

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**  
**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**  
**DIVISIÓN DE ESTUDIOS DE POSGRADO**



**“PRONÓSTICO DE LA DEMANDA DE EFECTIVO EN  
UNA INSTITUCIÓN FINANCIERA EN MÉXICO.”**

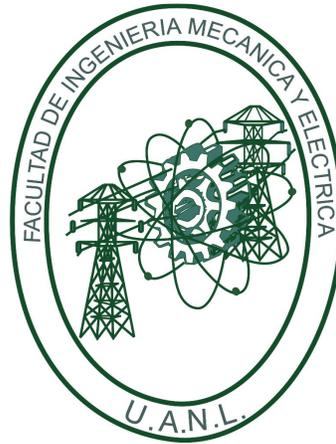
**POR:**

**OMAR ALEXIS FIGUEROA ARMENDÁRIZ**

**TESIS**

**EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA DE SISTEMAS**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**  
**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**  
**DIVISIÓN DE ESTUDIOS DE POSGRADO**



**“PRONÓSTICO DE LA DEMANDA DE EFECTIVO EN  
UNA INSTITUCIÓN FINANCIERA EN MÉXICO.”**

**POR:**

**OMAR ALEXIS FIGUEROA ARMENDÁRIZ**

**TESIS**

**EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA DE SISTEMAS**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**  
**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**  
**DIVISIÓN DE ESTUDIOS DE POSGRADO**

Los miembros del Comité de Tesis recomendamos que la tesis “Pronóstico de la demanda de efectivo en una institución financiera en México”, realizada por el alumno Omar Alexis Figueroa Armendáriz con número de matrícula 1577000, sea aceptada para su defensa como opción al grado de Maestro en Ciencias en Ingeniería de Sistemas.

**El Comité de Tesis**

---

Dra. Sara Verónica Rodríguez Sánchez  
Director

---

Dr. Arturo Berrones Santos  
Revisor

---

Dr. Richard Weber  
Revisor

Vo. Bo.

---

Dr. Moisés Hinojosa Rivera  
División de Estudios de Posgrado

*A mis padres.*

# ÍNDICE GENERAL

ÍNDICE DE FIGURAS.....	vii
ÍNDICE DE TABLAS .....	ix
AGRADECIMIENTOS .....	x
RESUMEN .....	xi
CAPÍTULO 1 INTRODUCCIÓN.....	1
1.1 PANORAMA GENERAL. ....	1
1.2 DESCRIPCIÓN DEL PROBLEMA. ....	2
1.3 OBJETIVO.....	5
1.4 JUSTIFICACIÓN. ....	5
1.5 HIPÓTESIS. ....	7
1.6 ESTRUCTURA DE LA TESIS.....	8
CAPÍTULO 2 ANTECEDENTES.....	9
2.1 PRONÓSTICO DE SERIES DE TIEMPO.....	9
2.1.1 PRONÓSTICO DE SERIES DE TIEMPO USANDO RNAs. ....	10
CAPÍTULO 3 ANÁLISIS DEL SISTEMA SUJETO A PRONÓSTICO .....	13
3.1 INTRODUCCIÓN.....	13
3.2 DESCRIPCIÓN DEL SISTEMA: LA CADENA DE SUMINISTRO DE EFECTIVO.....	14
3.3 DESCRIPCIÓN DE LOS DATOS. ....	15
3.4 ANÁLISIS ESTADÍSTICO DE LOS DATOS. ....	18
3.5 DEFINICIÓN DEL PROBLEMA.....	25
CAPÍTULO 4 METODOLOGÍA PROPUESTA.....	27
4.1 INTRODUCCIÓN.....	27
4.1.1 RED NEURONAL ARTIFICIAL. ....	28
4.1.2 MODELO AUTORREGRESIVO.....	30
4.2 DESCRIPCIÓN DE LA METODOLOGÍA. ....	31
4.2.1 IDENTIFICACIÓN DE REGRESORES POTENCIALES. ....	31
4.2.2 SELECCIÓN DE LOS REGRESORES.....	32
4.2.3 CONSTRUCCIÓN DEL CONJUNTO DE ENTRENAMIENTO Y PRUEBA. ....	36

---

4.2.4	AJUSTE DE LOS PARÁMETROS CONTROLABLES.....	37
4.2.5	SELECCIÓN DEL MODELO.....	39
4.3	AJUSTE DE PRONÓSTICO EN PERIODOS CLASIFICADOS.....	39
CAPÍTULO 5 EXPERIMENTACIÓN Y RESULTADOS.....		41
5.1	SELECCIÓN DE VARIABLES DE ENTRADA.....	41
5.2	AJUSTE DE PARÁMETROS CONTROLABLES.....	44
5.3	SELECCIÓN DEL MODELO.....	45
5.4	AJUSTE DE PRONÓSTICO EN PERIODOS CLASIFICADOS.....	48
5.5	COMPARACIÓN DE RESULTADOS OBTENIDOS. ....	54
CAPÍTULO 6 CONCLUSIONES Y TRABAJO FUTURO .....		59
REFERENCIAS BIBLIOGRÁFICAS .....		62
FICHA AUTOBIOGRÁFICA .....		66

# ÍNDICE DE FIGURAS

Figura 1.1- Retiros de una sucursal (3 años de operación). .....	5
Figura 3.1- Esquema de representación de los datos.....	17
Figura 3.2 - Comportamiento de los retiros de efectivo en una sucursal.....	18
Figura 3.3 - Comportamiento de los retiros por semana desde 1999 a 2011 para la Serie A.....	19
Figura 3.4 - Comportamiento de los retiros por semana desde 1999 a 2011.....	20
Figura 3.5 - Comportamiento de los retiros por semana desde 1999 a 2011.....	20
Figura 3.6 - Gráfico de cajas para los retiros por año en la Serie A.....	22
Figura 3.7 - Gráfico de cajas para los retiros por año en la Serie B.....	22
Figura 3.8 - Gráfico de cajas para los retiros por año en la Serie C.....	23
Figura 3.9 - Gráfico de la función de autocorrelación para la Serie A. ....	24
Figura 3.10 - Gráfico de la función de autocorrelación para la Serie B.....	24
Figura 3.11 - Gráfico de la función de autocorrelación para la Serie C.....	25
Figura 4.1 - Representación gráfica de una Red Neuronal Artificial uni-capas con conexiones hacia delante.....	30
Figura 4.2 - Estructura general de RNA propuesta. ....	35
Figura 4.3 - Ejemplo de partición de los datos con $K=5$ . ....	38
Figura 5.1 - Pronóstico 2011 para la Serie A. ....	47

---

Figura 5.2 - Pronóstico 2011 para la Serie B. ....	47
Figura 5.3 - Pronóstico 2011 para la Serie C. ....	48
Figura 5.4 - Pronóstico de periodo de pascua en 2011 para la Serie A. ....	50
Figura 5.5 - Pronóstico de periodo de pascua en 2011 para la Serie B.....	50
Figura 5.6 - Pronóstico de periodo de pascua en 2011 para la Serie C. ....	51
Figura 5.7 - Pronóstico ajustado de 2011 para la Serie A. ....	53
Figura 5.8 - Pronóstico ajustado de 2011 para la Serie B. ....	53
Figura 5.9 - Pronóstico ajustado de 2011 para la Serie C. ....	54
Figura 5.10 - Pronóstico ajustado de 2011 para la Serie A usando modelo ARIMA. ...	57
Figura 5.11 - Pronóstico ajustado de 2011 para la Serie B usando modelo ARIMA. ...	57
Figura 5.12 - Pronóstico ajustado de 2011 para la Serie C usando modelo ARIMA. ...	58

# ÍNDICE DE TABLAS

Tabla 3.1 - Estadísticas descriptivas para el valor nominal de los retiros para cada serie. ....	21
Tabla 4.1- Funciones de R mayormente utilizadas para el análisis.....	28
Tabla 4.2 - Configuración de las neuronas de entrada. ....	34
Tabla 5.1 - Neuronas de entrada seleccionadas para cada serie. ....	42
Tabla 5.2 - RMSE de los residuales para cada configuración en la Serie A. ....	43
Tabla 5.3 - RMSE de los residuales para cada configuración en la Serie B. ....	43
Tabla 5.4 - RMSE de los residuales para cada configuración en la Serie C. ....	43
Tabla 5.5 - Valor de los parámetros controlables. ....	44
Tabla 5.6 - Arquitectura de los modelos de RNA.....	45
Tabla 5.7 - Error de pronóstico del 2011. ....	46
Tabla 5.8 - Orden del modelo seleccionado para cada serie. ....	49
Tabla 5.9 - Error de pronóstico ajustado para 2011. ....	52
Tabla 5.10 - Orden del modelo seleccionado para cada serie. ....	55
Tabla 5.11 - Error de pronóstico ajustado para 2011 utilizando ARIMA. ....	56
Tabla 5.12 - Comparación del error de pronóstico en términos de MAPE.....	58

# AGRADECIMIENTOS

A mis padres, hermanos y amigos por su incondicional apoyo.

A mis compañeros y profesores del posgrado por todo el conocimiento compartido. Agradecimientos especiales a la Dra. Sara Rodríguez Sánchez por su apoyo y paciencia, así como por el asesoramiento y dirección de este trabajo. Agradezco también de manera especial a mis revisores, Dr. Arturo Berrones (Universidad Autónoma de Nuevo León) y Dr. Richard Weber (Universidad de Chile), que aportaron de manera sustancial a mi aprendizaje y al desarrollo de la tesis.

A la UANL-FIME y a el Programa de Posgrado en Ingeniería de Sistemas.

Al Consejo Nacional de Ciencia y Tecnología (Conacyt) por el apoyo económico otorgado.

# RESUMEN

Omar Alexis Figueroa Armendáriz.

Candidato para el grado de Maestro en Ciencias

con especialidad en Ingeniería de Sistemas.

Universidad Autónoma de Nuevo León.

Facultad de Ingeniería Mecánica y Eléctrica.

Título del trabajo:

PRONÓSTICO DE LA DEMANDA DE EFECTIVO  
EN UNA INSTITUCIÓN FINANCIERA EN MÉXICO.

Número de páginas: 66

**OBJETIVO Y MÉTODO DE ESTUDIO:** El presente trabajo aborda el problema de predecir la demanda de efectivo de una importante institución financiera en México. Esta cuenta con una red de distribución a lo largo de toda la República Mexicana, maneja inventarios de efectivo en diversas bóvedas, así como una flotilla de aviones y camiones usados para la distribución. La idea central es que la institución establezca un plan sobre sus operaciones, acompañado de una correcta administración de sus recursos, tal que puedan satisfacer la demanda.

Se presenta un análisis de datos históricos de la demanda y una metodología de pronóstico para tres series de tiempo, para las cuales se busca encontrar patrones estacionales y de tendencia mismos que sirven para construir un modelo de pronóstico a corto, mediano y largo plazo de manera que de soporte a la planeación de las operaciones y a una correcta administración de los recursos de la institución. Por la misma naturaleza de los datos, los modelos autorregresivos tradicionales no logran capturar de manera eficiente el comportamiento de los retiros de efectivo, por lo que

se propone la técnica de Redes Neuronales Artificiales (RNAs) para abordar el problema. Los análisis se hacen utilizando la herramienta computacional R.

Con base en el análisis de los datos, se establecen estrategias para seleccionar los regresores más adecuados y construir los modelos potenciales de RNAs. Los modelos seleccionados se utilizan para obtener un pronóstico, mismo que se ajusta en ciertos periodos con ayuda de un modelo autorregresivo.

**CONTRIBUCIONES Y CONCLUSIONES:** Se muestra una comparación de los resultados que se obtienen con la metodología propuesta para diferentes horizontes de pronóstico, contra los resultados que se obtienen mediante métodos tradicionales lineales de pronóstico. Se encuentra que los modelos de RNAs obtienen un mejor desempeño para las 3 series analizadas.

El pronóstico obtenido funge como base para la toma de decisiones, pues puede ser ajustado conforme se tenga conocimiento del proceso, por ejemplo en eventos especiales que no han sucedido con anterioridad y por ende se espera que el modelo no logre pronosticar adecuadamente tal periodo. Asimismo, como se propone es este trabajo, los periodos conocidos pero que no tienen una estacionalidad fija pueden ser abordados mediante técnicas más sencillas de manera independiente, aprovechando sus características particulares.

Firma del director: \_\_\_\_\_

Dra. Sara Verónica Rodríguez Sánchez

# CAPÍTULO 1

## INTRODUCCIÓN

### 1.1 PANORAMA GENERAL.

Las organizaciones hoy en día se enfrentan a un amplio rango de factores que afectan e inciden en la eficiencia de la administración de sus operaciones y, por ende, en su economía. Estos factores se pueden clasificar en internos y externos. Los primeros, también llamados *factores controlables*, son aquellos sobre los cuales la organización internamente puede tomar decisiones y modificar su comportamiento (i.e. nivel de inventario, nivel de producción, cantidad de recursos a utilizar, etc.), mientras que los factores externos son aquellos derivados del entorno y que afectan directa o indirectamente a la organización. Éstos últimos son llamados *factores no controlables* ya que no se puede tomar una decisión sobre ellos (i.e. inflación de precios, reformas fiscales, crecimiento demográfico, demanda, etc.). Para una buena administración de los recursos es importante que se tenga conocimiento de cómo se comportarán ambos factores en un intervalo de tiempo futuro, mismo que dependerá del nivel de decisión que se esté tomando (estratégico, táctico u operativo). Predecir el comportamiento de los factores no controlables no es una tarea trivial, pero sí necesaria para apoyar las decisiones que se tomarán sobre los factores controlables. Si bien la intuición suele ser el método comúnmente utilizado para predecir el comportamiento de los factores externos, éste no suele ser muy exacto. Lamentablemente la gran competitividad del entorno económico está exigiendo un mayor rigor en la toma de decisión, y con ello la necesidad de reducir el error de predicción es cada vez mayor. Los métodos de pronóstico están cobrando gran relevancia no solo en la ciencia sino también en la industria (Makridakis, Wheelwright, & Hyndman, 1998). En los últimos años, el campo de la predicción ha

tenido grandes desarrollos de métodos y técnicas para pronosticar el comportamiento de los factores externos de manera confiable. Un estudio adecuado de los factores puede determinar si siguen un comportamiento totalmente impredecible o por el contrario existen patrones distintivos que pueden ser extrapolados, como la variación, la tendencia y la estacionalidad. En el caso de existir estos patrones, resulta de sumo interés para el tomador de decisiones encontrar estrategias de predicción confiables.

El presente trabajo aborda el problema de predecir la demanda de efectivo de una importante institución financiera en México. La demanda actúa como un factor externo de la organización, pues no se puede controlar el momento y la cantidad de efectivo demandada por el cliente. Una de las políticas de la institución es satisfacer en todo momento la demanda. Para ello, la institución cuenta con una red de distribución a lo largo de toda la República Mexicana, maneja inventarios de efectivo en diversas bóvedas, así como una flotilla de aviones y camiones usados para la distribución. La idea central es que la institución establezca un plan sobre sus operaciones, acompañado de una correcta administración de sus recursos, tal que puedan satisfacer la demanda. El principal aspecto que complica la toma de decisión es el comportamiento variable de la misma.

El resto del capítulo se estructura de la siguiente manera: en la Sección 1.2 se describe el problema a abordar, la Sección 1.3 se plantea el objetivo de este trabajo, la justificación se da en la Sección 1.4, dejando para la Sección 1.5 las hipótesis planteadas y finalmente se da una estructura general de este trabajo en la Sección 1.6.

## **1.2 DESCRIPCIÓN DEL PROBLEMA.**

En el área de administración la necesidad de planear es importante para asignar los recursos de la mejor manera. El plazo de ejecución para la toma de decisiones puede tener rangos que van desde varios años, como es el caso de inversiones a largo plazo; unos días u horas (i.e. calendarización de producción o transporte), hasta unos

segundos, como en el área de las telecomunicaciones y de distribución de energía eléctrica. Para todos estos casos, los pronósticos ayudan a tener una efectiva y eficiente planeación ante la incertidumbre del sistema al estimar los eventos posteriores y poder asignar adecuadamente los recursos disponibles. Pronosticar es necesario para determinar cuándo ocurrirá un evento de manera que puedan tomarse acciones apropiadas en el momento preciso. Pronosticar la demanda de un cierto artículo es crucial para la administración de una cadena de suministro, dado que la demanda futura es la base para el respectivo sistema de reposición. Un mejor pronóstico de la demanda permite operar de manera más eficiente con bajos costos de inventario a través de toda la cadena de suministro (Aburto & Weber, 2007). Tal es el caso de Institución Financiera, cuya principal responsabilidad es proveer efectivo por medio de su red de distribución a otras instituciones financieras y bancos comerciales, y los cuales a su vez deben satisfacer las demandas de efectivo del público de la región.

La entidad financiera gasta un monto significativo de su presupuesto anual en administrar su cadena de suministro de efectivo. La principal razón de este gasto se debe al pago de comisión a bancos corresponsales. Los bancos corresponsales son bancos comerciales que alquilan un espacio físico de sus instalaciones para la instalación de bóvedas, que actúan a nombre de la institución financiera para satisfacer la demanda de efectivo y a cambio reciben una comisión por sus servicios. La administración del inventario en bancos corresponsales está a cargo de la institución financiera. Las decisiones más importantes a tomar y que influyen directamente en el pago de la comisión son: ¿Cuándo enviar efectivo? ¿Cuánto y de qué denominación? Estas decisiones dependen en gran medida del conocimiento que se tenga del comportamiento de la demanda. Conocer con certeza la demanda de efectivo resulta imposible, sin embargo se puede estimar su valor con cierto grado de error desarrollando un pronóstico.

Conocer con suficiente certeza los montos de los retiros en periodos posteriores brinda un apoyo al tomador de decisiones para administrar los envíos e inventarios en

las sucursales. Sin embargo, lo anterior resulta una tarea complicada dada la variación de los montos. A manera de ejemplo, en la Figura 1.1, se muestra el comportamiento de los últimos tres años de retiros en un banco corresponsal. Puede notarse que en concreto para esta serie de tiempo en la temporada navideña los retiros de efectivo se incrementan considerablemente debido al pago de aguinaldos, las compras relacionadas a la temporada, viajes, etc. Un incremento de los retiros también se observa en el periodo de Pascua (La Semana Santa), la semana del 16 de septiembre y vacaciones de verano. Una característica particular de la Semana Santa es que no se presenta en la misma fecha año con año, por lo que su efecto sobre la demanda se ve reflejado en marzo o en abril. Para el ejemplo mostrado en la Figura 1.1, se resaltan en rojo las semanas que contienen los denominados días santos, siendo la semana 14 (abril) para el año 2009, la semana 13 (marzo-abril) para el año 2010 y la semana 16 (abril) para el año 2011.

Así bien, el área de planeación de la institución financiera tiene que calendarizar los envíos y calcular los montos necesarios para cada banco corresponsal, de manera que no se presenten desabastos de efectivo, a la vez que se busca reducir el costo de comisión. Por lo tanto es necesario implementar una técnica de pronóstico confiable que sirva de base para planear una estrategia óptima de distribución e inventarios. Por la misma naturaleza de los datos, los modelos autorregresivos tradicionales no logran capturar de manera eficiente el comportamiento de los retiros de efectivo, por lo que se propone la técnica de Redes Neuronales Artificiales (RNAs) para abordar el problema.

