



Universidad autónoma del
Estado de México



Facultad de Economía.

“Contraste entre modelos de Redes Neuronales Artificiales, GLM y GARCH en el pronóstico y análisis del tipo de cambio mexicano: 2000-2014”

TESIS

Que para obtener el título de licenciado en:

Actuaría

Economía

Presenta:

Luis Enrique Torres López

Alejandro Munguía Salazar

Asesor:

Dr. en Adm: Oswaldo García Salgado.

Revisores:

Dra. C.E.A. Rosa Azalea Canales García

M. en M.A. Verónica Ángeles Morales

Toluca, Estado de México, Julio 2016

Índice

| | |
|--------------------------------------------------------------------------------------------------------|----|
| Índice de Figuras | 4 |
| Índice de Tablas | 6 |
| Introducción | 7 |
| | |
| Capítulo 1 | 9 |
| Capítulo 1 El tipo de Cambio Peso/Dólar, Definiciones, Antecedentes, Teorías y Marco Referencial | 10 |
| 1.1 Definiciones relacionadas con el tipo de cambio | 10 |
| 1.2 El tipo de cambio a través del tiempo en el mundo | 11 |
| 1.3 Tipo de cambio a través del tiempo en México | 21 |
| 1.4 Teorías del tipo de cambio | 28 |
| 1.5 Regímenes Cambiarios | 35 |
| 1.6 Determinación teórica del tipo de cambio..... | 37 |
| 1.7 Variables que determinan el tipo de cambio | 38 |
| 1.8 Artículos y Literatura revisada como preámbulo | 46 |
| | |
| Capítulo 2 | 52 |
| Capítulo 2 Introducción a la metodología de las Redes Neuronales Artificiales | 53 |
| 2.1 Definiciones de inteligencia artificial y redes neuronales artificiales ... | 53 |
| 2.2 Historia de las redes neuronales artificiales | 55 |
| 2.3 Analogía entre una RNA's y cerebro humano..... | 58 |
| 2.4 Clasificación de las RNA's de acuerdo a su topología y aplicación | 71 |
| 2.5 Ejemplos y Aplicaciones de las redes neuronales | 77 |
| 2.6 Softwares capaces de usar RNA. | 80 |

| | |
|-----------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Capítulo 3..... | 84 |
| Capítulo 3 Modelos basados en RNA para determinar el comportamiento del Tipo de Cambio Mexicano y su contraste con modelo GLM y GARCH..... | 85 |
| 3.1 Variables | 85 |
| 3.2 Tratamiento de datos, preparación y submuestreo de la información para su modelación..... | 101 |
| 3.3 Validación de los modelos..... | 102 |
| 3.4 Estimación de los modelos..... | 104 |
| Conclusiones | 116 |
| | |
| Anexos | 122 |
| | |
| Referencias | 143 |
| Referencias | 145 |

Índice de Figuras

| | |
|----------------------------------------------------------------------------------------------|----|
| Figura 1.1 Comparativo entre peso/euro..... | 19 |
| Figura 1.2 Comparativo peso/dólar australiano..... | 19 |
| Figura 1.3 Comparativo peso/yuan chino..... | 20 |
| Figura 1.4 Comparativo peso/yen japonés..... | 20 |
| Figura 1.5 Comparativo peso/libra..... | 21 |
| Figura 1.6 Comparativo peso/dólar con periodicidad semanal..... | 25 |
| Figura 1.7 Comparativo peso/dólar con periodicidad mensual..... | 25 |
| Figura 1.8 Serie dólar/peso, total de la serie al momento de consulta..... | 26 |
| Figura 1.9 Línea temporal eventos (1)..... | 26 |
| Figura 1.10 Línea temporal eventos (2)..... | 27 |
| Figura 1.11 Línea temporal eventos (3)..... | 27 |
| Figura 1.12 Teorías del tipo de cambio..... | 28 |
| Figura 1.13 Regímenes cambiarios..... | 35 |
| Figura 1.14 Mecanismo de transmisión de la política monetaria..... | 40 |
| Figura 2.1 Línea del tiempo de los diferentes tipos de redes neuronales artificiales..... | 57 |
| Figura 2.2 Neurona..... | 60 |
| Figura 2.3 Neurona artificial..... | 64 |
| Figura 2.4 Función sigmoidea..... | 69 |
| Figura 2.5 Red neuronal..... | 70 |
| Figura 2.6 RNA, una capa..... | 72 |

