.USD	1.40873377	0.58107285	10.915637775	0.78656116	13.555816725
Neto.Transferencias.Clientes.USD	4.86049458	17.53465702	5.014150927	15.57033343	0.223779573

ACP indicadores red LBTR en colones

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10
Variance	7.444	1.193	0.694	0.330	0.171	0.092	0.069	0.008	0.000	0.000
% of var.	74.444	11.928	6.940	3.296	1.705	0.918	0.690	0.079	0.000	0.000
Cumulative % of var.	74.444	86.372	93.312	96.608	98.313	99.231	99.921	100.000	100.000	100.000



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.RTGS.CRC	0.9595387	0.1905140	-0.11493185	-0.08203444	-0.15104668
Grado.entrada.RTGS.CRC	0.9600723	0.1777016	-0.14102261	-0.04452315	-0.09877627
Grado.salida.RTGS.CRC	0.9403043	0.2006655	-0.08448113	-0.12100609	-0.20463777
Intensidad.RTGS.CRC	0.9047615	-0.3382158	0.21424012	-0.12923450	0.06448632
Intensidad.entrada.RTGS.CRC	0.8870220	-0.3422665	0.20173422	0.02195345	-0.00454310
Intensidad.salida.RTGS.CRC	0.8700875	-0.3167705	0.21262570	-0.24234251	0.11583383
Centralidad.del.vector.propio.RTGS.CRC	0.8003837	-0.3438006	0.11412355	0.45843019	-0.08723287
Centralidad.Autoridad.RTGS.CRC	0.8969082	0.2225323	-0.29610477	0.08684311	0.17016147
Centralidad.Hub.RTGS.CRC	0.8989584	0.2036876	-0.27413073	0.08269929	0.19877109
Centralidad.de.intermediación.RTGS.CRC	0.3195576	0.7372585	0.58830653	0.07636192	0.04882507


contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.RTGS.CRC	12.367914	3.042945	1.903380	2.0415264	13.38102319
Grado.entrada.RTGS.CRC	12.381671	2.647422	2.865643	0.6013598	5.72232114
Grado.salida.RTGS.CRC	11.877042	3.375872	1.028405	4.4419848	24.56057584
Intensidad.RTGS.CRC	10.996123	9.590211	6.613727	5.0666336	2.43894577
Intensidad.entrada.RTGS.CRC	10.569153	9.821302	5.864133	0.1462070	0.01210519
Intensidad.salida.RTGS.CRC	10.169446	8.412590	6.514426	17.8164749	7.86933017
Centralidad.del.vector.propio.RTGS.CRC	8.605338	9.909542	1.876702	63.7542283	4.46300374
Centralidad.Autoridad.RTGS.CRC	10.806061	4.151706	12.633842	2.2878804	16.98202192
Centralidad.Hub.RTGS.CRC	10.855519	3.478319	10.828295	2.0747518	23.17252622
Centralidad.de.intermediación.RTGS.CRC	1.371734	45.570091	49.871448	1.7689530	1.39814683

ACP indicadores red LBTR en dólares

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10
Variance	7.186	1.215	0.666	0.499	0.169	0.134	0.115	0.017	0.000	0.000
% of var.	71.858	12.147	6.656	4.985	1.693	1.339	1.147	0.175	0.000	0.000
Cumulative % of var.	71.858	84.005	90.661	95.646	97.339	98.678	99.825	100.000	100.000	100.000



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.RTGS.USD	0.9597623	0.2106687	-0.1217746	-0.018862592	-0.052499101
Grado.entrada.RTGS.USD	0.9522298	0.1831638	-0.1254966	0.007579147	-0.185604722
Grado.salida.RTGS.USD	0.9316699	0.2348187	-0.1127246	-0.049145290	0.105614662
Intensidad.RTGS.USD	0.8761394	-0.4241695	0.1542664	-0.167401081	0.005391270
Intensidad.entrada.RTGS.USD	0.8343934	-0.4707740	0.1473405	-0.009279112	-0.016795174
Intensidad.salida.RTGS.USD	0.8454100	-0.3420639	0.1484285	-0.312604294	0.027267410
Centralidad.del.vector.propio.RTGS.USD	0.6963689	-0.3885037	-0.0379972	0.590880031	0.061298552
Centralidad.Autoridad.RTGS.USD	0.9114310	0.2258388	-0.1881293	0.046432253	-0.192469944
Centralidad.Hub.RTGS.USD	0.8664607	0.3092008	-0.2129459	-0.047958107	0.281068755
Centralidad.de.intermediación.RTGS.USD	0.4949396	0.5152997	0.6874629	0.127541154	0.008418749


contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.RTGS.USD	12.818944	3.653677	2.2278833	0.07137058	1.62809555
Grado.entrada.RTGS.USD	12.618518	2.761908	2.3661545	0.01152278	20.34952125
Grado.salida.RTGS.USD	12.079502	4.539367	1.9090462	0.48448495	6.58907701
Intensidad.RTGS.USD	10.682461	14.811834	3.5753785	5.62125137	0.01716953
Intensidad.entrada.RTGS.USD	9.688725	18.245460	3.2615476	0.01727147	0.16662693
Intensidad.salida.RTGS.USD	9.946256	9.632617	3.3098945	19.60227006	0.43920162
Centralidad.del.vector.propio.RTGS.USD	6.748443	12.425685	0.2169115	70.03499739	2.21960958
Centralidad.Autoridad.RTGS.USD	11.560389	4.198816	5.3173119	0.43247001	21.88275463
Centralidad.Hub.RTGS.USD	10.447745	7.870659	6.8126759	0.46136065	46.66607695
Centralidad.de.intermediación.RTGS.USD	3.409018	21.859977	71.0031962	3.26300074	0.04186695

ACP indicadores red MIL en colones

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10
Variance	3.914	2.741	1.166	0.848	0.646	0.393	0.203	0.090	0.000	0.000
% of var.	39.136	27.412	11.660	8.479	6.463	3.926	2.028	0.895	0.000	0.000
Cumulative % of var.	39.136	66.548	78.208	86.687	93.151	97.077	99.105	100.000	100.000	100.000



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MIL.CRC	0.75460774	0.483053225	0.26335777	-0.301069460	0.095944568
Grado.entrada.MIL.CRC	0.95363234	0.006131442	-0.02663719	-0.224439303	-0.004212999
Grado.salida.MIL.CRC	-0.30948300	0.762523760	0.46337973	-0.124558986	0.160086173
Intensidad.MIL.CRC	0.09908998	0.827631681	-0.54154295	0.045213061	-0.069415627
Intensidad.entrada.MIL.CRC	0.80842631	0.179968333	-0.13032321	0.128778474	0.173305224
Intensidad.salida.MIL.CRC	-0.28231399	0.782601790	-0.50607448	-0.014086043	-0.155666203
Centralidad.del.vector.propio.MIL.CRC	0.54924700	0.143129561	0.04276490	0.723006157	0.305253185
Centralidad.Autoridad.MIL.CRC	0.91615524	-0.041230242	-0.07626822	-0.268439341	0.043443915
Centralidad.Hub.MIL.CRC	-0.44268918	0.711276290	0.38483445	0.006661418	0.154641990
Centralidad.de.intermediación.MIL.CRC	0.50886685	0.261557069	0.39887014	0.278816278	-0.658353360


contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MIL.CRC	14.5499837	8.512466953	5.94834989	10.689796258	1.424215394
Grado.entrada.MIL.CRC	23.2371002	0.001371484	0.06085289	5.940648298	0.002746108
Grado.salida.MIL.CRC	2.4473360	21.211541397	18.41527854	1.829726383	3.964994054
Intensidad.MIL.CRC	0.2508878	24.988470880	25.15185645	0.241081480	0.745502990
Intensidad.entrada.MIL.CRC	16.6994002	1.181565106	1.45662495	1.955791575	4.646845178
Intensidad.salida.MIL.CRC	2.0365018	22.343291018	21.96509612	0.023399903	3.749070076
Centralidad.del.vector.propio.MIL.CRC	7.7082427	0.747350181	0.15684807	61.648144736	14.416349474
Centralidad.Autoridad.MIL.CRC	21.4465842	0.062015070	0.49887467	8.498227413	0.292006694
Centralidad.Hub.MIL.CRC	5.0074636	18.456193360	12.70141493	0.005233225	3.699897993
Centralidad.de.intermediación.MIL.CRC	6.6164999	2.495734551	13.64480348	9.167950730	67.058372038