Así pues, este trabajo presenta un análisis de datos y una metodología de pronóstico para tres series de tiempo. Se buscará encontrar patrones estacionales y de tendencia mismos que nos servirán para construir un modelo de pronóstico a largo plazo. Un pronóstico confiable de la demanda de efectivo en periodos futuros dará soporte a la planeación de las operaciones y una correcta administración de los recursos de la institución.

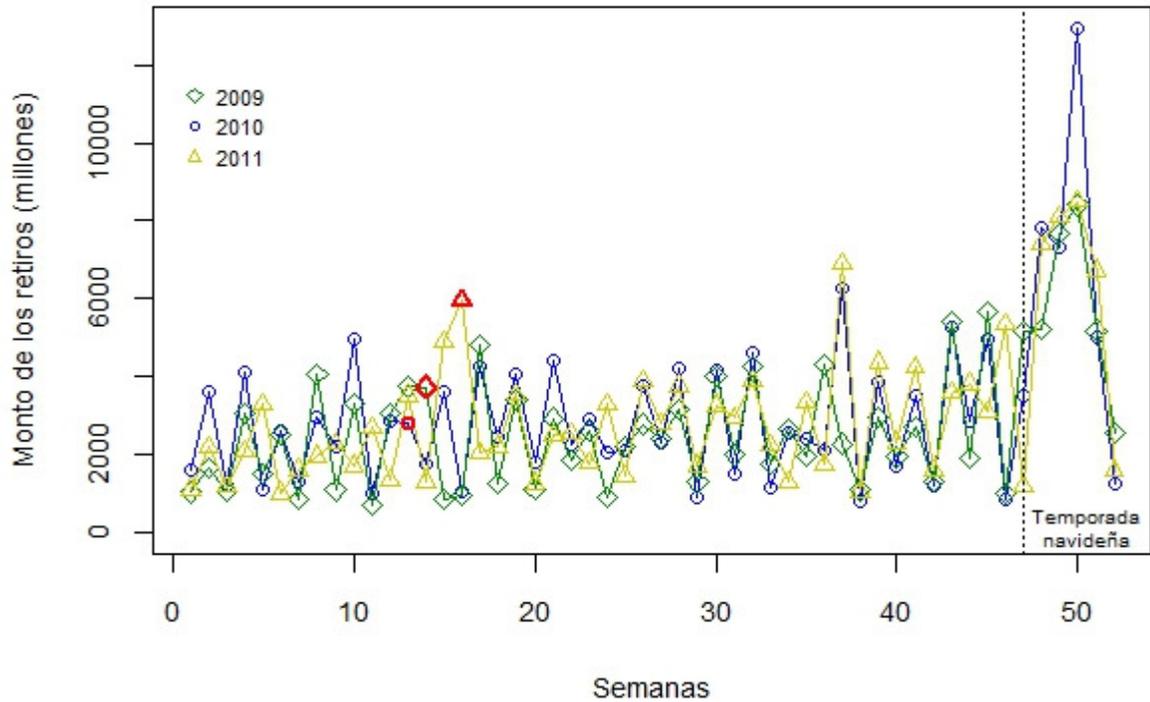


Figura 1.1- Retiros de una sucursal (3 años de operación).

### 1.3 OBJETIVO.

El objetivo de este trabajo consiste en proponer y evaluar una metodología para la construcción de un modelo de pronóstico que brinde una predicción confiable en la demanda de efectivo en distintas sucursales para hasta trece periodos, buscando apoyar a la administración de la cadena de suministro de una institución financiera.

### 1.4 JUSTIFICACIÓN.

El dinero en efectivo sigue siendo hoy en día el medio de pago más tradicional en el mundo. A pesar de que en años recientes se ha incrementado el uso de medios de pago electrónicos, la mayoría de los pagos al menudeo en México sigue siendo en efectivo. Las características propias del efectivo favorecen su uso para realizar pagos por bienes o servicios por el hecho de ser aceptado en todos lados. Además, se tiene la

ventaja de poder disponer del efectivo inmediatamente después de una transacción. Exceptuando la falsificación de billetes, el pago en efectivo es el método no riesgoso de efectuar una transacción, pues se puede verificar con absoluta certeza. Si bien estas ventajas se ven aminoradas cuando las transacciones son montos grandes, dado que no es factible portar grandes cantidades de dinero en efectivo, el efectivo circulante sigue teniendo mayor participación. Al cierre de 2009, los billetes y monedas en circulación sumaron un valor de MXN 632 mil millones, mientras que para el cierre del año 2012 fue de MXN 845 mil millones, un incremento del 33.7% (Banco de México, 2013). La mayoría de los billetes en circulación provienen de transacciones realizadas en cajeros automáticos (ATM). Tan solo en 2009 se registraron en México 1.3 millones de transacciones en estos cajeros. Si a esto se le agrega que México es un país con aproximadamente 2 millones de kilómetros cuadrados de extensión territorial, y en donde el Instituto Nacional de Estadística, Geografía e Informática (INEGI) registró en su último censo poblacional en 2010 un total de 112 millones 336 mil 538 habitantes, se vuelve una tarea compleja distribuir el dinero para satisfacer a toda la población demandante.

Lo anterior nos habla de la complejidad en el desarrollo de un pronóstico de demanda de efectivo. Para apoyar esta tarea, se propone pronosticar a largo plazo la demanda de efectivo usando la información histórica disponible, de manera que se pueda actuar con anticipación ante las variaciones en la demanda de efectivo en diferentes regiones.

Además, cabe señalar que conforme las tasas de interés crecen y la eficiencia operativa se torna esencial para mantenerse competitivo en el mercado, los bancos deben poner especial atención en la administración eficiente de sus operaciones, especialmente en el efectivo dispuesto en almacenes y en cajeros automáticos, considerado “efectivo ocioso” puesto que no genera un rendimiento. Las instituciones financieras deben evitar caer en la tentación de mantener grandes inventarios por temor al desabasto.

En este trabajo, la demanda es pronosticada mediante el uso de RNAs ya que surgen como una herramienta de modelación cuantitativa que ha sido aplicada con éxito en una amplia gama de problemas de predicción en el área industrial, médica, ciencia y medio ambiente, entre otras (Widrow, Rumelhart, & Lehr, 1994). Las RNAs son una herramienta muy flexible y su capacidad de adaptación y modelación no lineal las vuelven atractivas para ser utilizadas en la labor de predicción, además de que han mostrado ser generalizables, pues funcionan bien aún cuando el comportamiento de la serie es lineal (Hwang, 2001; Medeiros & Pedreira, 2001; Zhang, E., & Hu, 2001). Esto las hace mayormente competitivas contra los métodos tradicionales de pronóstico, hecho por el cual pueden ser implementadas con mayor éxito en la industria.

## **1.5 HIPÓTESIS.**

Los retiros de efectivo contienen patrones que poseen dependencia con los montos retirados en periodos pasados. Se asume que resultado de pronosticar utilizando Redes Neuronales Artificiales brinda un mejor pronóstico que el que ofrece un método basado únicamente en dependencias lineales (i.e. Modelo autorregresivo integrado de medias móviles - ARIMA), debido a su flexibilidad en su construcción y su capacidad de capturar dependencias tanto lineales como no lineales.

## 1.6 ESTRUCTURA DE LA TESIS.

El resto de la tesis está organizada de la manera siguiente:

El Capítulo 2 contiene antecedentes relacionados al pronóstico de series de tiempo. Se mencionan algunos trabajos encontrados en la literatura en donde se han utilizado las RNAs como herramienta de predicción.

En el Capítulo 3 se describe el sistema sujeto a pronóstico. Se muestran análisis preliminares de las series que representan la demanda de efectivo en donde se muestran sus características de estacionalidad, tendencia y alta variación.

El Capítulo 4 describe la metodología propuesta para abordar el problema de pronóstico de la demanda de efectivo. Con base en los análisis mostrados en el Capítulo 3, se establecen estrategias para seleccionar los regresores más adecuados para construir los modelos potenciales de RNAs. En este capítulo se define también la manera en que se obtiene un pronóstico final con ajustes en ciertos periodos.

En el Capítulo 5 se muestran los resultados que se obtienen al seguir la metodología propuesta en el Capítulo 4. Aquí se muestran resultados de comparación para diferentes horizontes de pronóstico, así como los resultados que se obtienen mediante métodos tradicionales lineales de pronóstico.

Finalmente, en el Capítulo 6 se da una conclusión al trabajo presentado, así como recomendaciones para el desarrollo de trabajos futuros.

## CAPÍTULO 2

# ANTECEDENTES

### 2.1 PRONÓSTICO DE SERIES DE TIEMPO.

El campo del pronóstico organizacional, nacido en los años de 1950s, ha tomado en la actualidad gran relevancia gracias a los desarrollos teóricos en estimación y predicción, tecnología más accesible, software especializado, etc. Lo anterior ha influido a su vez a incrementar la aceptación de estos métodos por parte de las organizaciones para utilizarlos en la administración de sus operaciones, así como para apoyo a la toma de decisión (Makridakis, Wheelwright, & Hyndman, 1998).

Los modelos para pronóstico de series de tiempo consisten en predecir la continuación de patrones históricos presentados en una serie de datos. Existen desde modelos muy básicos, como pueden ser los intuitivos, que carecen de fundamentos estadísticos y se basan por lo general en el conocimiento propio del sistema; hasta los métodos estadísticos formales que son realizados mediante un procedimiento más estandarizado y de manera sistemática, buscando minimizar el error de pronóstico. La selección de la metodología depende de la disponibilidad de datos históricos, el grado de exactitud deseado, el periodo de tiempo a pronosticar, la relevancia del pronóstico, la estacionalidad de la serie, la tendencia y la variabilidad de los datos, entre otros factores.

El problema de predecir series de tiempo ha sido abordado principalmente mediante la aplicación de modelos de la familia ARIMA, propuesta por Box y Jenkins (1994). En un modelo  $ARIMA(p,d,q)$ , el valor futuro de una variable se asume que tiene una relación lineal con una o varias observaciones históricas y errores aleatorios. Sin embargo, para la correcta aplicación de esta metodología en el análisis de series de

tiempo, las series deben cumplir condiciones como poseer una estructura lineal, ser estacionarias en su media y varianza constante (Makridakis, Wheelwright, & Hyndman, 1998). Si bien, mediante transformaciones de los datos se puede abordar el problema de la tendencia y la varianza, la condición de linealidad sigue siendo una limitante para esta metodología.

Las RNAs, por otro lado, han ganado popularidad debido a su potente capacidad de modelación sin necesidad de hacer supuestos *a priori* acerca de la estructura del modelo y el proceso generador de los datos, como lo hace la metodología Box-Jenkins, que asumen que la serie estudiada es generada por un proceso lineal y por lo tanto pueden ser inapropiados si los datos provienen de un proceso no lineal. Cabe destacar que en el mundo real los sistemas son comúnmente no lineales (Khashei & Bijari, 2010; Hamzaçebi, Akay, & Kutay, 2009).

Es de interés (por la similitud que se guarda con el problema de la tesis) señalar que la Competencia de Pronóstico con Redes Neuronales Artificiales e Inteligencia Computacional, en su versión *NN5* en 2008 consistió en pronosticar los retiros de efectivo en 111 cajeros automáticos ubicados en diferentes puntos de Inglaterra. La estrategia implementada utiliza herramientas de inteligencia computacional y sigue una metodología consistente. Los datos representan los retiros de efectivo por día a lo largo de 2 años, encontrándose patrones estacionales, tendencias y efectos de calendario como días feriados, eventos especiales, etc. Andrawis et al., (2011) presenta una metodología basada en promediar el pronóstico obtenido con 9 diferentes modelos, logrando el primer lugar, de 19, en una de las categorías de esta competencia.

### **2.1.1 PRONÓSTICO DE SERIES DE TIEMPO USANDO RNAs.**

Las RNAs han experimentado una considerable popularidad en años recientes. Su utilización como una herramienta de modelación se ha incrementado en áreas donde un enfoque cuantitativo puede ser usado como apoyo a la toma de decisiones (Zhang P. G., 2007). Las RNAs han sido consideradas como un método no lineal alternativo a

los modelos tradicionales para clasificación, análisis de series de tiempo y problemas de regresión.

Las RNAs han sido usadas en un amplio rango de aplicaciones, incluyendo problemas de pronóstico de series de tiempo, mostrando un desempeño alentador (Zhang & Qi, 2005). Las RNA son más flexibles y aplicables que otros métodos (Zhang, Patuwo, & Hu, 1998) y es por eso que se han utilizado para abordar problemas de pronóstico en ciencias sociales, ciencias económicas, en mercados cambiarios, ingeniería, medio ambiente, problemas de inventario, entre otros. Lapedes and Farber (1987) reportan el primer intento de modelar series de tiempo no-lineales usando redes neuronales artificiales. De Groot y Wurtz (1991) presentan un análisis detallado del pronóstico de series de tiempo univariadas usando redes neuronales de propagación hacia delante para dos series no-lineales (Khashei & Bijari, 2010). Estudios literarios más detallados son presentados en (Zhang, Patuwo, & Hu, 1998).

Aburto y Weber (2007) proponen el uso de redes neuronales en combinación con un modelo ARIMA para pronosticar la demanda de ciertos artículos en una cadena de supermercados, con el fin de mejorar la administración de la cadena de suministro. Tomando como base el flujo de datos generados por los consumidores, el supermercado tiene que decidir qué, cuánto y cuándo comprar. La solución de este problema requiere una confiable predicción de la demanda futura. En este caso los autores logran un modelo con un error de predicción del 28.80% contra el 56.83% obtenido mediante un método tradicional que la cadena de supermercados utiliza. Otras aplicaciones de RNAs se han desarrollado en relación a la administración de operaciones y han llevado a importantes ahorros en cuanto a los costos de inventario (Bansal, Vadhavkar, & Gupta, 1998).

Puesto que en aplicaciones reales es por lo general de interés pronosticar más de un periodo futuro, los estudios se han concentrado en mejorar la predicción a largo plazo (pronóstico multi-periodo). Existen dos principales metodologías para abordar este problema al usar RNAs como herramienta de pronóstico, llamadas *iterativa* y *directa*. En el método iterativo, el primer periodo subsecuente es pronosticado

utilizando la información real histórica. Después de esto, el valor estimado es utilizado como entrada para predecir el siguiente periodo. Este proceso se realiza de manera consecutiva hasta el horizonte de tiempo que se desea pronosticar. Por otro lado, con el método directo se pretenden pronosticar varios periodos consecutivos a la vez, utilizando solamente información conocida, lo que significa que la arquitectura de la RNA deberá tener tantas variables de salida como periodos se deseen predecir. Hill et al. (1996) concluye en sus resultados que el proceso iterativo lleva a mejores resultados que el método directo. Por otro lado, según Zhang (1994), el método directo brinda resultados más favorables. Hamzaçebi et al. (2009) realiza un estudio comparativo entre ambos métodos, concluyendo con base en sus resultados que el método directo lleva a mejores resultados, pero sin embargo no es posible determinar que sea mejor para todos los problemas de pronóstico de series de tiempo.

## CAPÍTULO 3

# ANÁLISIS DEL SISTEMA SUJETO A PRONÓSTICO

### 3.1 INTRODUCCIÓN.

Definir el sistema a pronosticar no siempre es una tarea sencilla, ya que involucra un profundo conocimiento de cómo se va a utilizar el pronóstico, quién lo requiere y de qué manera aporta un beneficio a la compañía u organización para la que se desarrolla el modelo. Por lo tanto, se debe tener comunicación clara con quienes estén involucrados en la administración de la información, mantenimiento de bases de datos y personas que finalmente van a utilizar los pronósticos para la planeación de operaciones.

Una vez que se ha definido el sistema, es necesario recolectar y procesar los datos para generar información. Así bien, se tiene información estadística (usualmente numérica) o información por conocimiento de personal experto. Ambos tipos son relevantes y deben ser considerados para la construcción del modelo. Es necesario recolectar información relacionada al producto o servicio que se va a pronosticar. Si los datos son recolectados a través del tiempo durante intervalos igualmente espaciados y ordenados cronológicamente, se dice que los datos forman una serie de tiempo. Los intervalos varían dependiendo de la serie a analizar, es decir, una serie de tiempo puede ser generada por segundo, minuto, hora, día, semana, mes, año o cualquier otra unidad de tiempo.

La inspección visual de los datos por medio de gráficas y sus estadísticas descriptivas son primordiales como un análisis básico, así como correlaciones o

autocorrelaciones de los datos que permitan identificar patrones en los datos. Las gráficas de cajas son herramientas útiles para observar los rangos de los datos en diferentes periodos de tiempo, así como su tendencia y observaciones inusuales. Este paso permite tener una idea más clara de qué modelo de pronóstico puede ser adecuado. Con base en lo anterior se seleccionan y construyen diferentes modelos. Para este trabajo se proponen redes neuronales con diferente arquitectura y se selecciona aquel con menor error en el ajuste del modelo.

Finalmente, una vez que se hace la selección de la metodología, se utiliza sobre la serie de tiempo seleccionada y se evalúa el desempeño conforme se tenga disponible la información real y se pueda obtener un error real del pronóstico. En este paso se decide si hay que reajustar los parámetros del modelo.

## **3.2 DESCRIPCIÓN DEL SISTEMA: LA CADENA DE SUMINISTRO DE EFECTIVO.**

La principal responsabilidad de esta entidad financiera es proveer efectivo por medio de su red de distribución a otras instituciones financieras y bancos comerciales, los cuales a su vez deben satisfacer las demandas de efectivo del público de la región. Para lograr esta tarea, dicha institución invierte importante cantidad de su presupuesto en el control de sus inventarios.

La red de distribución de efectivo se compone de una sucursal matriz en la capital del país, seis sucursales regionales y cuarenta y tres bancos corresponsales o corresponsalías. Las necesidades de efectivo de cada banco corresponsal es suministrada por un banco regional que a su vez es suministrado por la sucursal matriz. La sucursal matriz y los bancos regionales son propiedad de la entidad financiera, mientras que los bancos corresponsales son instalaciones privadas propiedad de bancos comerciales a los que se les alquila un espacio físico y se les contrata para actuar a nombre de la Institución Financiera. El rol de los

corresponsales en la red de distribución es sumamente importante. Por citar un ejemplo, en 2009 los corresponsales participaron en el 59% de la circulación de billetes y atendieron 82% de las transacciones de divisas de los bancos comerciales.

Los billetes que circulan en el país son manufacturados y suministrados por el Banco de México, quien controla la inyección de efectivo en la economía mexicana. Existen seis denominaciones para los billetes: \$20.00 MXN, \$50.00 MXN, \$100.00 MXN, \$200.00 MXN, \$500.00 MXN y \$1000.00 MXN.

La cadena de suministro comienza en la sucursal matriz y se distribuyen principalmente mediante contratación de servicios logísticos a lo largo de todo el país por vía terrestre o aérea. Primeramente se envía de la sucursal matriz hacia las sucursales regionales, quienes a su vez distribuyen hacia los bancos corresponsales. La Institución Financiera ha dividido el país en siete regiones geográficas. La sucursal matriz y las sucursales regionales tienen asignada una región específica en la cual, en conjunto con los bancos corresponsales, actúan como consignatarios para el sistema bancario de su respectiva región. Gracias a este esquema de distribución, se cubre en su totalidad el territorio nacional.