| | |
|---------------------------------------------------------------------------------|-----|
| Figura 2.7 RNA multicapa..... | 73 |
| Figura 2.8 RNA recurrente..... | 74 |
| Figura 3.1 Tipo de cambio peso/dólar a la venta..... | 87 |
| Figura 3.2 Producto Interno Bruto..... | 88 |
| Figura 3.3 Total de cuenta corriente..... | 89 |
| Figura 3.4 Saldo de cuenta corriente USA..... | 90 |
| Figura 3.5 Inversión extranjera México..... | 91 |
| Figura 3.6 Inversión directa USA..... | 92 |
| Figura 3.7 Ingresos del sector público total..... | 93 |
| Figura 3.8 Total de ingreso presupuestado de gobierno..... | 94 |
| Figura 3.9 Gasto del sector público total..... | 95 |
| Figura 3.10 Tasa de interés interbancaria de equilibrio..... | 96 |
| Figura 3.11 Tasa de interés fondos federales..... | 97 |
| Figura 3.12 Saldo de deuda externa..... | 98 |
| Figura 3.13 Deuda externa, financiamiento del comercio exterior..... | 99 |
| Figura 3.14 Banca de desarrollo..... | 100 |
| Figura 3.15 Modelos RNA's para el tipo de cambio y las fases de estimación..... | 105 |
| Figura 3.16 Diagrama de flujo..... | 106 |
| Figura 3.17 Modelo lineal y serie original..... | 110 |
| Figura 3.18 RNA de panel vs serie original..... | 110 |
| Figura 3.19 RNA rezago, GARCH(1,1) y serie original del tipo de cambio..... | 112 |
| Figura 3.20 RNA mixta y serie original del tipo de cambio..... | 115 |
| Figura c1 Peso de las variables en el comportamiento del tipo de cambio..... | 118 |

Índice de Tablas

| | |
|---------------------------------------------------------------------------------------------|-----|
| Tabla 1.1 Comparación peso/monedas extranjeras..... | 18 |
| Tabla 2.1 Tipos de RNA de acuerdo al problema que resuelve y características de diseño..... | 76 |
| Tabla 3.1 Resumen de variables..... | 86 |
| Tabla 3.2 RNA vs modelo GLM..... | 109 |
| Tabla 3.3 Resultados RNA mixta..... | 114 |
| Tabla c1 Resumen de resultados..... | 116 |

Introducción

El tipo de cambio, visto como relación proporcional entre el valor de una moneda y otra es una variable macroeconómica importante de la economía globalizada, en el caso de México la paridad más importante que existe es la del peso (MXN) con respecto al dólar americano (USD) por la estrecha relación de intercambio comercial y de inversión que existe con los Estados Unidos.

La variable es comparativa, una imagen útil para los hacedores de política y tomadores de decisiones en empresas privadas; repercute en la inflación, en el poder adquisitivo, golpea seriamente al comercio en mercados que dependen de insumos importados, así como los empleos generados por él, debilita e impacta en la calidad de vida de la población y crea una imagen del país hacia el exterior ahí radica la necesidad de poder generar pronósticos eficientes y precisos de él al emplear herramientas de predicción que permitan hacer un análisis amplio del comportamiento de esta variable con fines de tomar medidas ante efectos negativos además de aprovechar los positivos cuando estos se den.