ACP indicadores red MIL en dólares

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10
Variance	4.160	2.778	1.160	0.633	0.589	0.348	0.218	0.114	0.000	0.000
% of var.	41.599	27.777	11.600	6.325	5.894	3.481	2.183	1.141	0.000	0.000
Cumulative % of var.	41.599	69.376	80.976	87.301	93.195	96.676	98.859	100.000	100.000	100.000



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MIL.USD	0.9415252	0.09854945	-0.03486998	-0.046247898	0.25146723
Grado.entrada.MIL.USD	0.7189754	-0.63531599	-0.08792549	0.007580679	0.14201771
Grado.salida.MIL.USD	0.5539766	0.75914016	0.03996865	-0.069539902	0.19730596
Intensidad.MIL.USD	0.8902891	0.09763228	-0.16836864	0.127938354	-0.38856241
Intensidad.entrada.MIL.USD	0.7049635	-0.54887919	-0.14796560	0.052331360	-0.22755259
Intensidad.salida.MIL.USD	0.5234133	0.70937232	-0.08373804	0.126208303	-0.31186591
Centralidad.del.vector.propio.MIL.USD	0.2214916	-0.08840788	0.83945539	0.486400342	0.03573354
Centralidad.Autoridad.MIL.USD	0.6209999	-0.62200706	-0.15057646	0.070699607	0.26787056
Centralidad.Hub.MIL.USD	0.4649533	0.74752218	-0.02816602	-0.011827456	0.26400249
Centralidad.de.intermediación.MIL.USD	0.4849524	-0.14341031	0.60338668	-0.590521903	-0.15589166


contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MIL.USD	21.309908	0.3496407	0.10481800	0.33815712	10.7290783
Grado.entrada.MIL.USD	12.426412	14.5309241	0.66644142	0.00908554	3.4220362
Grado.salida.MIL.USD	7.377352	20.7471096	0.13771188	0.76454434	6.6051096
Intensidad.MIL.USD	19.053720	0.3431630	2.44373905	2.58783180	25.6165824
Intensidad.entrada.MIL.USD	11.946779	10.8459401	1.88735653	0.43297076	8.7854331
Intensidad.salida.MIL.USD	6.585779	18.1159929	0.60447450	2.51831692	16.5019567
Centralidad.del.vector.propio.MIL.USD	1.179321	0.2813815	60.74739573	37.40436383	0.2166466
Centralidad.Autoridad.MIL.USD	9.270447	13.9284983	1.95454923	0.79025732	12.1744570
Centralidad.Hub.MIL.USD	5.196803	20.1169360	0.06838853	0.02211654	11.8253956
Centralidad.de.intermediación.MIL.USD	5.653480	0.7404137	31.38512512	55.13235584	4.1233045

ACP indicadores red Monex

Eigenvalues

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9	Dim.10
Variance	4.130	2.911	1.020	0.855	0.429	0.357	0.156	0.143	0.000	0.000
% of var.	41.298	29.113	10.196	8.555	4.287	3.569	1.556	1.426	0.000	0.000
Cumulative % of var.	41.298	70.412	80.607	89.162	93.449	97.018	98.574	100.000	100.000	100.000



correlations variables - dimensions

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MONEX	0.9523728	0.08003593	-0.18878221	-0.08975813	-0.08364045
Grado.entrada.MONEX	0.6615670	0.66901925	-0.02662768	-0.15404960	0.05652591
Grado.salida.MONEX	0.7466359	-0.53703757	-0.25018691	0.01929214	-0.17765028
Intensidad.MONEX	0.7194154	-0.43206308	0.51516134	-0.01542810	0.15829498
Intensidad.entrada.MONEX	0.4887824	0.60677530	0.42066893	-0.10970292	-0.23445251
Intensidad.salida.MONEX	0.5365953	-0.71142432	0.35370471	0.03137992	0.26589554
Centralidad.del.vector.propio.MONEX	0.2733766	0.35374916	0.07146174	0.89055230	-0.02274047
Centralidad.Autoridad.MONEX	0.5574368	0.71415113	0.13633724	-0.11826967	-0.02076767
Centralidad.Hub.MONEX	0.6115588	-0.63502174	-0.21328157	0.05131583	-0.31220448
Centralidad.de.intermediación.MONEX	0.6509921	0.26374736	-0.53291351	0.01837797	0.37122441