### **3.3 DESCRIPCIÓN DE LOS DATOS.**

La institución cuenta con un registro minucioso de los movimientos que se realizan en cada sucursal y corresponsal. La base de datos refleja información sobre los retiros y depósitos, respectivamente, así como el inventario disponible. Para cada uno de estos rubros existe una separación entre 'efectivo apto' y 'efectivo no apto'. El efectivo apto está representado por billetes que aún están en condiciones para circular. El no apto está representado por los billetes rotos, deteriorados u obsoletos, y una vez que es captado, es separado, contabilizado y posteriormente destruido. Los registros son realizados por denominación (\$20, \$50, \$100, \$200, \$500 y \$1000) en cantidad de billetes. La Figura 3.1 muestra un cuadro esquemático que resume la información que

se puede obtener de los registros. El registro de movimientos está dado de manera diaria y comprende un periodo de 13 años, abarcando desde el día primero del mes de enero del año 1999 hasta el día último de diciembre del año 2011, lo que resulta en una matriz de datos de 4748 renglones (número de días desde 1999 a 2011) por 6 columnas (denominaciones) solamente para la información sobre retiros de billetes. Los días sábado y domingo no se realizan operaciones en almacén, por lo que los movimientos son nulos. Esto mismo sucede en días feriados.

Para los análisis posteriores se utiliza únicamente información que corresponde a los retiros de efectivo. Primeramente se obtiene valor nominal por día, es decir, el valor que se obtiene al multiplicar el número de billetes retirado por su correspondiente denominación, como se muestra en la siguiente ecuación:

$$\text{Valor nominal} = 20W_{20} + 50W_{50} + 100W_{100} + 200W_{200} + 500W_{500} + 1000W_{1000}$$

donde  $W$  es el número de billetes retirados de cada denominación.

A través de los años los billetes de más alta denominación han incrementado su presencia desplazando a billetes de menor denominación. En la Figura 3.2 se muestra lo anterior para una sucursal representativa. Los retiros en denominación de \$500 pesos para 1999 representa un 20.9% del valor nominal retirado mientras que en 2011 es del 50.4%. El billete de \$1000, igualmente, ha acrecentado su participación desde su introducción en 2004, aunque de manera más lenta, en los últimos 7 años llega a tener una participación del 9.2%. Caso contrario sucede con los billetes de más baja denominación. El billete \$20 pesos en 1999 representa el 2.3% del valor nominal retirado, mientras que en 2011 fue de solo el 0.6%. El billete de \$50 pesos representa el 10.1% de los retiros en 1999, mientras que en 2011 es del 3.5%. En el caso del billete de \$100 pesos, en 1999 representa un 17.7%, contra un 8.8% en 2011, y el billete de \$200 pesos pasa del 49.4% en 1999 contra 27.3% en 2011. Esto muestra la tendencia a tener flujos de efectivo más grandes a través de los años y por ende, a utilizar billetes de más alta denominación.

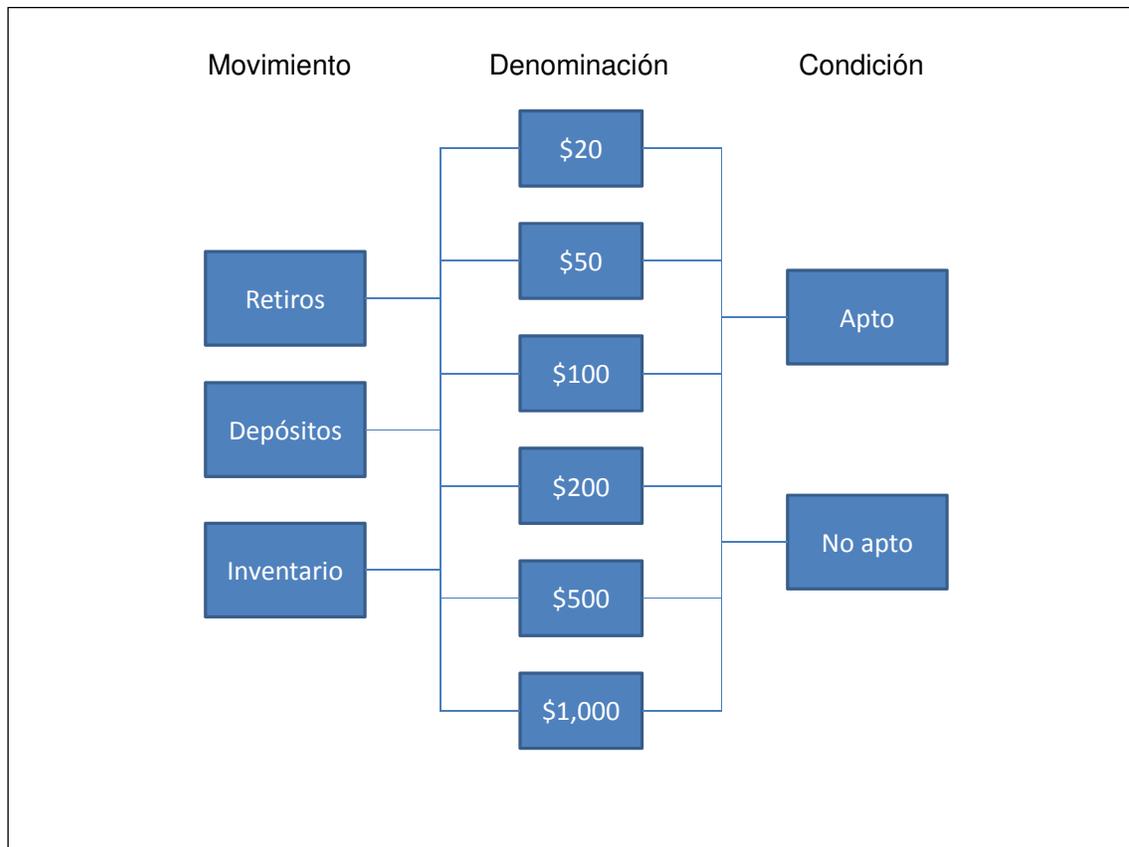


Figura 3.1- Esquema de representación de los datos.

Para el desarrollo de la metodología, se utilizan solo los datos que reflejan los retiros de efectivo. La base de datos original se pre-procesa de manera que facilite la tarea del pronóstico ya que resulta complicado realizarlo de manera diaria y por denominación debido a la alta variación que presentan los datos entre un día y otro. A la suma del monto retirado por día se le llama '*valor agregado*' en adelante. Posteriormente el valor agregado se agrupó por semana, comenzando la semana en día lunes, según el calendario, por lo que se comienza desde el día 4 de enero de 2009, no afectando esto ya que los días anteriores tienen movimientos nulos. Cada serie es agrupada por semana, quedando con 678 observaciones cada una.

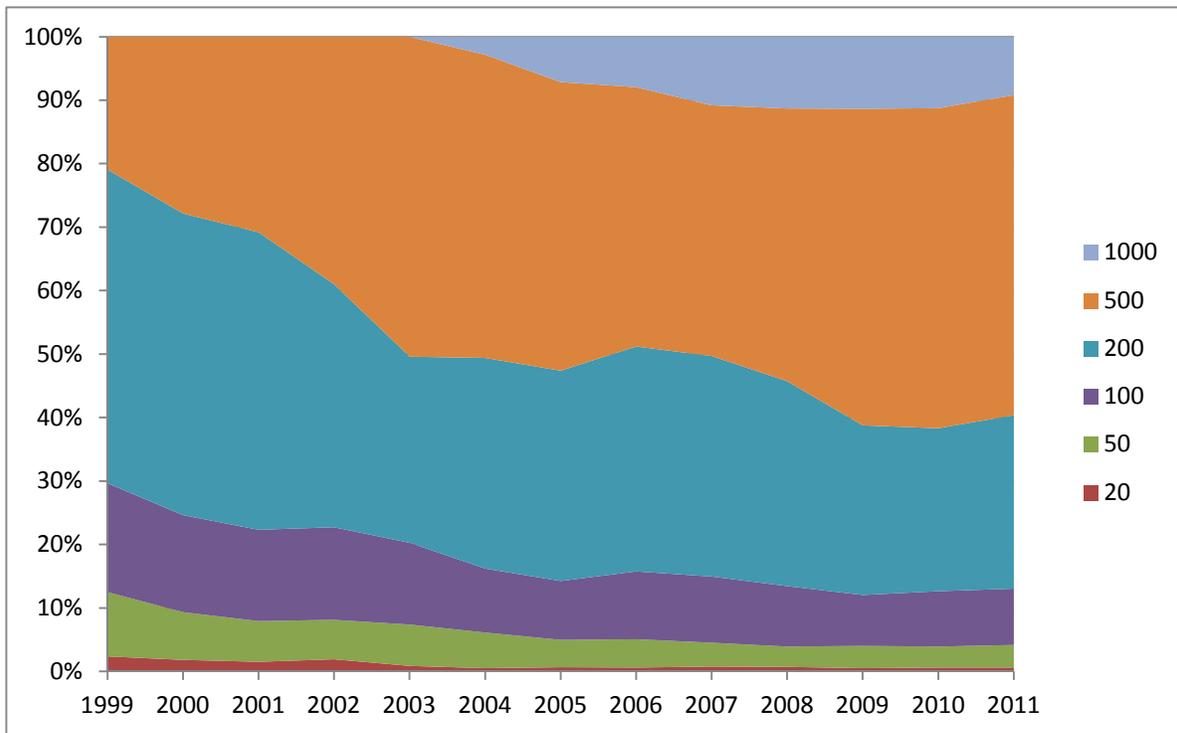


Figura 3.2 - Comportamiento de los retiros de efectivo en una sucursal.

### 3.4 ANÁLISIS ESTADÍSTICO DE LOS DATOS.

Tres series de diferentes sucursales son descritas y analizadas. Si bien los datos comprenden hasta el 31 de diciembre de 2011, para el análisis solamente se contempla hasta el 31 de diciembre de 2010, ya que todo el año 2011 es sujeto a pronóstico y el valor de los retiros en el año 2011 se considera desconocido. Los valores reales posteriormente se utilizan para evaluación del pronóstico. Para tal efecto, una vez que se tienen los datos agrupados por semana, se entiende que la semana en la posición 626 de la serie semanal corresponde a la última semana del año 2010, por lo que queda sujeto a pronóstico a partir de la semana 627 hasta la semana 678.

Las series se denominan *Serie A*, *Serie B* y *Serie C* respectivamente y se muestran en la Figura 3.3, Figura 3.4 y Figura 3.5. Las tres muestran un comportamiento similar, aunque en montos diferentes. Dado que todas reflejan retiros de efectivo, es de esperar que la demanda tenga un incremento (o decremento) en los mismos periodos

para todas las sucursales, independientemente de su ubicación geográfica. No siendo así para el monto de los retiros, donde su ubicación sí tiene influencia en la cantidad de dinero demandada, pues depende de la actividad económica de la región, así como de la cantidad de usuarios que atiende. Las estadísticas descriptivas para los montos de retiro pueden verse en la Tabla 3.1.

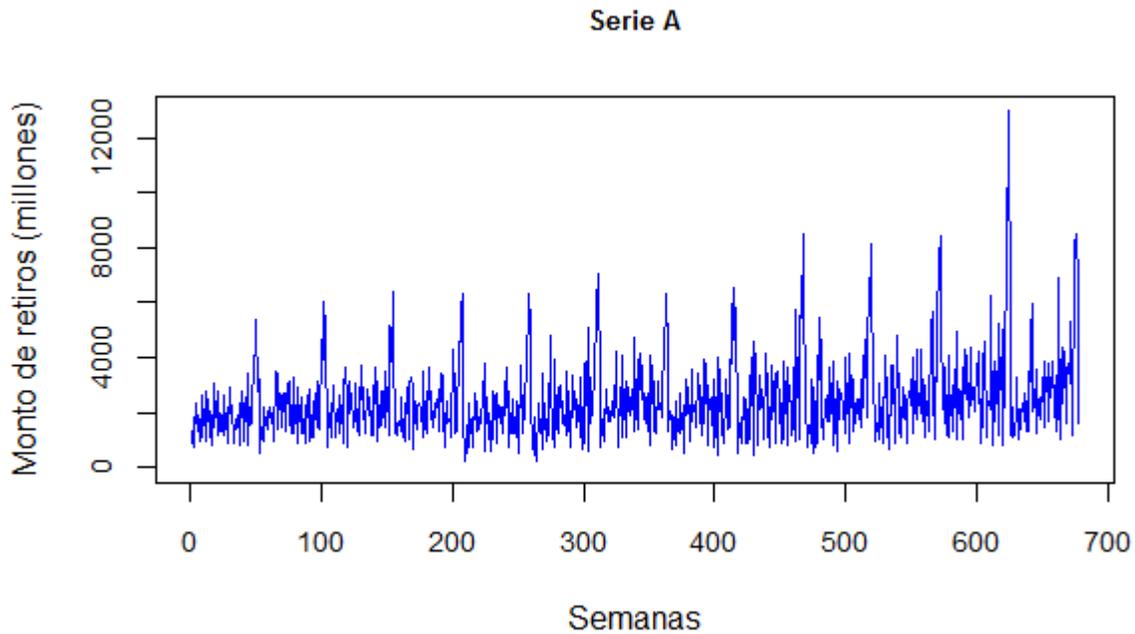


Figura 3.3 - Comportamiento de los retiros por semana desde 1999 a 2011 para la Serie A.

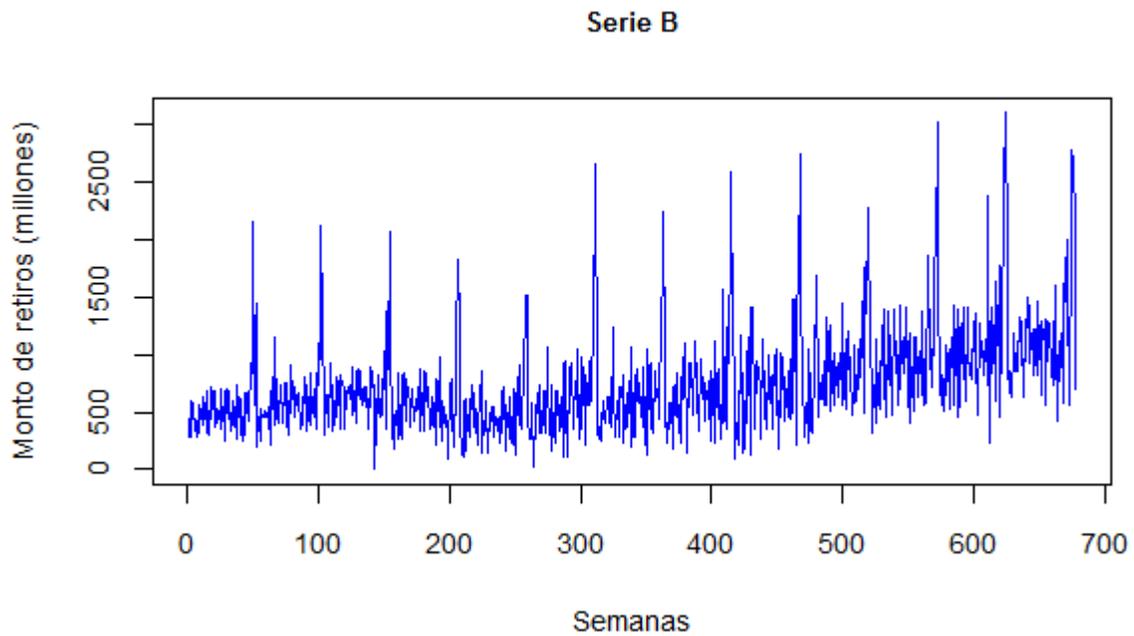


Figura 3.4 - Comportamiento de los retiros por semana desde 1999 a 2011.

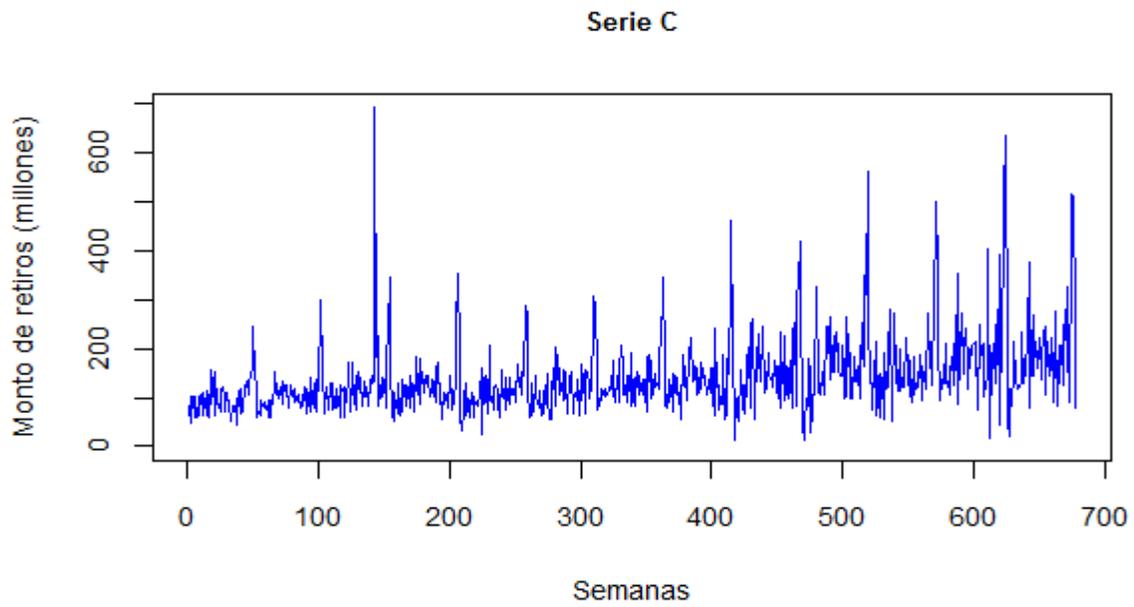


Figura 3.5 - Comportamiento de los retiros por semana desde 1999 a 2011.

Tabla 3.1 - Estadísticas descriptivas para el valor nominal de los retiros para cada serie.

Serie	Obs.	Mínimo*	1er cuartil*	Mediana*	Media*	3er cuartil*	Máximo*	Coefficiente de variación
A	626	226.5	1306	2202	2436	3150	12950	60.71%
B	626	0	412.3	624.7	718.0	884.4	3098.0	61.69%
C	626	12	96	123.1	141.5	165.9	392.3	55.35%

\*Millones de pesos

Puede notarse que existe una alta variación en los datos, sobre todo del máximo con respecto a las demás estadísticas, y es debido al incremento de demanda de efectivo que muestran las series en el periodo de diciembre. Además, estos picos se crecen en amplitud para los últimos años. Como se muestra en el gráfico de cajas de la Figura 3.6, Figura 3.7 y Figura 3.8, respectivamente, los rangos de los valores crecen al final de las series, acentuando la varianza de los datos. Asimismo, este gráfico permite observar el comportamiento de los datos a través de los años. En el caso de la *Serie A*, la media es estadísticamente igual para toda la serie, por lo que se trata de una serie estacionaria en su media. Sin embargo, en el caso de la *Serie B* y *Serie C*, se identifica una tendencia positiva, por lo tanto ambas series no son estacionarias en su media.