En el análisis y pronóstico del tipo de cambio existen estudios basados en técnicas de series de tiempo junto a modelos paramétricos tales como: regresiones, modelos multivariados y de panel pero muy pocos se aventuran en el terreno no para-métrico como el de la inteligencia artificial específicamente las redes neuronales artificiales (RNA) las cuales tienen ventajas como: aprendizaje, auto organización, tolerancia a fallos, flexibilidad y por ello es posible crear una herramienta basada en RNA con mayor certidumbre a los métodos tradicionales, con ellas, se pueden observar los periodos con mayores fluctuaciones así como los componentes que determinan el comportamiento del tipo de cambio

Se construyeron 5 modelos en total, 3 de Redes Neuronales Artificiales (RNA), un modelo lineal (GLM) y uno de tipo GARCH donde los modelos basados en inteligencia artificial permitieron una mayor certidumbre de predicción con los datos disponibles y publicados únicamente por el Instituto Nacional de Estadística y Geografía (INEGI) en un periodo de análisis de 2000 a 2014, datos libres y homólogos en metodología para su consulta, así como se destaca el uso dado al software libre especializado.

Para el capítulo 1 se repasaron los artículos y teorías consultadas junto a un recorrido a través de la historia del tipo de cambio en México, en el capítulo 2 desarrolló la técnica propuesta en la que se centra esta investigación, sus características, desarrollo matemático con énfasis en las ventajas de ella y para el capítulo 3 Se desplegaron los modelos y resultados para finalmente dar a conocer las conclusiones, así como la resolución de los hallazgos dentro de los cuales se destaca a la metodología de redes neuronales sobre los métodos tradicionales y las variables con mayor peso en el comportamiento del tipo de cambio como la tasa de interés americana y la inversión extranjera.

Capítulo 1

Capítulo 1

El tipo de Cambio Peso/Dólar, Definiciones, Antecedentes, Teorías y Marco Referencial

Este capítulo desarrolla el objeto de estudio, el tipo de cambio, como fenómeno económico, sus variables y cómo está compuesto comenzando con su definición, un contexto histórico mundial y nacional para entender cómo los eventos sociales lo afectan con fines contextuales pues la recopilación histórica no es el objetivo de este trabajo de investigación, se analizarán las teorías y tipos de regímenes cambiarios así como se subdividen para su análisis para posteriormente analizar las variables teóricas que influyen en él para finalizar con el conjunto de artículos y textos consultados como base de ella.

1.1 Definiciones relacionadas con el tipo de cambio

El Banco de México (2007) define al tipo de cambio como el precio de una moneda en términos de otra. Se expresa habitualmente en términos del número de unidades de la moneda nacional que hay que entregar a cambio de una unidad de moneda extranjera; para México la equivalencia del peso con respecto a la moneda extranjera.

El tipo de cambio es determinado (por el Banco de México) con base en un promedio de cotizaciones del mercado de cambios al mayoreo para operaciones liquidables el segundo día hábil bancario siguiente y que son obtenidas de plataformas de transacción cambiaria y otros medios electrónicos con representatividad en el mercado de cambios. Así el tipo de cambio es un precio más en la economía, pero su

importancia radica en que está ligado no sólo a los precios del propio país, sino también a los del exterior. Las fluctuaciones que pueden presentarse de él tienen consecuencias en la inflación, salarios, tasas de interés, niveles de producción y oportunidades de empleo (Banco de México, 2007)

Otros conceptos importantes a considerar y que serán ampliados más adelante son:

- a. Tipo de cambio directo: unidades de divisa nacional necesarias para adquirir una divisa extranjera.
- b. Tipo de cambio indirecto: cantidad de moneda extranjera a entregar por una unidad de moneda nacional.
- c. Tipo de cambio fijo: es marcado por el Banco Central, devaluación se usa en este esquema donde el gobierno fija el tipo de cambio y anuncia que su valor pasará de uno a otro más elevado.
- d. Tipo de cambio flexible: nace de la oferta y la demanda de las divisas en los mercados con continuos ajustes de los valores, propio de los países más desarrollados y con mayor libertad económica. Los términos usados para el cambio de valor de la moneda en este caso son, apreciación y depreciación. (Gómez, 2014).