contributions of the variables

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5
Grado.MONEX	21.962570	0.220027	3.49542373	0.94177691	1.6318314
Grado.entrada.MONEX	10.597827	15.373873	0.06954154	2.77409685	0.7453114
Grado.salida.MONEX	13.498544	9.906390	6.13913097	0.04350723	7.3616364
Intensidad.MONEX	12.532241	6.412101	26.02940539	0.02782439	5.8448975
Intensidad.entrada.MONEX	5.784960	12.646252	17.35635768	1.40681470	12.8218997
Intensidad.salida.MONEX	6.972091	17.384551	12.27041959	0.11510762	16.4916726
Centralidad.del.vector.propio.MONEX	1.809639	4.298302	0.50086989	92.70845499	0.1206262
Centralidad.Autoridad.MONEX	7.524204	17.518073	1.82308417	1.63511111	0.1006047
Centralidad.Hub.MONEX	9.056194	13.851068	4.46153585	0.30782455	22.7363554
Centralidad.de.intermediación.MONEX	10.261732	2.389364	27.85423118	0.03948166	32.1451646

APÉNDICE E. RESULTADOS DEL ANÁLISIS DE REDES NEURONALES

```


> library(NeuralNetTools)
> library(nnet)

> modelo = nnet(Banco ~ .,
+               data = training,
+               size = k,
+               rang = 0.1,
+               decay = 5e-2,
+               maxit = 50000)

> print(modelo)
a 23-20-14 network with 774 weights
inputs: CP01.HP.CRC CP02.HP.CRC CP03.HP.CRC CP04.HP.CRC CP05.HP.CRC CP01.HP.USD CP02.HP.USD
CP03.HP.USD CP04.HP.USD CP05.HP.USD CP01.MIL.CRC CP02.MIL.CRC CP03.MIL.CRC CP01.MIL.USD
CP02.MIL.USD CP03.MIL.USD CP01.RTGS.CRC CP02.RTGS.CRC CP01.RTGS.USD CP02.RTGS.USD CP01.Monex
CP02.Monex CP03.Monex
output(s): Banco
outputs were - softmax modelling decay=0.05

> plotnet(modelo,
+         circle_cex = 3,
+         cex_val = 0.5)

```



ANEXOS

ANEXO A: LISTA DE SERVICIOS Y CÓDIGOS DE MOTIVOS SINPE

Código	Siglas	Descripción
10	CDF	Cuentas de Fondos
12	SIL	Sistema Interbancario de Liquidación
14	REF	Reclamaciones de Fondos
20	TFI	Transferencias de Fondos Interbancarias
21	TFT	Transferencias de Fondos a Terceros
23	MEX	Mercado de Monedas Extranjeras Confidencial
24	DTR	Débito en Tiempo Real
30	CLC	Compensación y Liquidación de Cheques
31	CCD	Compensación de Créditos Directos
32	CDD	Compensación de Débitos Directos
35	ATH	Liquidación de Servicios Externos
36	TEO	Traspaso Entre Operadoras
38	COV	Compensación de Otros Valores
40	ILI	Información y Liquidación de Impuestos
50	TCS	Tarifas y Cobros
53	LAI	Comisiones del SINPE
60	RDE	Registro de Emisiones
62	RDD	Registro de Depósitos a Plazo
66	VVE	Ventanilla de Valores Estandarizados
67	LIM	Liquidación de Mercados
72	CAN	Custodias Auxiliares de Numerario
76	MEN	Mercado de Numerario
81	MIL	Mercado Integrado de Liquidez
83	PMB	Pagos Monedero Bancario
84	PEX	Servicio de Pagos al Exterior

ANEXO B: REPRESENTACIÓN MATEMÁTICA DEL MODELO MLP SEGÚN GÜNTER Y FRITSH (2010)