Además, para las tres series es perceptible que estos montos altos de retiros se repiten cada 52 semanas aproximadamente y corresponden a las últimas semanas de cada respectivo año, indicando la presencia de estacionalidad en las series. Para corroborar esto se utiliza la función de autocorrelación. Esta función se define como la correlación que tiene la serie consigo misma pero rezagada 1, 2, ...,  $n$  periodos y se obtiene mediante la fórmula:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

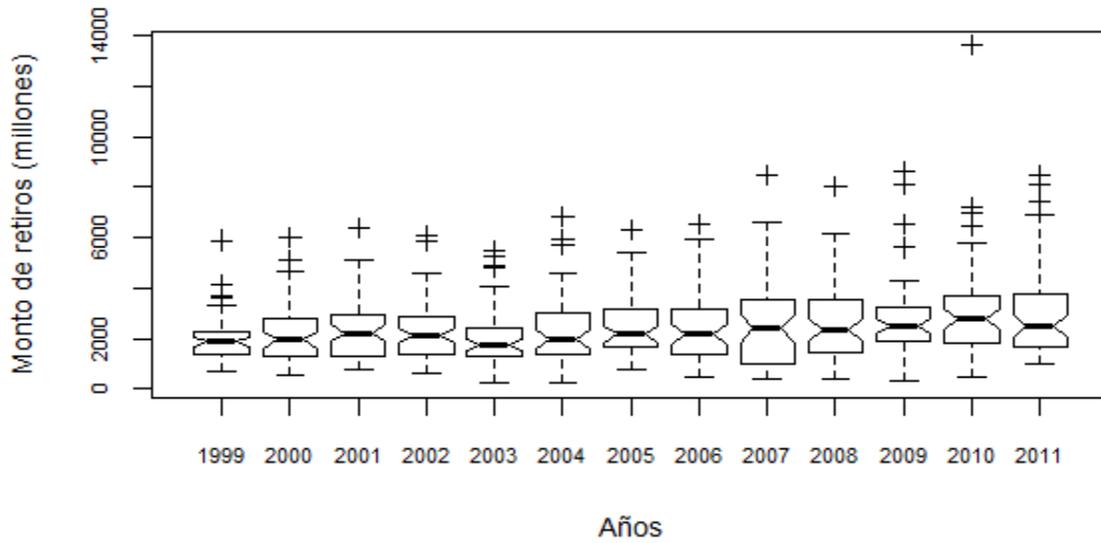


Figura 3.6 - Gráfico de cajas para los retiros por año en la Serie A.

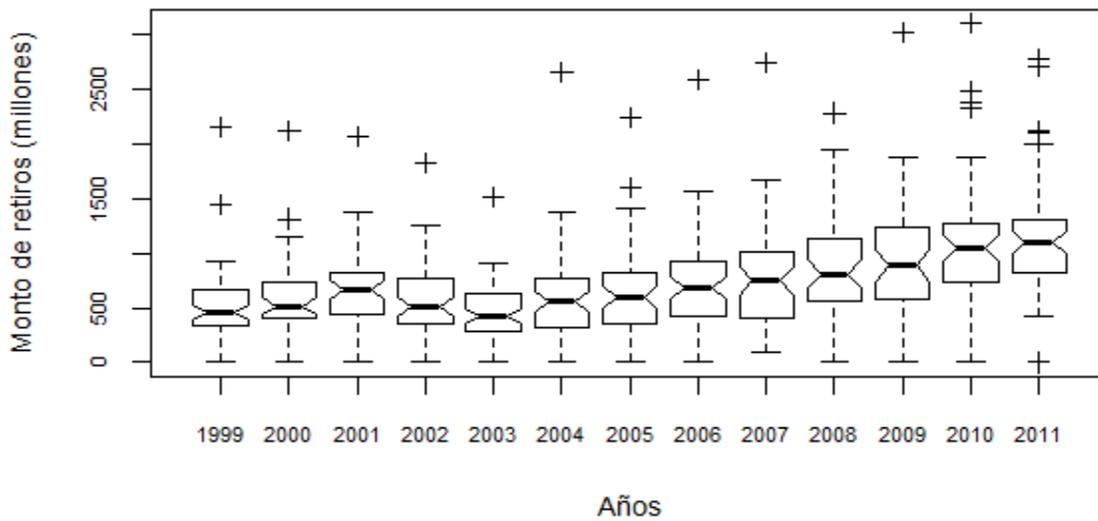


Figura 3.7 - Gráfico de cajas para los retiros por año en la Serie B.

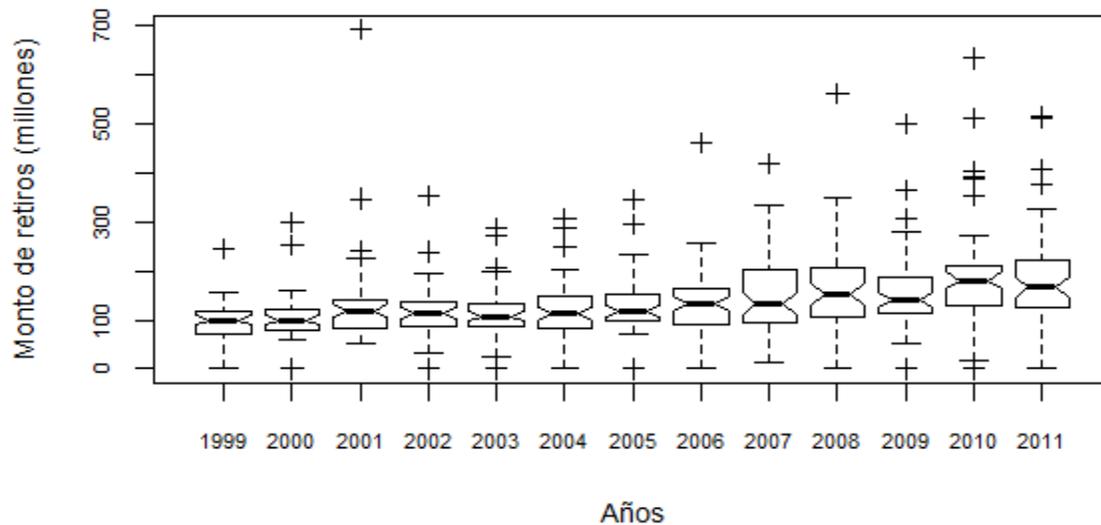


Figura 3.8 - Gráfico de cajas para los retiros por año en la Serie C.

El análisis de autocorrelación permite conocer la relación lineal que existe entre la serie al tiempo  $t$  y la serie rezagada  $k$  periodos, es decir, al tiempo  $t-k$ . La gráfica de la función de autocorrelación muestra los valores (entre 0 y 1) de correlación para cada periodo de rezago. Evidentemente, a un índice de rezago cero se obtiene el valor máximo de correlación. Considerando un intervalo de confianza del 95%, los límites están dados por  $\pm 1.96/\sqrt{n}$ , por lo cual, un valor por encima o por debajo de estos valores se considera significativo (Makridakis, Wheelwright, & Hyndman, 1998). Para este análisis, primeramente se estabiliza la varianza mediante una transformación logarítmica de los datos y para el caso de las series  $B$  y  $C$ , por ser no estacionarias, se emplea la técnica de diferenciación descrita por Box-Jenkins. La diferenciación consiste en construir una serie a partir de las diferencias que hay entre  $x_{n+1}$  y  $x_n$ , con la finalidad de obtener una serie estacionaria en su media. Los gráficos de la función de autocorrelación de cada serie se muestran en la Figura 3.9, Figura 3.10 y Figura 3.11, respectivamente.

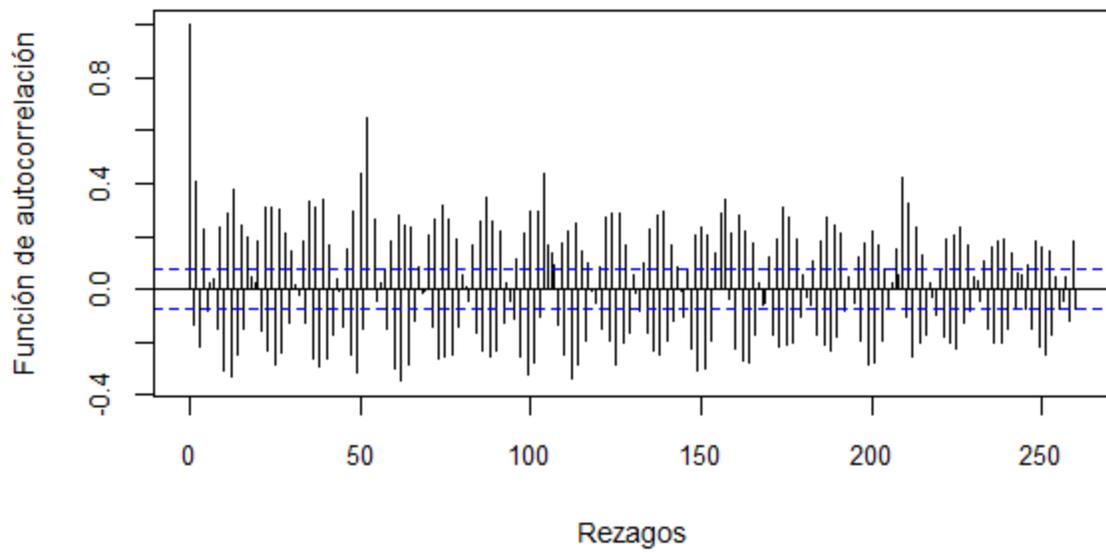


Figura 3.9 - Gráfico de la función de autocorrelación para la Serie A.

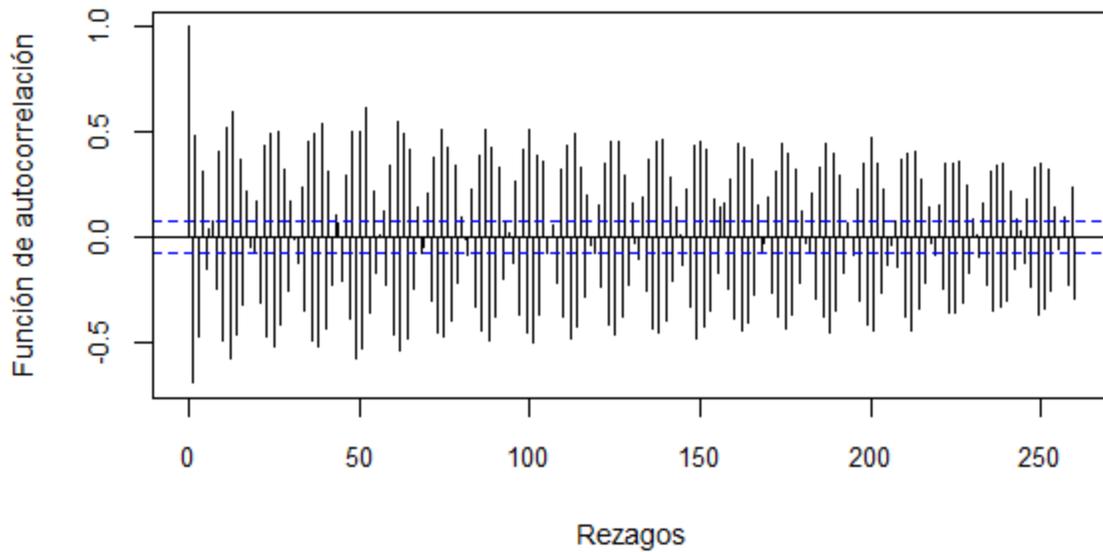


Figura 3.10 - Gráfico de la función de autocorrelación para la Serie B.

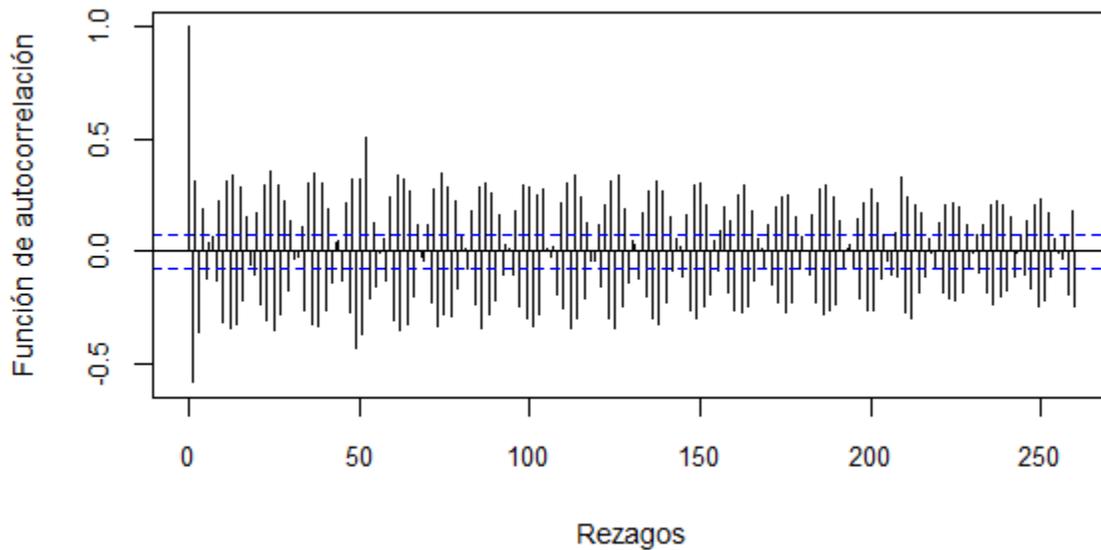


Figura 3.11 - Gráfico de la función de autocorrelación para la Serie C.

Para todas las series se obtienen múltiples valores significativos (positivos y negativos) a diferentes rezagos, sin embargo, se puede destacar que, principalmente para la *Serie A*, se distinguen valores más altos en rezagos múltiplos de 52, o cercanos a estos (en ocasiones se tienen 53 semanas en un año), indicando la estacionalidad presente en la serie. También se observa un patrón intermedio entre cada estación que se compone de 13 periodos en la *Serie B* y *Serie C*, indicando una posible estacionalidad trimestral, el cual es tomado en cuenta para la selección de regresores del modelo.

### 3.5 DEFINICIÓN DEL PROBLEMA.

El objetivo principal de este proyecto es seleccionar, evaluar y utilizar un método de pronóstico que mejor se ajuste al comportamiento de los datos históricos disponibles. Una de las técnicas de pronóstico más conocidas es la metodología ARIMA (Khashei & Bijari, 2010) que se basa en construir un modelo lineal en función de valores históricos de la serie. Sin embargo, una de las grandes desventajas es la selección de los regresores del modelo, ya que solo permite seleccionar valores

históricos consecutivos, comenzando con el valor pasado inmediato. La metodología SARIMA o *Seasonal-ARIMA* es una extensión de la metodología tradicional con especial enfoque en abordar la estacionalidad, sin embargo, además de tener la misma desventaja anteriormente mencionada, la estacionalidad se asume que se presenta exactamente en el mismo número de periodos, por lo que desfases de tiempo de uno o dos periodos afectan al momento de calcular un pronóstico.

Por lo anterior se busca una técnica que logre abordar las series de datos con suficiente precisión de pronóstico. Las RNAs son una alternativa a los métodos tradicionales que se ha vuelto popular en pronóstico de series de tiempo en áreas como finanzas, generación de energía, telecomunicaciones, ciencias ambientales, entre otras (Maier & Dandy, 2000). Werbos (1988) encuentra que una RNA entrenada mediante el algoritmo de retropropagación supera el desempeño del método Box-Jenkins.

Una de las ventajas que ofrecen los modelos de RNA se debe a la selección de los regresores, ya que pueden introducirse a criterio, además de la anteriormente mencionada capacidad de encontrar relaciones no-lineales que pudieran estar describiendo el proceso.

## CAPÍTULO 4

# METODOLOGÍA PROPUESTA

### 4.1 INTRODUCCIÓN.

Para desarrollar el pronóstico de la demanda de efectivo de una entidad financiera, el presente trabajo utiliza dos técnicas de pronóstico conocidas en la literatura: las Redes Neuronales Artificiales (RNA) y el modelo autorregresivo (AR). La primera es propuesta como la metodología principal para realizar el pronóstico, mientras que la segunda se utiliza como una herramienta para mejorar el pronóstico en periodos donde se presenta un comportamiento particular de la demanda de efectivo.

Para los análisis que se realizan en este trabajo se utiliza el software estadístico R (<http://www.r-project.org/>). Los paquetes y funciones que sirven de apoyo para realizar la labor estadística se citan en la Tabla 4.1.

En este capítulo se describe la metodología que se propone para abordar el problema de pronóstico de los retiros de efectivo en las sucursales de la Institución Financiera. Primeramente se define lo que es una RNA y el modelo autorregresivo, para después describir en la sección 4.2 cada uno de los pasos a seguir para el desarrollo de los modelos de RNA, que incluye la identificación de regresores potenciales, la selección de los regresores, la construcción de los conjuntos de entrenamiento y prueba, el ajuste de los parámetros controlables y finalmente la selección del modelo. En la sección 4.3 se propone la utilización de un modelo autorregresivo para ajustar el pronóstico en periodos del año particulares.

Tabla 4.1- Funciones de R mayormente utilizadas para el análisis.

Paquete	Funciones utilizadas	Descripción
<i>Stats</i>	<code>acf()</code>	Genera el gráfico de la función de autocorrelación.
	<code>ar()</code>	Ajusta un modelo autorregresivo.
	<code>mean()</code>	Obtiene la media de un conjunto de datos.
	<code>predict()</code>	Predecir valores acorde a una fórmula y modelo específico.
<i>Nnet</i>	<code>nnet()</code>	Ajusta un modelo de RNAs.
<i>Nortest</i>	<code>ad.test()</code>	Realiza la prueba de normalidad de Anderson-Darling.
<i>e1071</i>	<code>tune.nnet()</code>	Realiza una validación cruzada para un modelo de tipo <i>nnet</i> para ajuste de parámetros.

#### 4.1.1 RED NEURONAL ARTIFICIAL.

Una Red Neuronal Artificial es un modelo matemático inspirado en el funcionamiento de las redes neuronales biológicas. Consiste en un grupo interconectado de neuronas artificiales capaces de procesar información y modelar relaciones complejas entre variables de entrada y variables de salida. En sí, las RNAs son modelos estadísticos no lineales, considerados como aproximadoras universales de funciones, primeramente usadas para reconocimiento de patrones, clasificación y pronóstico de series de tiempo (Haykin, 1999; Bishop, 2006; Ripley B. D., 1996) en este último enfoque se concentra este trabajo. Las RNAs han sido bien aceptadas para predicción de series de tiempo ya que muestran una gran flexibilidad en su implementación. Debido a que no existe un procedimiento estándar para construir una

RNA, los regresores y sus parámetros pueden seleccionarse a criterio, lo que ofrece una ventaja sobre los métodos lineales tradicionales de pronóstico. Sin embargo, esto mismo hace que la tarea de construir la RNA no sea algo trivial.