1.2 El tipo de cambio a través del tiempo en el mundo

Debido al carácter del tipo de cambio como objeto de estudio, un recorrido histórico como tal es un trabajo de gran extensión y dificultad por la cantidad de factores que influyen en él, que es más simple enfocarse en una moneda en específico y compararla de manera dinámica con la de su mayor socio comercial. Existen autores que

mencionan las monedas de mayor importancia en un contexto determinado por sucesos históricos trascendentes tal como el realizado por Nogueira (2006), en el tercer capítulo del libro *“Las Reglas del Juego. Mercado de Cambios y Operaciones con Divisas”*, o el estudio de la UNICACC, que muestra el desarrollo histórico del mercado cambiario en México.

1.2.1 Comienzo del tipo de cambio

El comienzo de un tipo de cambio teóricamente se da desde la necesidad de intercambiar productos con economías que usen distinto medio de intercambio, incluso es posible decir que en el trueque existe un valor a la transacción, aunque esto no se ve establecido hasta más adelante. En la historia de la humanidad han existido muchos eventos que trascienden a nivel de desarrollo, a nivel biológico y claro a nivel económico, como lo son catástrofes naturales, guerras mundiales, epidemias, etc. (Nogueira, 2006)

El tipo de Cambio es uno de los fenómenos con mayor sensibilidad ante cambios en el contexto comercial económico porque es factor directo en las decisiones que se llevan a cabo en dicho mercado. (Banco de México, 2007). Según el libro de Nogueira (2006), al comienzo, las divisas al rededor del mundo estuvieron basadas en oro, por lo que una unidad monetaria expedida por un gobierno para el uso en una región limitada geográficamente representaba una cantidad real de oro que el mismo gobierno guardaba en un lugar seguro predispuesto a ello.

En la década de los 30's, Estados Unidos estableció el valor del dólar en un único e inalterable valor de una onza de oro por \$35 dólares, teniendo uno de los principales

referentes a nivel internacional de influencia en el valor de la moneda nacional ante las extranjeras pues, se influía en el valor del oro.

La Segunda Guerra Mundial es uno de los sucesos históricos más trascendentales a lo largo de la humanidad provocó cambios en todas las economías, el desarrollo, terminó con gran parte de lo que era la cooperación y las relaciones internacionales. Al final; Alemania y Japón sufrían diferentes grados de destrucción y sus economías dependían de los productos que se fabricaban en los Estados Unidos. Mientras que los americanos gracias a ello habían consolidado su economía, producía y usaba tecnología de avanzada, operaba al máximo de su nivel de capacidad con alto grado de eficiencia logrando así excedentes en su balanza de pagos. (Nogueira, 2006).

Estados Unidos y la Gran Bretaña negocian el comienzo de un sistema monetario libre, multilateral y estable, para evitar los sucesos económicos de los treintas, basados en el patrón oro; así en Bretton Woods, New Hampshire, Estados Unidos, representantes de cuarenta y cuatro naciones crean un nuevo orden monetario.

Los principales puntos acordados son citados a continuación:

“* Se vuelve al sistema de tipos de cambio fijos, estableciéndose como patrón oro el precio de 35 dólares la onza de fino, debiendo los países signatarios del acuerdo definir las respectivas paridades de sus monedas según esa relación.

* Los tipos de cambio no debían sufrir modificaciones mayores al uno por ciento, en más o en menos, salvo en el caso de “desequilibrio fundamental”, situación que exigiría una devaluación o una revaluación.

* Los gobiernos se comprometían a intervenir en los mercados para sostener el valor de sus divisas, ... y tomar severas medidas de austeridad para corregir los desequilibrios entre la oferta y la demanda.

También, otros de sus objetivos, eran el de fomentar la expansión del comercio, el pleno empleo y la cooperación internacional, lo que dio lugar, más tarde, al Acuerdo General de Comercio y Tarifas (General Agreement on Trades and Tariffs, GATT)." (Nogueira, 2006)

Así en la segunda posguerra mundial algunos países basaron su moneda en el dólar americano, sin embargo, como toda economía dinámica ya de tintes globalizados, el dólar no pudo mantener su inercia siendo víctima de la inflación, así empezó a perder terreno y otras monedas a revalorizarse. Para la década de los 70s, Los Estados Unidos se deshicieron del patrón oro dejando a libre consecuencia de las fuerzas de mercado el valor del mismo.