Günter y Fritsh (2010) representan matemáticamente la MLP más simple como:

$$o(\mathbf{x}) = f\left(w_0 + \sum_{i=1}^n w_i x_i\right) = f(w_0 + \mathbf{w}^T \mathbf{x})$$

Donde w_0 es el intercepto, $\mathbf{w} = (w_1, \dots, w_n)$ es el vector de pesos sinápticos sin el intercepto y $\mathbf{x} = (x_1, \dots, x_n)$ el vector de covariables. La función es matemáticamente equivalente a un modelo lineal generalizado (GLM por sus siglas en inglés) con una función de enlace f^{-1} . Por lo tanto, todos los pesos calculados son en este caso equivalentes a los parámetros de regresión del GLM.

Para incrementar la flexibilidad del modelo anterior pueden incluirse las capas ocultas. Un modelo MLP con una capa oculta se puede representar como:

$$\begin{aligned} o(\mathbf{x}) &= f\left(w_0 + \sum_{j=1}^J w_j \times f\left(w_{0j} + \sum_{i=1}^n w_{ij} x_i\right)\right) \\ &= f\left(w_0 + \sum_{j=1}^J w_j \times f(w_{0j} + \mathbf{w}_j^T \mathbf{x})\right) \end{aligned}$$

Donde w_0 es el intercepto de la neurona de salida y w_{0j} es el intercepto de la j -ésima neurona oculta. Adicionalmente, w_j es el peso sináptico correspondiente a la sinapsis que comienza en la j -ésima neurona oculta y conduce a la neurona de salida, $\mathbf{w}_j = (w_{1j}, \dots, w_{nj})$ es el vector de todos los pesos sinápticos correspondientes a las sinapsis que conducen a la j -ésima neurona oculta y $\mathbf{x} = (x_1, \dots, x_n)$ el vector de covariables. Esto demuestra que las redes neuronales son extensiones directas de los GLM. Sin embargo, los parámetros, es decir, los pesos, no pueden interpretarse de la misma manera.

ANEXO C: DETERMINACIÓN DE LOS COMPONENTES PRINCIPALES SEGÚN JOHNSON (2000)

Dado un conjunto de variables aleatorias X_1, X_2, \dots, X_p que poseen una distribución p-dimensional cualquiera, con vector de medias $\boldsymbol{\mu}$ y matriz de varianzas y covarianzas $\boldsymbol{\Sigma}$ con raíces características $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$.

De esta distribución se extrae una muestra de n observaciones independientes x_1, x_2, \dots, x_n , representada por la matriz de datos $\mathbf{X} = X_{ij}$, para $i = 1, 2, \dots, n; j = 1, 2, \dots, p$.

Los componentes principales muestrales son aquellas combinaciones lineales y_j de las variables originales X_j , que no están correlacionadas entre sí y que tienen una varianzas muestral máxima. Simbólicamente:

$$\begin{aligned} y_1 &= a_{11}x_1 + a_{21}x_2 + \dots + a_{p1}x_p = \mathbf{a}'_1\mathbf{x} \\ y_2 &= a_{12}x_1 + a_{22}x_2 + \dots + a_{p2}x_p = \mathbf{a}'_2\mathbf{x} \\ &\vdots \\ y_i &= a_{1i}x_1 + a_{2i}x_2 + \dots + a_{pi}x_p = \mathbf{a}'_i\mathbf{x} \\ &\vdots \\ y_p &= a_{1p}x_1 + a_{2p}x_2 + \dots + a_{pp}x_p = \mathbf{a}'_p\mathbf{x} \end{aligned}$$

Donde $\mathbf{a}'_i = (a_{1i}, a_{2i}, \dots, a_{pi})$ es un vector fila de constantes ($i = 1, 2, \dots, n$) y $\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_p \end{bmatrix}$ es un vector columna que representa los valores de las variables en un individuo cualquiera.

Para determinar el valor de los a_i se resuelve un problema de optimización para encontrar el valor con los que se maximiza la varianzas. Una forma de resolver esta optimización es mediante el cálculo de los valores propios (*eigenvalues*) y vectores propios (*eigenvector*) de la matriz de covarianzas.