Una de las estructuras más comunes de la RNA es la llamada Red uni-capas con conexiones hacia adelante y aprendizaje por retropropagación, representada como en la Figura 4.1. Para casos de regresión, típicamente existe solo una variable de salida  $y_t$ . La relación entre la salida  $y_t$  y las entradas  $(y_{t-1}, \dots, y_{t-p})$  tiene la siguiente representación matemática:

$$y_t = w_0 + \sum_{j=1}^q w_j \cdot g \left( w_{0j} + \sum_{i=1}^p w_{ij} \cdot y_{t-i} \right) + \varepsilon_t,$$

donde,  $w_{ij} (i=0,1,2,\dots,p, j=1,2,\dots,q)$  y  $w_j (j=0,1,2,\dots,q)$  son parámetros del modelo llamados *pesos*;  $p$  es el número de neuronas de entrada; y  $q$  es el número de neuronas en la capa oculta. La función de activación en las neuronas ocultas es la función logística, descrita como:

$$g(x) = \frac{1}{1 + e^{-x}}.$$

Por lo tanto, el modelo de RNA descrito anteriormente en efecto realiza un mapeo de observaciones pasadas de la serie hacia el valor futuro  $y_t$ , es decir:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, \mathbf{w}) + \varepsilon_t,$$

donde,  $\mathbf{w}$  es un vector de todos los parámetros y  $f(\cdot)$  es una función determinada por la estructura de la red y los pesos de sus conexiones. De esta manera, un modelo de RNA es equivalente a un modelo autoregresivo no-lineal. Los modelos son construidos con la función *nnet()* que se encuentra en el paquete *nnet* (Ripley B., 2013), que de manera predeterminada construye un modelo de RNA entrenado por

retropropagación, con una sola neurona de salida, una sola capa oculta y conexiones hacia adelante.

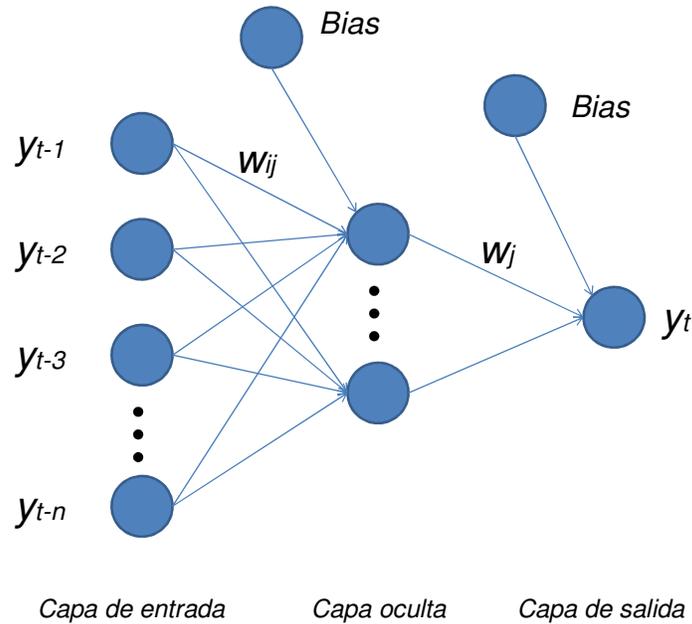


Figura 4.1 - Representación gráfica de una Red Neuronal Artificial uni-capas con conexiones hacia adelante.

#### 4.1.2 MODELO AUTORREGRESIVO.

Un modelo autorregresivo es un modelo de regresión de la forma:

$$Y = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_p Y_{t-p} + e_t$$

en donde  $Y$  es la variable a pronosticar,  $b_0$  a  $b_p$  son los coeficientes de regresión lineal,  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  son los regresores del modelo, los cuales son simplemente valores previos (rezagos) de la serie de tiempo y  $e_t$  es el error de pronóstico al tiempo  $t$ .

Este tipo de modelos pertenecen a la familia ARIMA, pero es una forma simplificada, ya que solo utilizan la parte autorregresiva, por lo que se denominan

modelos  $AR(p)$ , donde  $p$  indica el orden del modelo, es decir, el número de términos o rezagos que se incluyen en el modelo.

Una de las diferencias con un modelo de regresión tradicional es que, en los autorregresivos, el principal supuesto de independencia en los residuales puede no ser satisfecho, indicando que los rezagos incluidos en el modelo no explican de manera apropiada la variable de salida. Determinar este número de valores pasados a incluir no siempre es una tarea sencilla (Makridakis, Wheelwright, & Hyndman, 1998). Existen diversas estrategias, pero todas coinciden en buscar minimizar el error de pronóstico.

## **4.2 DESCRIPCIÓN DE LA METODOLOGÍA.**

### **4.2.1 IDENTIFICACIÓN DE REGRESORES POTENCIALES.**

Al igual que en todo modelo de regresión, la selección de las variables a incluir en el modelo de pronóstico juega un papel fundamental en su desempeño. Las RNAs tratan de encontrar una relación entre las variables de entrada y la variable de salida ajustando las ponderaciones en las conexiones de la red, por lo que los regresores que actúan como variables de entrada al modelo deben tener una relación con la variable de salida, de lo contrario no podría ajustarse un modelo apropiado.

Usualmente, el número apropiado de neuronas de entrada se espera obtener mediante prueba y error o métodos heurísticos (Hamzaçebi, Akay, & Kutay, 2009). En este trabajo, la identificación de regresores potenciales se realiza mediante un análisis de autocorrelación, como lo propone Box y Jenkins (1994) en modelos autorregresivos. Si bien este análisis no refleja relaciones no-lineales que puedan existir en el proceso, sí brinda la posibilidad de encontrar regresores potenciales que influyan linealmente de manera significativa en la variable de salida, de tal manera que deban considerarse como variables de entrada en la RNA. Se puede acceder a los valores de los coeficientes de correlación mediante el siguiente comando en R:

`acf(serie, lag.max=k)$acf`

Donde *serie* representa la variable que contiene la serie de tiempo y  $k$  es el máximo número de rezagos a considerar en el gráfico. Para un caso estacional aparecen coeficientes de correlación significativos cada  $m$  rezagos, siendo  $m$  el número de periodos que dura la estación. Para este caso de estudio se propone una mixtura de regresores entre los valores históricos y las diferencias  $x_m - x_{m-1}$  para toda  $m$ . Es decir, si se utiliza como variable de entrada el valor  $x_{t-52}$ , también se considera el valor  $x_{t-52} - x_{t-53}$ . Estas diferencias se proponen con el fin de que se encuentre una relación entre el valor al tiempo  $t-m$  y el incremento (o decremento) que tuvo la serie con respecto al periodo anterior (Reveco & Weber, 2011).

#### 4.2.2 SELECCIÓN DE LOS REGRESORES.

Una vez identificados los rezagos de cada variable de entrada se discierne entre las que aportan una mejor predicción de la variable de salida y las que no contribuyen de manera significativa. Este procedimiento es llevado a cabo mediante experimentación. La Tabla 4.2 muestra las 34 diferentes configuraciones que se someten a prueba. La columna *Rezagos* representa los rezagos no estacionales usados para construir el conjunto de entrenamiento. Se prueba con 4, 8 y 13 periodos, representando, aproximadamente, 1, 2 y 3 meses de datos históricos, respectivamente. Asimismo, los rezagos estacionales que se incluyen como variables de entrada se muestran en la columna *Rezagos estacionales*. En esta parte se toma como máximo cinco años de rezago. Finalmente, las diferencias que participan en el modelo se encuentran en la columna *Diferencias* y solamente se hace para los rezagos estacionales que forman parte de las variables de entrada.

Además de los regresores mostrados en la Tabla 4.2 se incluyen 3 variables binarias de entrada para todas las configuraciones. Una variable,  $x_{fin}=\{0,1\}$ , toma el valor de 1 cuando la semana incluye el cambio de un mes a otro, 0 en otro caso. La

variable  $x_{dic}=\{0,1\}$  toma el valor de 1 cuando la semana incluye las fechas decembrinas, 0 en otro caso. Las semanas que se marcan son las que corresponden a la semana que contiene el 25 de diciembre, así como las dos anteriores y una posterior a esta. Por su comportamiento particular, esta variable binaria le indica al modelo cuándo se espera que suceda de nuevo el evento. De la misma manera, la variable  $x_{ss}=\{0,1\}$  toma el valor de 1 cuando la semana incluye la denominada ‘Semana Mayor’ del periodo de pascua, así como la semana posterior, ya que estas dos semanas conforman el periodo vacacional de Semana Santa en el sistema educativo en México, esperando tener un comportamiento particular en la demanda de dinero. Toma el valor de 0 en caso contrario. Por lo tanto, la arquitectura de la Red Neuronal se puede representar gráficamente de manera generalizada como en la Figura 4.2.

Se construyen 10 modelos válidos para cada configuración de la red y se obtiene un promedio del error obtenido en cada ejecución. Por ‘modelo válido’ se entiende que es aquél que cumpla con el supuesto de normalidad en sus residuales. Para esto se efectúa la prueba de normalidad de Anderson-Darling mediante la función *ad.test()*. Se descarta aquella configuración que no logre alcanzar 10 modelos válidos en 100 ejecuciones. Todas las configuraciones se prueban usando como máximo 20 neuronas en la capa oculta o el número de neuronas tal que las conexiones de la red no sea superior al número de ejemplos del conjunto de entrenamiento. Posteriormente se afina mediante validación cruzada.



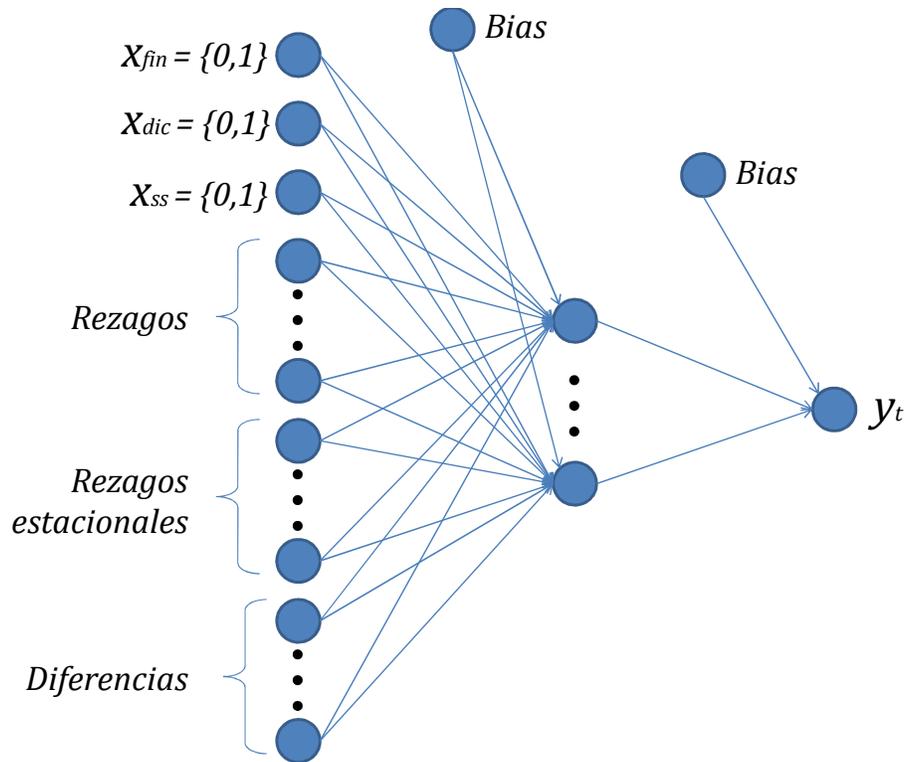


Figura 4.2 - Estructura general de RNA propuesta.

La medición del error se realiza mediante la métrica RMSE, por las siglas en inglés de Raíz Cuadrada del Error Cuadrático Medio. Es decir:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}.$$

Donde  $Y_t$  es el valor real de la serie,  $F_t$  el valor ajustado por el modelo,  $n$  es el número total de observaciones que intervienen en el modelo. Un menor RMSE indica una menor variación en los residuales del modelo ajustado.

### 4.2.3 CONSTRUCCIÓN DEL CONJUNTO DE ENTRENAMIENTO Y PRUEBA.

Cuando se tienen seleccionadas las variables de entrada al modelo, el siguiente paso es construir el conjunto que sirve que entrenamiento para la RNA así como el conjunto de prueba. Por la naturaleza de la serie, los años desde 1999 a 2010, dejando el 2011 para probar el modelo.

La arquitectura de la RNA está construida para realizar un pronóstico de un periodo a la vez (*one-step-ahead*), por lo que el pronóstico se realiza de manera iterativa. El valor del siguiente periodo es pronosticado usando el valor que se predijo anteriormente como entrada al modelo.

El pronóstico del 2011 se hace se realiza de tres maneras diferentes. Primeramente se pronostica un horizonte de tiempo de 13 semanas. Una vez que se han pronosticado, se procede a pronosticar el siguiente bloque de 13 semanas incorporando al conjunto de entrenamiento los  $h$  valores reales que se pronosticaron anteriormente y se repite el procedimiento hasta completar las 52 semanas, donde  $h$  indica el número de periodos que transcurren antes de actualizar la información del conjunto de entrenamiento. Se utilizan los valores de 1, 13 y 52 semanas.

Se utilizan tres métricas para evaluar el pronóstico: Error Absoluto Porcentual Medio, Error Absoluto Medio y Raíz Cuadrada del Error Cuadrado Medio (MAPE, MAE y RSME, respectivamente, por sus siglas en inglés) y que están definidos de la siguiente manera:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|.$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}.$$

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{(Y_t - F_t)}{Y_t} \right| \times 100.$$

Cabe destacar que la serie original es transformada mediante la función  $\sqrt[5]{X/1 \times 10^8}$  para la *Serie A* y por la función  $\sqrt[3]{X/1 \times 10^8}$  para la *Serie B* y *Serie C*, donde X es la serie en cuestión. Esto se hace con la finalidad de estabilizar la varianza. Al término del procesamiento de los datos por la RNA, el pronóstico obtenido es transformado de la manera inversa, es decir, mediante la función  $(1 \times 10^8 \cdot X)^5$  para la *Serie A* y por la función  $(1 \times 10^8 \cdot X)^3$  para las series *B* y *C*.

#### 4.2.4 AJUSTE DE LOS PARÁMETROS CONTROLABLES.

Un paso crítico en la construcción de una red neuronal artificial es la selección de los parámetros controlables. Estos parámetros son aquellos que son seleccionados, hasta cierto punto, por criterio de quien construye la RNA (i.e. el número de capas ocultas y el número de neuronas en cada capa oculta, el parámetro de decaimiento, número de neuronas de entrada, número de iteraciones). Este trabajo se enfoca en el número de neuronas en la capa oculta y el valor de decaimiento. Se utiliza solamente una capa oculta en la red, ya que una sola capa resulta suficiente para la labor de predicción (Hastie, Tibshirani, & Friedman, 2009) y las neuronas de entrada son definidas mediante la experimentación definida con anterioridad. Se estableció fijo un número de 40 iteraciones para la labor de aprendizaje. Para el ajuste de los dos parámetros restantes se utiliza la técnica de validación cruzada.

La validación cruzada es un método para estimar el error de predicción esperado cuando el modelo o método  $\hat{f}(X)$  (en este caso, la RNA) es aplicado a una muestra independiente de datos. La forma tradicional de realizar este trabajo se conoce como *K-Fold Cross-Validation*, o Validación Cruzada de *K* iteraciones. Este método

particiona de manera aleatoria el conjunto de datos disponibles para entrenamiento en  $K$  subconjuntos aproximadamente del mismo tamaño (Figura 4.3). De los  $K$  subconjuntos, uno es tomado para validación del modelo, el cual es construido a partir de los  $K-1$  subconjuntos restantes. El proceso es repetido  $K$  veces, de manera que cada subconjunto funge una vez como conjunto de validación para el modelo y al menos una vez forma parte del conjunto de entrenamiento. Los resultados obtenidos en cada iteración se combinan y producen una sola estimación. Comúnmente, un valor de 5 o 10 es usado para el parámetro  $K$  (Hastie, Tibshirani, & Friedman, 2009).

Entrenamiento	Entrenamiento	Validación	Entrenamiento	Entrenamiento
1	2	3	4	5

Figura 4.3 - Ejemplo de partición de los datos con  $K=5$ .

Para la selección de parámetros del modelo utilizando este método se determina un rango de valores que puede tomar el parámetro a ajustar. La validación cruzada realiza el proceso descrito anteriormente para cada uno de los valores especificados y determina con cuál se obtuvo el menor error. Para lo anterior primero se define y construye el conjunto de entrenamiento de la RNA. La validación cruzada se desarrolla con ayuda de la función `tune.nnet()` que contiene el paquete `e1071` (Meyer, Dimitriadou, Hornik, Weingessel, & Leisch, 2013) en el software R, indicando el rango de neuronas escondidas a probar, así como el rango de valores que debe tomar el parámetro de decaimiento. En este trabajo, el rango de neuronas se selecciona entre 10 y 20, sin permitir que exista mayor número de conexiones que de ejemplos en el conjunto de entrenamiento y evitar el sobreajuste (Foix & Weber, 2007). Para el parámetro de decaimiento se utilizan los valores 0.001, 0.005 y 0.01.

#### 4.2.5 SELECCIÓN DEL MODELO.

El proceso de entrenamiento de una red neuronal no es un proceso determinista, por lo que la construcción de un solo modelo no es algo eficiente. En este trabajo se construyeron 10 modelos con la misma configuración, pero inicializando los pesos de los arcos en diferentes valores aleatorios. De esta manera se pretende explorar de manera más amplia el espacio de búsqueda.

Para evitar seleccionar un modelo posiblemente sobre-ajustado en sus parámetros o que contenga errores de pronóstico inusuales, se propone promediar los valores de pronóstico obtenidos con cada uno de los 10 modelos construidos y ofrecerlo como pronóstico final (Ripley B. D., 1996).

### 4.3 AJUSTE DE PRONÓSTICO EN PERIODOS CLASIFICADOS.

Al tratarse de semanas del año, se pueden identificar en la serie eventos que se espera que sucedan por conocimiento previo, tal como las fechas decembrinas y de Semana Santa. Las primeras se presentan en la misma semana año con año, presentando valores hasta más del 40% mayor que el promedio del resto del año y tienen un comportamiento particular que no depende de las semanas anteriores, sino de las mismas semanas en años anteriores, por lo que la RNA logra capturar estas variaciones al usar los regresores apropiados. Para el periodo de Semana Santa, por el contrario, no siempre se presentan en la misma semana del año, inclusive pueden presentarse en diferente mes, lo que dificulta ser pronosticadas con exactitud mediante un modelo que utiliza como regresores los valores de años anteriores.

Por lo anterior, se propone llevar a cabo un ajuste del pronóstico que realiza la red neuronal para estos periodos. Se propone un modelo autorregresivo (AR) ajustado mediante mínimos cuadrados ordinarios. Se identifica la semana que contiene los días festivos de la Semana Santa (considerada la ‘Semana Mayor’). A partir de esta semana se toma una antes y una después, seleccionando 3 semanas para cada año,

resultando en una serie de 39 datos, de los cuales 36 son usados para construir el modelo y se pronostica el valor de los últimos 3. Se selecciona el orden del modelo que minimice el Error Cuadrado Medio de los residuales, probando de 1 hasta 12 términos sugeridos por la función de autocorrelación. Los valores obtenidos para estas tres semanas se reemplazan por los correspondientes en el pronóstico obtenido con las RNAs.

## CAPÍTULO 5

# EXPERIMENTACIÓN Y RESULTADOS

### 5.1 SELECCIÓN DE VARIABLES DE ENTRADA.

Los modelos de RNA fueron construidos utilizando el siguiente comando:

```
nnet(train_inputs, train_output, size, decay, linout=TRUE, maxit=40,  
      MaxNWts=nrow(train_set)-size)
```

en donde *train\_inputs* se refiere a las variables de entrada del conjunto de entrenamiento, *train\_output* indica el valor de salida en el conjunto de entrenamiento, *size* y *decay* se refieren a los parámetros de neuronas en la capa oculta y valor de decaimiento, respectivamente. En *linout* se especifica si el valor de salida se le debe aplicar la función lineal, para este caso debe hacerse para tener un valor de salida con las mismas unidades que las variables de entrada. En *maxit* se especifica el máximo número de iteraciones para el proceso de aprendizaje y finalmente *MaxNWts* determina el máximo número de conexiones (pesos) permitidas, las cuales no deben superar el número de ejemplos en el conjunto de entrenamiento.

Con base al promedio del RMSE obtenido en los 10 modelos válidos construidos para cada configuración se selecciona la configuración con la cual se obtiene la menor desviación de los residuales, quedando para la *Serie A* la configuración 12, para la *Serie B* y *Serie C* la configuración 7. En la Tabla 5.1 se resalta en amarillo los rezagos que incluye cada una de las configuraciones seleccionadas. Los resultados obtenidos en la experimentación se muestran en la Tabla 5.2, Tabla 5.3y Tabla 5.4. La columna N representa las neuronas usadas en la capa oculta. Se observa que resultan factibles las configuraciones que incluyen rezagos de

por lo menos 3 años, indicando que los rezagos estacionales tienen una influencia más favorable durante el aprendizaje que los rezagos no estacionales.

Tabla 5.1 - Neuronas de entrada seleccionadas para cada serie.

Serie	Rezagos													Rezagos estacionales					Diferencias				
	1	2	3	4	5	6	7	8	9	10	11	12	13	52	104	156	209	261	52	104	156	209	261
A	•	•	•	•										•	•	•	•	•	•	•	•	•	•
B	•	•	•	•										•	•	•	•	•					
C	•	•	•	•										•	•	•	•	•					

Para la *Serie A* se tienen 10 modelos que tienen como entrada 4 rezagos no estacionales y 5 rezagos estacionales con sus respectivas diferencias. Para la *Serie B* y *Serie C* se construyen los modelos usando 4 rezagos no estacionales y 5 estacionales sin sus diferencias. Agregando las 3 variables binarias que participan en todos los modelos, se tienen 10 modelos con:

- 17 neuronas de entrada para pronosticar la *Serie A*,
- 12 neuronas de entrada para pronosticar la *Serie B*,
- 12 neuronas de entrada para pronosticar la *Serie C*.

Nótese que para todos los casos se obtiene un mejor desempeño de los modelos cuando se incluyen los 5 rezagos estacionales, lo que corrobora la correlación existente entre los diferentes años y por lo tanto influyen significativamente en la variable de salida.

Tabla 5.2 - RMSE de los residuales para cada configuración en la Serie A.

Config.	N	MAPE	Config.	N	MAPE	Config.	N	MAPE
<b>1</b>	20	23276.34	<b>13</b>	20	22955.85	<b>25</b>	20	-
<b>2</b>	20	-	<b>14</b>	20	-	<b>26</b>	20	-
<b>3</b>	20	-	<b>15</b>	20	-	<b>27</b>	19	-
<b>4</b>	20	-	<b>16</b>	20	-	<b>28</b>	18	-
<b>5</b>	20	-	<b>17</b>	20	-	<b>29</b>	15	22659.22
<b>6</b>	20	-	<b>18</b>	19	22744.56	<b>30</b>	20	-
<b>7</b>	20	-	<b>19</b>	20	-	<b>31</b>	20	-
<b>8</b>	20	-	<b>20</b>	20	-	<b>32</b>	16	-
<b>9</b>	20	-	<b>21</b>	20	-	<b>33</b>	16	23505.56
<b>10</b>	20	-	<b>22</b>	18	22713.81	<b>34</b>	13	24029.01
<b>11</b>	20	-	<b>23</b>	15	23270.50			
<b>12</b>	18	22498.50	<b>24</b>	20	22986.48			

Tabla 5.3 - RMSE de los residuales para cada configuración en la Serie B.

Config.	N	MAPE	Config.	N	MAPE	Config.	N	MAPE
<b>1</b>	20	-	<b>13</b>	20	-	<b>25</b>	20	-
<b>2</b>	20	-	<b>14</b>	20	-	<b>26</b>	20	-
<b>3</b>	20	-	<b>15</b>	20	-	<b>27</b>	19	567.68
<b>4</b>	20	-	<b>16</b>	20	548.87	<b>28</b>	18	541.55
<b>5</b>	20	-	<b>17</b>	20	576.47	<b>29</b>	15	567.23
<b>6</b>	20	554.62	<b>18</b>	19	657.59	<b>30</b>	20	-
<b>7</b>	20	531.37	<b>19</b>	20	-	<b>31</b>	20	-
<b>8</b>	20	-	<b>20</b>	20	-	<b>32</b>	16	587.10
<b>9</b>	20	-	<b>21</b>	20	573.78	<b>33</b>	16	574.81
<b>10</b>	20	606.15	<b>22</b>	18	594.31	<b>34</b>	13	591.89
<b>11</b>	20	585.15	<b>23</b>	15	578.98			
<b>12</b>	18	567.23	<b>24</b>	20	-			

Tabla 5.4 - RMSE de los residuales para cada configuración en la Serie C.

Config.	N	MAPE	Config.	N	MAPE	Config.	N	MAPE
<b>1</b>	20	-	<b>13</b>	20	-	<b>25</b>	20	-
<b>2</b>	20	-	<b>14</b>	20	-	<b>26</b>	20	-
<b>3</b>	20	-	<b>15</b>	20	-	<b>27</b>	19	-
<b>4</b>	20	-	<b>16</b>	20	-	<b>28</b>	18	-
<b>5</b>	20	-	<b>17</b>	20	-	<b>29</b>	15	-
<b>6</b>	20	-	<b>18</b>	19	-	<b>30</b>	20	-
<b>7</b>	20	-	<b>19</b>	20	-	<b>31</b>	20	0.0474
<b>8</b>	20	-	<b>20</b>	20	-	<b>32</b>	16	-
<b>9</b>	20	-	<b>21</b>	20	-	<b>33</b>	16	-
<b>10</b>	20	-	<b>22</b>	18	0.0601	<b>34</b>	13	-
<b>11</b>	20	-	<b>23</b>	15	-			
<b>12</b>	18	NA	<b>24</b>	20	NA			

## 5.2 AJUSTE DE PARÁMETROS CONTROLABLES.

Para el proceso de ajuste de los parámetros controlables se utiliza la técnica de validación cruzada utilizando el siguiente comando en R:

```
tune.nnet(Output~., data=train.data, size=c(10:20), decay=c(0.001, 0.005, 0.01))
```

Donde *Output~.* hace referencia a que la columna de la matriz de entrenamiento que representa la variable de salida, y el resto de las columnas son las variables de entrada. *Size* es el parámetro que indica el número de neuronas en la capa oculta que se van a utilizar, en este caso un rango de 10 a 20. De la misma manera, *decay* hace referencia al parámetro de decaimiento para el algoritmo de entrenamiento, para este caso se prueban los valores 0.001, 0.005 y 0.01.

Al terminar de ejecutar la instrucción, R reporta los valores que resultaron con mejor desempeño durante el proceso de validación, realizando un total de diez muestreos para cada combinación. Los resultados se muestran en la Tabla 5.5.

Tabla 5.5 - Valor de los parámetros controlables.

<b>Serie</b>	<b>Neuronas en capa oculta</b>	<b>Valor de decaimiento</b>
A	13	0.001
B	20	0.001
C	18	0.001

Con esto se define la estructura de la red neuronal, pues cada neurona de entrada está conectada con las neuronas en la capa oculta y estas a su vez con la neurona de salida. Además, se agrega la neurona umbral que se conecta con cada una de las neuronas en la capa oculta y con la neurona de salida. Por lo tanto, tenemos finalmente la arquitectura de los modelos como se muestran en la Tabla 5.6

### 5.3 SELECCIÓN DEL MODELO.

Una vez determinadas las variables de entrada y las neuronas en la capa oculta, se realiza el pronóstico de las series como se describió en la metodología propuesta. Las gráficas de la Figura 5.1, Figura 5.2 y Figura 5.3 muestran la comparación entre la serie real y el pronóstico para el año 2011. La Tabla 5.7 muestra los errores con las tres métricas descritas anteriormente para cada horizonte de pronóstico evaluado.

Tabla 5.6 - Arquitectura de los modelos de RNA.

<b>Serie</b>	<b>Neuronas de entrada</b>	<b>Neuronas en capa oculta</b>	<b>Neuronas de salida</b>	<b>Conexiones</b>
A	17	13	1	248
B	12	20	1	281
C	12	18	1	253

Tabla 5.7 - Error de pronóstico del 2011.

<b>Horizonte de pronóstico</b>	<b>Serie</b>	<b>MAE*</b>	<b>RMSE*</b>	<b>MAPE</b>
1	A	683.92	1023.08	24.64%
	B	169.38	228.74	15.54%
	C	42.26	58.92	25.86%
13	A	694.97	1070.36	25.30%
	B	179.59	237.59	16.50%
	C	41.61	61.62	26.64%
52	A	696.28	1078.74	25.27%
	B	181	236.29	16.91%
	C	40.81	60.66	26.35%

\*Millones

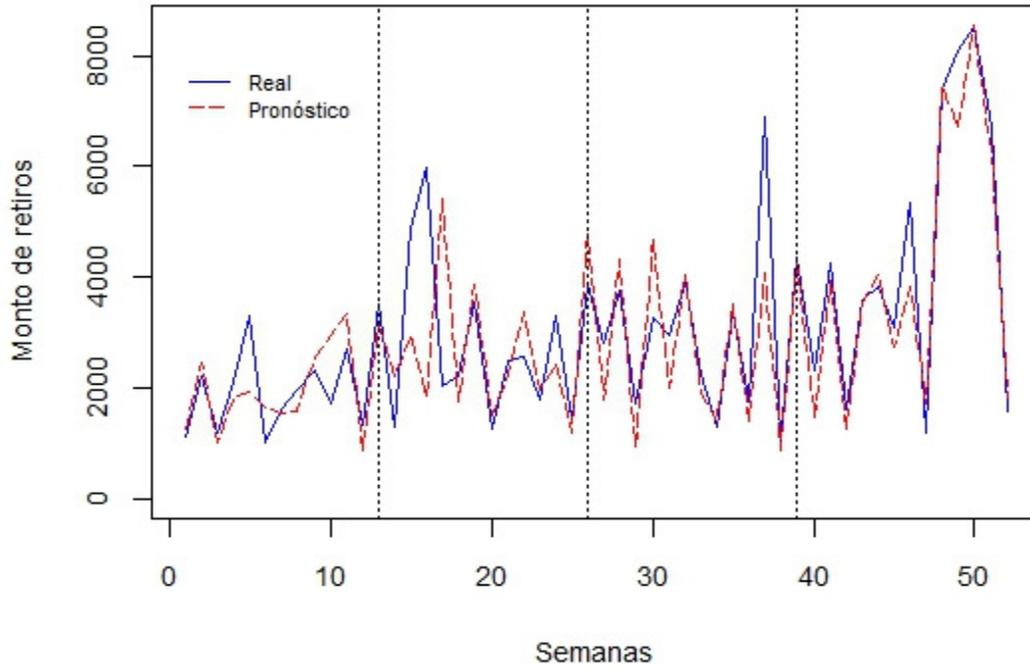


Figura 5.1 - Pronóstico 2011 para la Serie A.

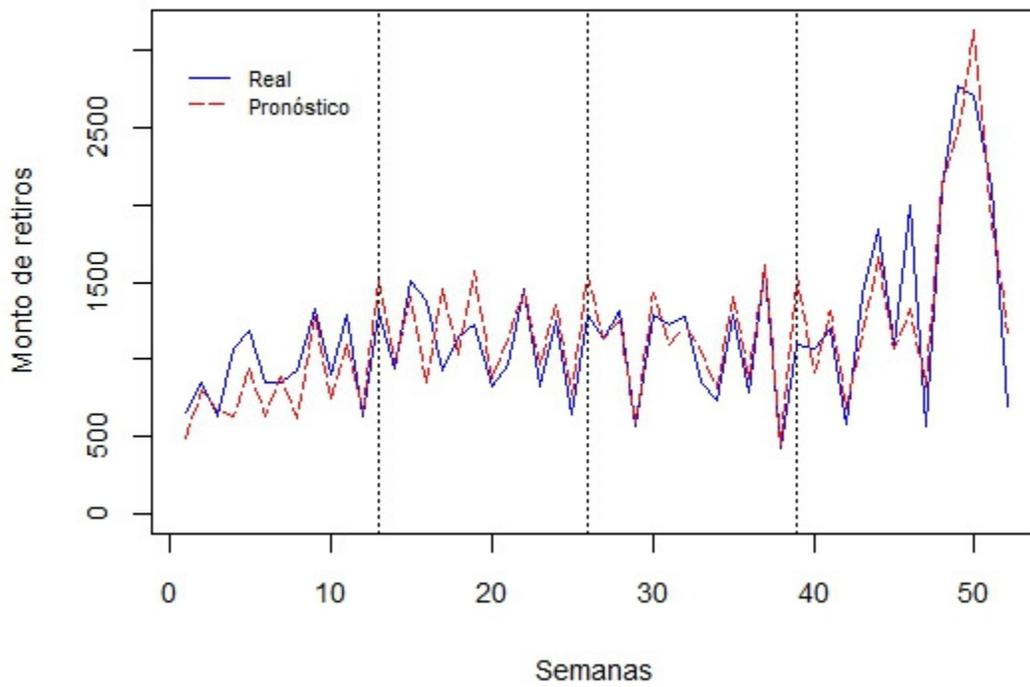


Figura 5.2 - Pronóstico 2011 para la Serie B.

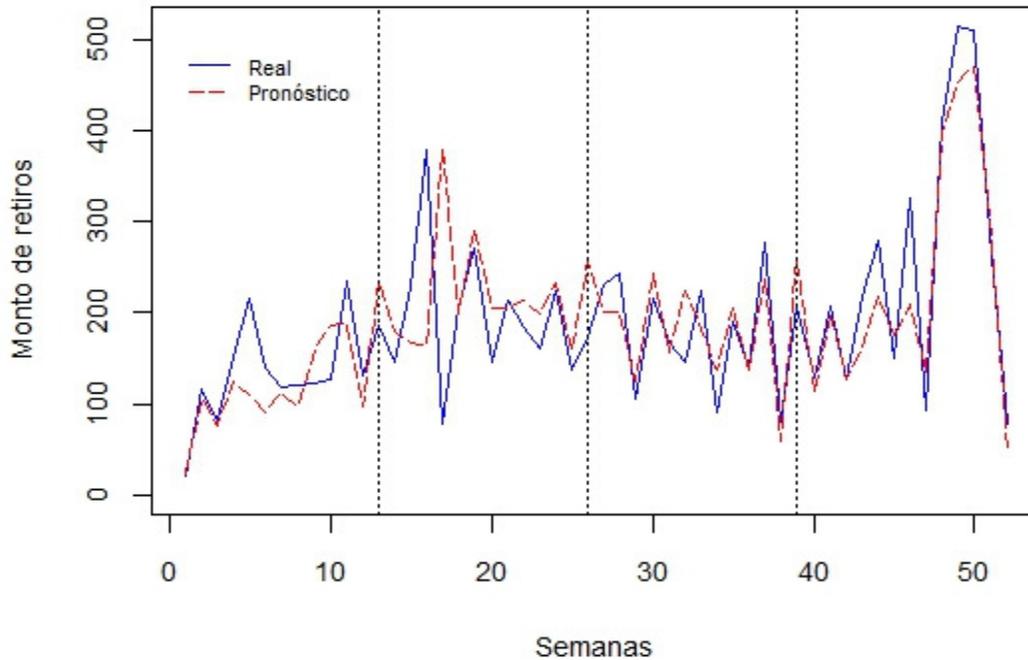


Figura 5.3 - Pronóstico 2011 para la Serie C.

#### 5.4 AJUSTE DE PRONÓSTICO EN PERIODOS CLASIFICADOS.

El pronóstico de las semanas correspondientes al periodo de pascua se muestran en la Figura 5.4, Figura 5.5 y Figura 5.6, respectivamente. Se introducen los primeros 36 valores de la serie para la construcción del modelo autorregresivo, el cual se construyó con el siguiente comando en R:

```
ar.ols(serie, aic=FALSE, order.max=order)
```

Donde *serie* se refiere al objeto que contiene las observaciones y *aic* con valor de 'FALSE' indica que el modelo no se va a construir usando el Criterio de Akaike, sino que se va a seleccionar el orden manualmente, especificándolo en *order.max*. Mediante experimentación se seleccionó el orden del modelo que tuviera menor error cuadrado en los residuales. Para el caso de la *Serie A*, el menos error cuadrado en los residuales se obtiene construyendo un modelo autorregresivo de orden 10, es decir, utilizando los últimos 10 valores de la serie. De igual forma para la serie B y C, los modelos se

construyen con utilizando las últimas 4 y 7 observaciones, respectivamente. La Tabla 5.8 muestra el orden seleccionado para cada serie.

Tabla 5.8 - Orden del modelo seleccionado para cada serie.

<b>Serie</b>	<b>Orden del modelo</b>
A	AR(10)
B	AR(4)
C	AR(7)

Con la función *predict()* se pronosticaron tres valores hacia delante de la siguiente manera:

```
predict(ar.model, n.ahead=3)
```

Donde *ar.model* es el objeto que contiene al modelo de tipo *ar* construido previamente y *n.ahead* indica el número de observaciones hacia adelante que se desean a predecir. Se puede acceder directamente a los valores pronosticados mediante:

```
predict(ar.model, n.ahead=3)$pred
```

Los valores pronosticados para las semanas de pascua obtenidos se reemplazan por los obtenidos con las RNAs. Cabe destacar que el valor real de las 3 semanas pronosticadas se consideran desconocidas, y por lo tanto no interfieren en la construcción del modelo autorregresivo. Por ende, se puede presentar el caso en que la predicción obtenida mediante las RNAs tenga una mejor predicción que el ajuste, como es para el caso de la Serie B. Sin embargo, mucho interfiere en este tipo de periodos el conocimiento previo del tomador de decisiones. La Figura 5.7, Figura 5.8 y Figura 5.9 muestran el pronóstico ajustado para cada una de las series y la Tabla 5.9 muestra los nuevos valores para las métricas de error de pronóstico.

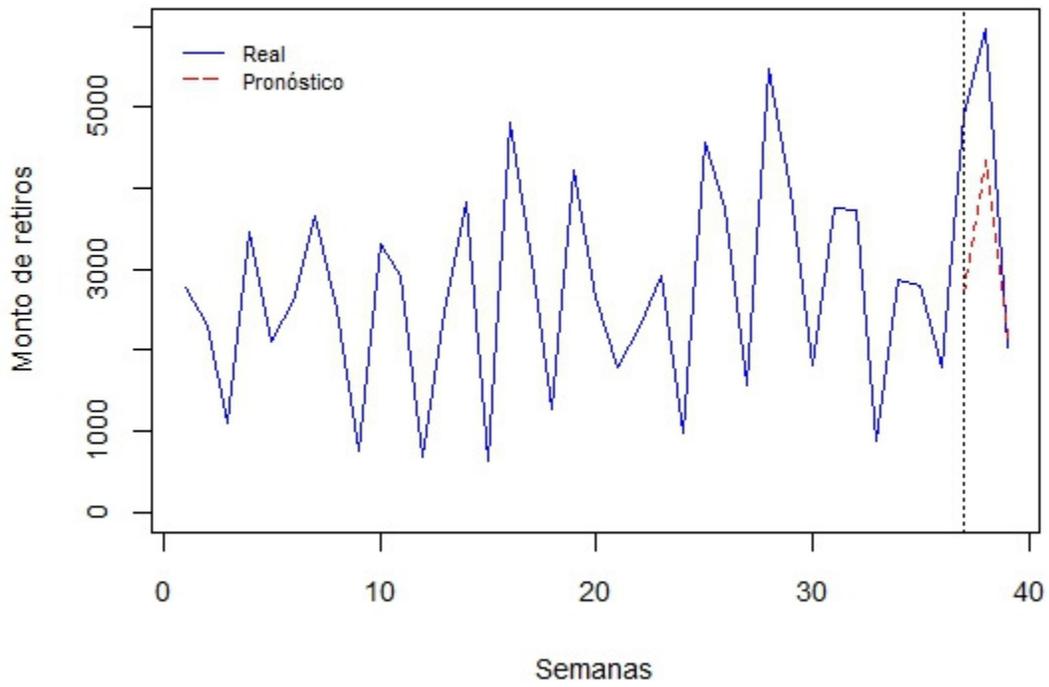


Figura 5.4 - Pronóstico de periodo de pascua en 2011 para la Serie A.

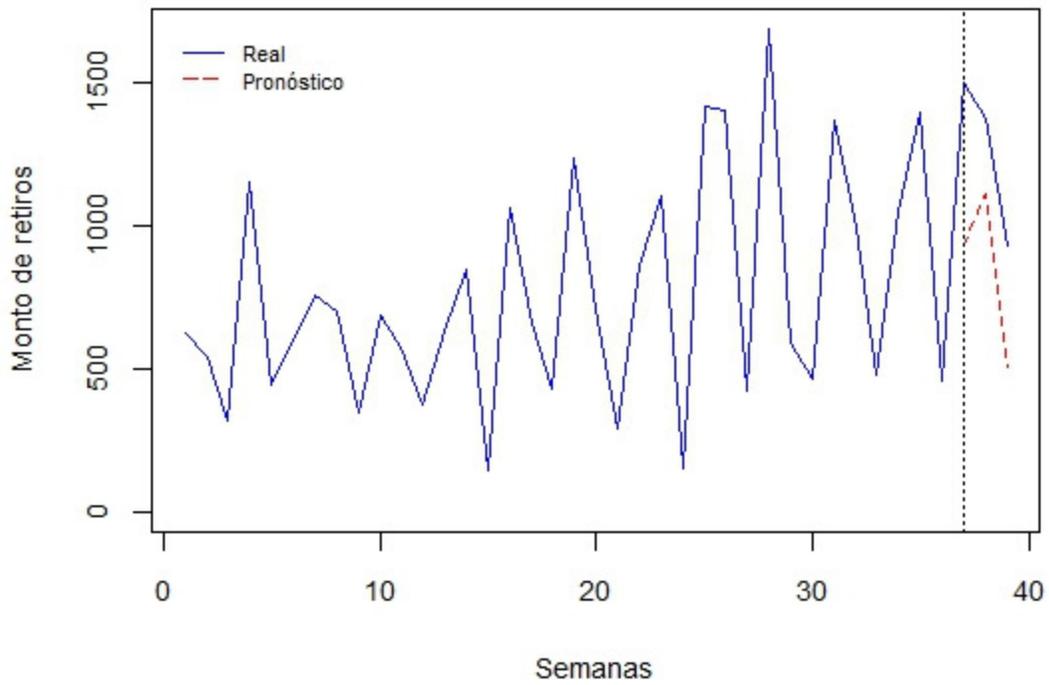


Figura 5.5 - Pronóstico de periodo de pascua en 2011 para la Serie B.

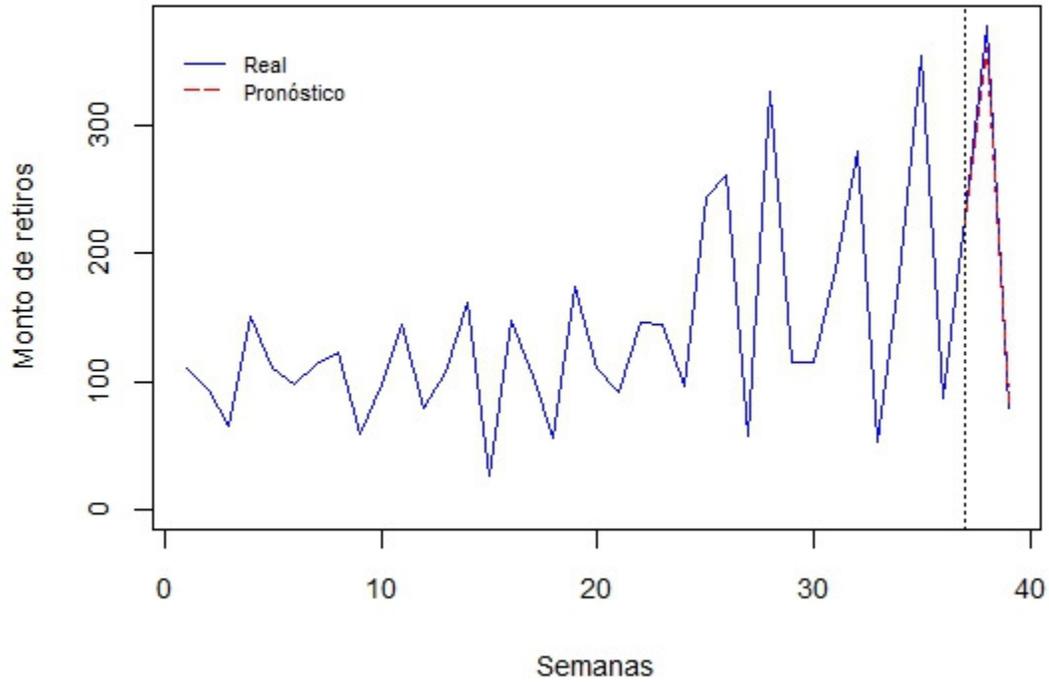


Figura 5.6 - Pronóstico de periodo de pascua en 2011 para la Serie C.

Tabla 5.9 - Error de pronóstico ajustado para 2011.

<b>Horizonte de pronóstico</b>	<b>Serie</b>	<b>MAE*</b>	<b>RMSE*</b>	<b>MAPE</b>
1	A	595.61	826.59	21.55%
	B	171.09	228.10	15.51%
	C	34.14	43.44	19.33%
13	A	589.25	821.10	21.53%
	B	181.46	237.74	16.51%
	C	32.12	41.50	18.65%
52	A	587.53	820.23	21.46%
	B	186.08	240.59	17.17%
	C	32.08	41.67	18.70%

\*Millones

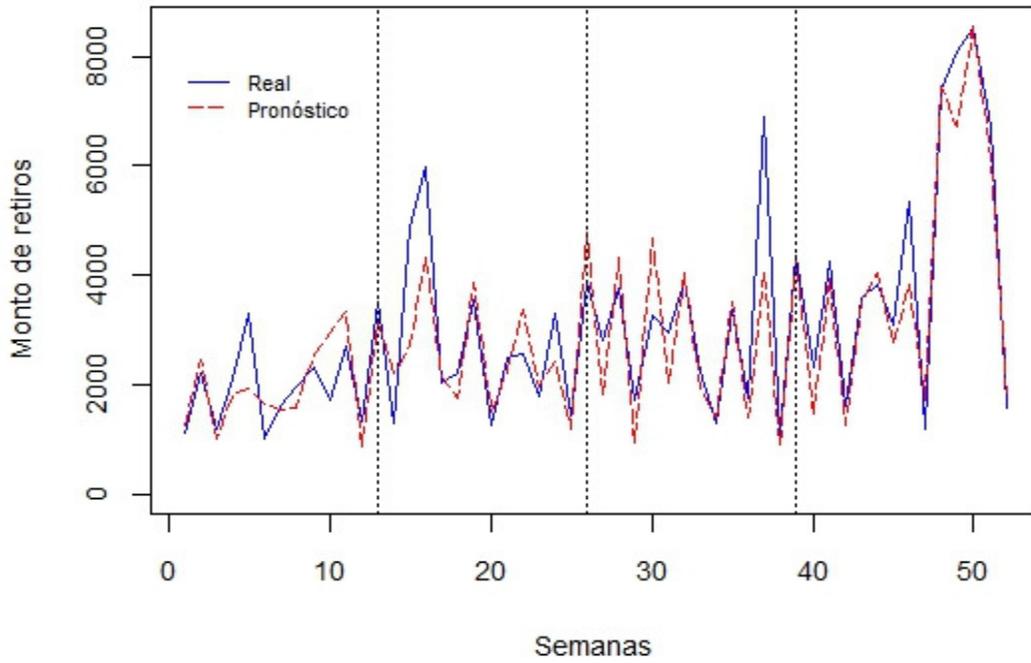


Figura 5.7 - Pronóstico ajustado de 2011 para la Serie A.

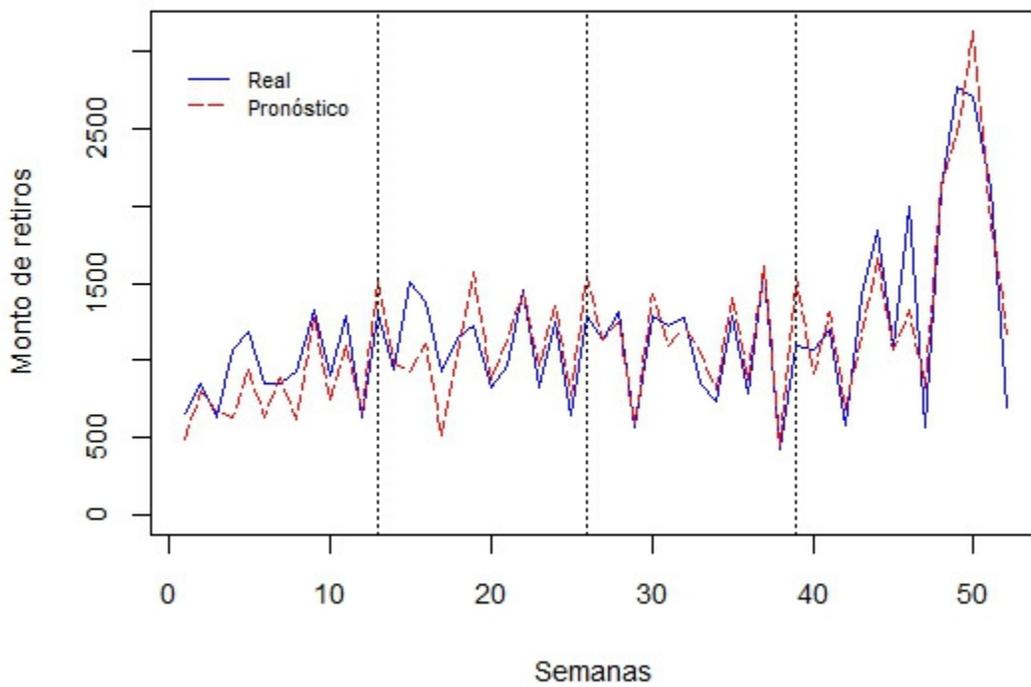


Figura 5.8 - Pronóstico ajustado de 2011 para la Serie B.

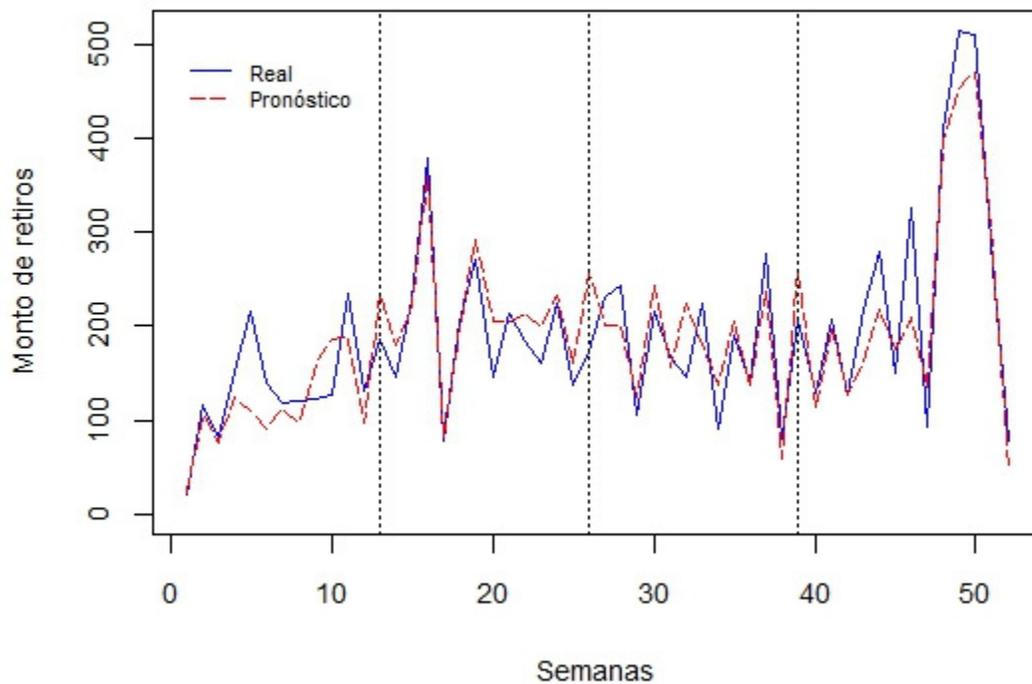


Figura 5.9 - Pronóstico ajustado de 2011 para la Serie C.

## 5.5 COMPARACIÓN DE RESULTADOS OBTENIDOS.

En esta sección se presentan resultados del pronóstico del retiro de efectivo utilizando modelos ARIMA para comparar los resultados obtenidos con ambas técnicas. Para esto, se pronostican los mismos horizontes de tiempo con el fin de comparar apropiadamente la capacidad de predicción a 1, 13 y 52 semanas adelante.

Se construye un modelo ARIMA para cada una de las series. Por la naturaleza de los datos, los modelos son estacionales (*Seasonal-ARIMA*), además de que incluir al modelo una serie binaria como regresor externo, que al igual que se hace con la RNA, indica con 1 si la semana incluye fin de mes, 0 en otro caso.

Los modelos que se utilizan son construidos mediante la ayuda del software R y se muestran en la Tabla 5.10 y en la Tabla 5.11 se muestra el error de pronóstico obtenido con cada modelo para cada horizonte de tiempo evaluado. Al igual que se

hizo para las RNAs, se ajustó el pronóstico en el periodo de pascua usando los mismos valores que se obtuvieron en la sección anterior.

Tabla 5.10 - Orden del modelo seleccionado para cada serie.

<b>Serie</b>	<b>Orden del modelo</b>
A	ARIMA(4, 0, 0)(1, 0, 0) <sub>52</sub>
B	ARIMA(2, 0, 1)(1, 1, 0) <sub>52</sub>
C	ARIMA(4, 0, 2)(1, 1, 0) <sub>52</sub>

Las gráficas de la Figura 5.10, Figura 5.11 y Figura 5.12 muestran la comparación de los valores reales del año 2011 contra el pronóstico obtenido al predecir en bloques de 13 semanas.

Tabla 5.11 - Error de pronóstico ajustado para 2011 utilizando ARIMA.

<b>Horizonte de pronóstico</b>	<b>Serie</b>	<b>MAE*</b>	<b>RMSE*</b>	<b>MAPE</b>
1	A	1018.37	1416.482	35.21%
	B	279.77	376.09	23.39%
	C	53.81	72.22	37.63%
13	A	1155.643	1437.68	45.29%
	B	304.36	392.87	27.20%
	C	50.48	70.48	37.56%
52	A	1101.38	1397.84	43.96%
	B	289.42	385.96	25.74%
	C	50.58	69.93	37.39%

\*Millones

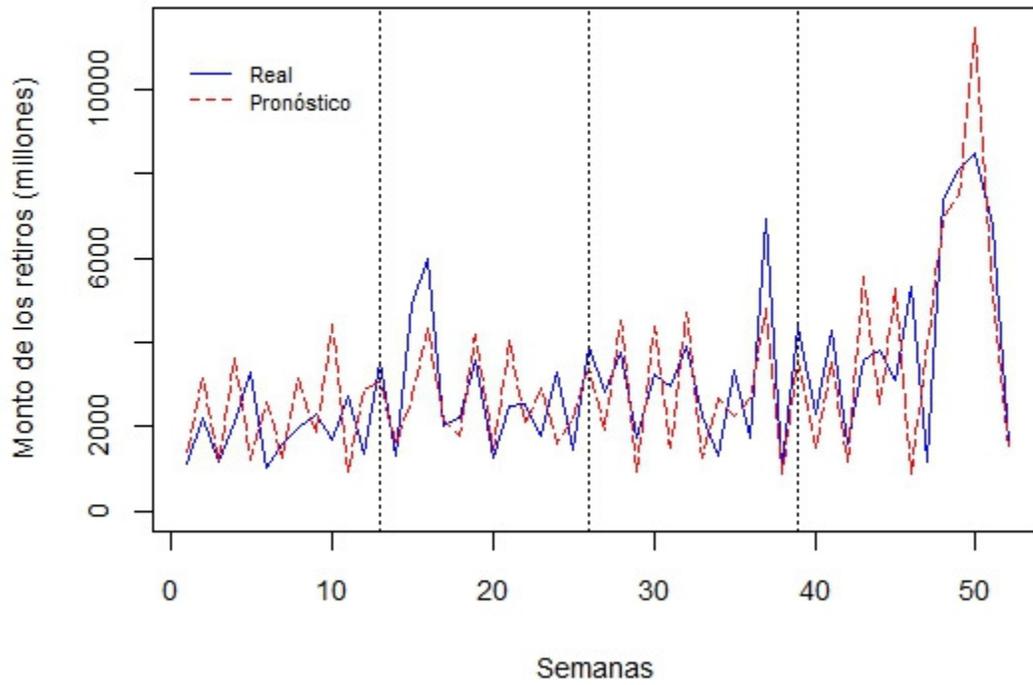


Figura 5.10 - Pronóstico ajustado de 2011 para la Serie A usando modelo ARIMA.

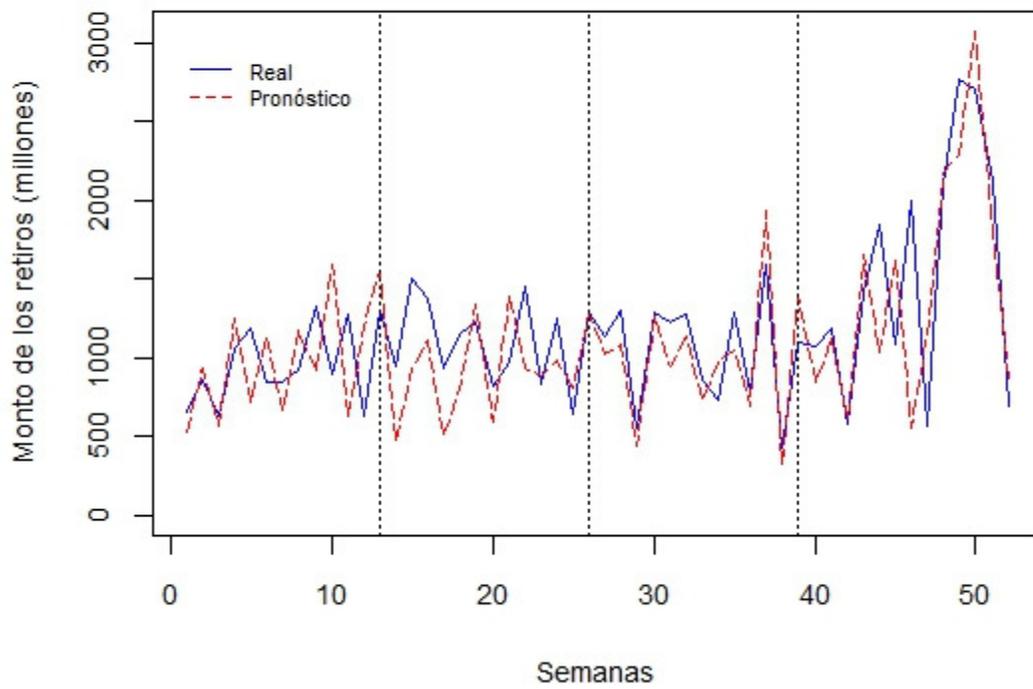


Figura 5.11 - Pronóstico ajustado de 2011 para la Serie B usando modelo ARIMA.

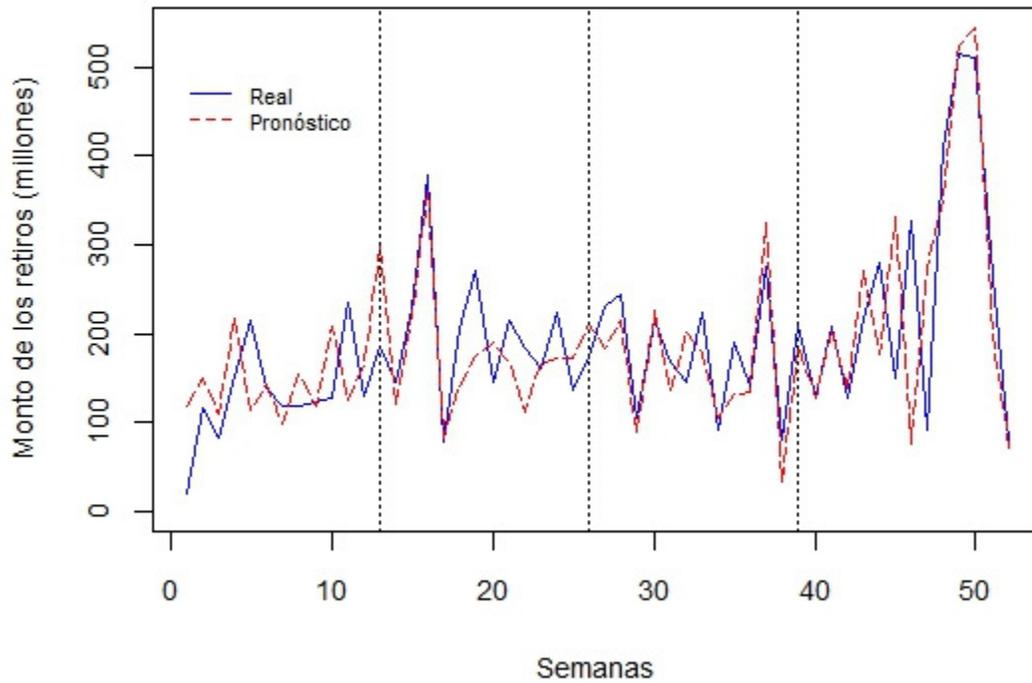


Figura 5.12 - Pronóstico ajustado de 2011 para la Serie C usando modelo ARIMA.

Finalmente, en la Tabla 5.12 se muestra una comparación en términos de MAPE para el pronóstico obtenido con RNAs y ARIMA para cada una de las series al pronosticar 13 periodos hacia adelante, donde se puede observar que usando RNAs se obtiene menor error porcentual de pronóstico para el año 2011.

Tabla 5.12 - Comparación del error de pronóstico en términos de MAPE.

Serie	MAPE (%)		Diferencia
	RNAs	ARIMA	
A	21.53	45.29	23.73
B	16.51	27.20	10.69
C	18.65	37.56	18.91

## CAPÍTULO 6

# CONCLUSIONES Y TRABAJO FUTURO

Actualmente la institución financiera en cuestión utiliza una metodología basada en ARIMA para pronosticar la demanda de efectivo en sus sucursales. Sin embargo, como se puede observar en los resultados obtenidos, los modelos de RNAs obtienen un mejor desempeño para las 3 series analizadas. Si bien el proceso pudiera explicarse mediante un proceso lineal, las RNAs poseen una importante flexibilidad en su construcción y no requieren de supuestos *a priori*. Esto brinda la posibilidad de implementar con mayor éxito un modelo de pronóstico para series extraídas de datos reales. A raíz de la era informática se cuenta con mayor disponibilidad de datos históricos, condición necesaria para implementar eficazmente un modelo de pronóstico de RNA.

En el trabajo presentado se utilizaron datos recolectados por 13 años de operación en una institución financiera, sin embargo la aplicación de estos modelos se puede hacer en diferentes rubros de la industria o de las ciencias sociales, como en ventas, inflación de precios, crecimiento demográfico, entre otros. La cantidad de datos históricos suficientes para construir un modelo será determinada por la misma estructura del modelo, la capacidad de aprendizaje y la complejidad del proceso.

En el caso que aquí se presenta, la institución financiera pretende reducir los costos atribuidos a la distribución del efectivo y su almacenamiento. Un pronóstico confiable brinda suficiente información para plantear un posterior modelo de optimización. En lo que respecta a la administración de la cadena de suministro, el principal objetivo es determinar las reglas apropiadas para la eficiente administración de los inventarios y de la red de distribución, que finalmente lleva a la empresa a

reducir sus costos operacionales. Si se trata de una empresa de capital privado, esto se traduce en una mayor ventaja competitiva en el mercado.

El paquete *nnet* del software estadístico R que se utiliza para abordar el problema del pronóstico resulta eficiente y sencillo de implementar, cualidad que generalmente se busca en los sectores productivos, además de ser de licencia libre. Si bien se trata de una estructura de RNA sencilla y con un algoritmo básico de entrenamiento, para la labor de predicción de series de tiempo se obtiene un mejor desempeño en comparación con el método de ARIMA. La transformación de los datos, sin embargo, es un paso que debe considerarse al momento de alimentar el modelo para estabilizar la varianza de los datos. Dado que no existe un procedimiento estándar para encontrar la mejor transformación, resulta útil probar con las transformaciones básicas de  $x^n$  y  $\log_n(x)$ , donde  $x$  es la serie en cuestión y  $n$  la potencia o base seleccionada mediante experimentación.

En este trabajo, la manera de construir el modelo de RNA para la labor de pronóstico utiliza técnicas propuestas en otros métodos de pronóstico lineales, como lo es el análisis de autocorrelación, sin embargo es útil al momento de seleccionar los regresores que pudieran estar linealmente relacionados con la salida deseada. Además, un análisis y conocimiento previo del sistema contribuye a seleccionar de manera eficiente los parámetros controlables del modelo. Se puede observar en los resultados obtenidos que los modelos construidos tienen una capacidad de pronóstico similar en el largo y corto plazo, en gran parte por la selección de los regresores. El pronóstico a largo plazo puede ser utilizado para la planeación estratégica de la compañía, mientras que el pronóstico a corto plazo apoya a la toma de decisiones a nivel operativo, ambas siguiendo una misma estimación futura.

Finalmente, el pronóstico obtenido funge como base para la toma de decisiones, pues puede ser ajustado conforme se tenga conocimiento del proceso, por ejemplo en eventos especiales que no han sucedido con anterioridad y por ende se espera que el modelo no logre pronosticar adecuadamente tal periodo. Asimismo, como se propone en este trabajo, los periodos conocidos pero que no tienen una estacionalidad fija

pueden ser abordados mediante técnicas más sencillas de manera independiente, aprovechando sus características particulares.

A manera de trabajo futuro, existe una amplia gama de estructuras de RNA y diferentes algoritmos de entrenamiento que pueden ser probados para comparar los resultados aquí obtenidos. También resulta interesante la búsqueda de regresores que puedan estar relacionados con la demanda de efectivo, como la inflación de precios en los productos denominados *commodities*.

Una estrategia que se considera desarrollar es un análisis de los factores que determinan el comportamiento de cada periodo del año, de tal manera que con estos factores y las características de cada periodo se puedan formar grupos con características similares (*clustering*) y proponer un modelo construido específicamente para capturar las características de cada semana, esperando que se obtenga una mejora en el pronóstico que utilizando un mismo modelo para todos los periodos.

Por otro lado, en años recientes se ha propuesto la utilización de otras técnicas de regresión y predicción no lineales, como lo son las máquinas de vectores de soporte o *Support Vector Machines* (SVM), técnica que es interesante probar para determinar si supera considerablemente la capacidad de predicción en las series mostradas.

En años recientes se han estudiado también propuestas de hibridación de modelos para el pronóstico de series de tiempo, donde se pretende mejorar el desempeño del pronóstico al explotar las diferentes ventajas que tienen los métodos conocidos. Por ejemplo, Zhang (2003), Khashei & Bijari (2010), Alagad et al. (2009) y Aburto & Weber (2007) proponen hibridación de modelos ARIMA con RNAs, donde el objetivo es capturar el comportamiento lineal de la serie mediante ARIMA, para después analizar los residuales del modelo que pudieran esconder la relación no lineal que ARIMA no pudo capturar. Al combinar ambos pronósticos se han obtenido mejores resultados que utilizando alguno de los dos modelos de manera independiente. Esta metodología resulta interesante probar para comparar los resultados que se obtuvieron mediante la metodología propuesta.

# REFERENCIAS BIBLIOGRÁFICAS

- Aburto, L., & Weber, R. (2007). Improved supply chain management based on hybrid demand forecast. *Applied Soft Computing*, 7, 137-144.
- Alagad, C. H., Egrioglu, E., & Kadilar, C. (2009). Forecasting nonlinear time series with a hybrid methodology. *Applied Mathematics Letters*, 22, 1467-1470.
- Andrawis, R. R., Atiya, A. F., & El-Shishiny, H. (2011). Forecast combinations of computational intelligence and linear models for the NN5 time series forecasting competition. *International Journal of Forecasting*, 27, 672-688.
- Balkin, S. D., & Ord, J. K. (2000). Automatic neural network modeling for univariate time series. *International Journal of Forecasting*, 16, 509-515.
- Banco de México. (6 de Diciembre de 2013). *Billetes y Monedas, circulación, Banco de México*. Recuperado el 16 de Marzo de 2013, de Banco de México: <http://www.banxico.org.mx/graph/test/?s=SF1,CF315,1&period=Men&l=es>
- Bansal, K., Vadhavkar, S., & Gupta, A. (1998). Neural networks based forecasting techniques for inventory control applications. *Data Mining Knowl(2)*, 97-102.
- Bates, J. M., & Granger, W. J. (1969). The combination of forecasts. *Operation Research*, 20, 451-468.
- Bernardos, P. G., & Vosniakos, G. C. (2007). Optimizing feed-forward artificial neural network architecture. *Engineering Applications of Artificial Intelligence*, 20, 365-382.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Cambridge, UK: Springer.
- Box, G. E., Jenkins, G. M., & Reinsel, G. C. (1994). *Time series analysis: Forecasting and Control*. San Francisco, CA: Wiley Series.
- De Groot, C., & Wutz, D. (1991). Analysis of univariate time series with connectionist nets: A case of study. *Neurocomputing*, 3, 177-192.
- Foix, C., & Weber, R. (2007). Pronóstico del precio del cobre mediante redes neuronales. *Ingeniería de Sistemas*, 21, 63-86.

- Ghysels, E., & Osborn, D. R. (2001). *The Econometric Analysis of Seasonal Time Series*. Cambridge, UK: Cambridge University Press.
- Gilbert, K. (2005). An ARIMA supply chain model. *Manage Sciences*, 51(2), 305-310.
- Ginzburg, I., & Horn, D. (1994). Combined neural networks for time series analysis. *Advance Neural Information Processing Systems*, 6, 224-231.
- Hamzaçebi, C., Akay, D., & Kutay, F. (2009). Comparison of direct and iterative artificial neural networks forecast approaches in multi-periodic time series forecasting. *Expert Systems with Applications*, 36, 3839-3844.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data mining, inference, and prediction*. New York, NY: Springer.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*. Saddle River, NJ: Prentice Hall.
- Hill, T., O'Connor, M., & Remus, W. (1996). Neural network models for time series forecasts. *Management science*, 42(7), 1086-1092.
- Hwang, B. (2001). Insights into neural-network forecasting of time series corresponding to ARMA (p,q) structures. *Omega: The International Journal of Management Science*, 29(3), 273-289.
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1-22.
- Hyndman, R., & Kostenko, A. V. (2007). Minimum sample size requirements for seasonal forecasting models. *Foresight*(6), 12-15.
- Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10, 215-236.
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p,d,q) model for time series forecasting. *Expert Systems with Applications*, 37, 479-489.
- Kuo, C., & Reitsch, A. (1995). Neural Networks vs. conventional methods of forecasting. *The Journal of Business Forecasting Methods & Systems*, 14(4), 17-22.
- Lapedes, A., & Farber, R. (1987). *Nonlinear signal processing using neural networks: Prediction and system modeling*. Los Alamos, NM: Technical Report LAUR-87-2662, Los Alamos National Laboratory.

- Luxhoj, J., & Riis, J. O. (1996). A hybrid econometric-neural network modeling approach for sales forecasting. *International Journal of Production Economics*, *43*, 175-192.
- Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: A review of modeling issues and applications. *Environment Modeling & Software*, *15*, 101-124.
- Makridakis, S. G., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications*. New Jersey: John Wiley & Sons, Inc.
- Medeiros, M., & Pedreira, C. (2001). What are the effects of forecasting linear time series with neural networks. *Logistics and Transportations Review*, *31*(3), 239-251.
- Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., & Leisch, F. (29 de August de 2013). *Misc Functions of the Department of Statistics (e1071)*, TU Wien. Obtenido de The comprehensive R archive network: [cran.r-project.org/web/packages/e1071/e1071.pdf](http://cran.r-project.org/web/packages/e1071/e1071.pdf)
- Poli, I., & Jones, R. D. (1994). A neural net model for prediction. *Journal of American Statistical Association*, *89*, 17-121.
- Reveco, C., & Weber, R. (2011). Gestión de capacidad en el servicio de urgencia en un hospital público. *Ingeniería de Sistemas*, *25*, 57-75.
- Ripley, B. (29 de August de 2013). *nnet: Feed-forward Neural Networks and Multinomial Log-Linear Models*. Obtenido de The comprehensive R archive network: [cran.r-project.org/web/packages/nnet/nnet.pdf](http://cran.r-project.org/web/packages/nnet/nnet.pdf)
- Ripley, B. D. (1996). *Pattern recognition and Neural Networks*. Cambridge, UK: Cambridge University Press.
- Shibata, R. (1976). Selection of the order of an autoregressive model by Akaike's information criterion. *Biometrika AC-63*, *1*, 17-126.
- Simutis, R., Dilijonas, D., & Bastina, L. (2008). Cash demand forecasting for ATM using neural networks and support vector regression algorithms. *20th EURO Mini Conference* (págs. 416-421). Neringa, Lituania: EUROPT-2008 Selected papers.
- Tseng, F. M., Yu, H. C., & Tzeng, G. H. (2002). Combining neural network model with seasonal time series ARIMA model. *Technological Forecasting and Social Change*, *69*, 71-87.

- Wagner, M. (2010). Forecasting daily demand in cash supply chains. *American Journal of Economics and Business Administration*, 2(4), 377-383.
- Weigend, D. K., & Cios, K. J. (1990). Predicting the future: A connectionist approach. *International Journal of Neural Systems*, 1, 193-209.
- Werbos, P. J. (1988). Generalization of backpropagation with applications to a recurrent gas market model. *Neural Networks*, 1, 339-356.
- Widrow, B., Rumelhart, D. E., & Lehr, M. A. (1994). Neural Networks: Applications in industry, bussines and science. *Communications of the ACM*, 37(3), 93-105.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, 160, 501-514.
- Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.
- Zhang, G., E., P. B., & Hu, M. Y. (2001). A simulation study of artificial neural networks for nonlinear time series forecasting. *Computers & Operations Research*, 28, 381-396.
- Zhang, P. G. (2007). Avoiding Pitfalls in Neural Network Research. *IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews*, 37(1), 3-16.
- Zhang, X. (1994). Time series analysis and prediction by neural networks. *Optimization Methods and Software*, 2, 151-170.

# FICHA AUTOBIOGRÁFICA

Omar Alexis Figueroa Armendáriz

Candidato para el grado de Maestro en Ciencias

con especialidad en Ingeniería de Sistemas

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica

Tesis:

PRONÓSTICO DE LA DEMANDA DE EFECTIVO EN UNA INSTITUCIÓN  
FINANCIERA EN MÉXICO.

Nací en Ciudad Juárez, Chihuahua, el 9 de noviembre de 1986, en donde cursé mis estudios profesionales de Ingeniería Industrial y de Sistemas en el Instituto de Ingeniería y Tecnología de la Universidad Autónoma de Ciudad Juárez. Posteriormente ingresé al programa de Maestría en Ingeniería de Sistemas en la Facultad de Ingeniería Mecánica y Eléctrica de la Universidad Autónoma de Nuevo León, en donde fui asesorado y dirigido por la Dra. Sara Verónica Rodríguez Sánchez para desarrollar este trabajo de tesis en conjunto con el Dr. Arturo Berrones, de la misma Universidad. En 2012 tuve oportunidad de realizar una estancia de investigación en el Departamento de Ingeniería Industrial de la Universidad de Chile, bajo la tutela del Dr. Richard Weber, profesor-investigador de esta institución.