Hoy en día, el dólar sigue dominando muchos mercados financieros al punto en que los tipos de interés con frecuencia se expresan en dólares estadounidenses. El dólar estadounidense y el euro suponen aproximadamente el 50 por ciento de todas las operaciones de cambio del mundo cifra que si se incluye a las libras británicas (lb), los dólares canadienses (dllc), los dólares australianos (dlla) y los yenes japoneses (y), tenemos más del 80 por ciento de todos los cambios de divisa a nivel mundial.

1.2.2 Antecedentes del sistema monetario internacional

El sistema monetario utilizado desde el tiempo del imperio romano fue uno basado en metal, y podía ser mono metálico (oro o plata) o bimetálico (oro y plata) (Lelart, 1998).

El uso de este sistema fue preferido contra el trueque, que era el sistema que se utilizaba en otras partes del mundo, ya que contaba con cualidades especiales que le permitían desempeñarse mejor como moneda. De acuerdo con Patricia (2002), las cualidades de una moneda son:

- a. Poseer un alto valor intrínseco
- b. Inalterable
- c. Fácil transporte
- d. Homogéneo
- e. Divisible
- f. Maleable y fundible
- g. Existir en grandes cantidades
- h. Características físicas reconocibles
- i. Valor estable

Como expone Lelart (1998), el uso del oro como base del sistema monetario se fue consolidando durante el siglo XIX. Todas las monedas nacionales recibían un precio fijo respecto al oro. Los déficits comerciales eran saldados con exportaciones de oro a sus acreedores. La oferta monetaria internacional estaba ligada al oro, de forma que, si se quería exportar oro, las reservas bajaban y se tenían que tomar acciones que redujeran la oferta monetaria nacional.

El uso del patrón oro fue suspendido en época de entreguerras 1914-1925 y también de 1931-1944; con el fin de la segunda guerra mundial surgió el sistema de Bretton-Woods el cual duró entre 1944 y 1971; estaba basado en el dólar y a cada moneda tenía un tipo de cambio fijo con respecto a él; a su vez, el dólar tenía un tipo de cambio

fijo con respecto al dólar. Sólo existían intervenciones gubernamentales para defender la cotización manteniendo los tipos de cambio dentro de una banda de fluctuación de 1%. (Lelart, 1998).

Además, durante este periodo se creó el Fondo Monetario Internacional (FMI), que fue creado para ayudar financieramente a los países que necesitaban corregir sus desequilibrios externos y el Banco Mundial (BM). El sistema de Bretton Woods quebró durante la Guerra de Vietnam, en la que Estados Unidos comenzó a enviar millones de dólares al exterior para financiarse, lo cual originó un déficit comercial.

Por esta razón, los países europeos comenzaron a demandar la conversión de los dólares a oro. El presidente Richard Nixon devaluó el dólar como medio para aliviar el desequilibrio comercial, que resultó en el abandono del acuerdo en 1971 y en que la economía mundial adoptara el actual sistema, de manera importante, el sistema de tipo de cambio fluctuante. (Lelart, 1998).

1.2.3 Europa

En 1978 la Comunidad Económica Europea decide institucionalizar un acuerdo cuyo principal objetivo era lograr una necesaria estabilidad cambiaria, se crea el Sistema Monetario Europeo (*European Monetary System – EMS*), con objetivo básico de moderar la inestabilidad de los tipos de cambio de las monedas de los países de la Comunidad, que en su momento integraban Alemania, Inglaterra, Francia, Holanda, Italia, Bélgica, Dinamarca, Irlanda y Luxemburgo; Estableciendo un sistema de tipos de cambio fijos que podrían ser ajustados, con una cooperación monetaria y económica

fuerte y la coordinación por parte de los respectivos bancos centrales, de las políticas monetarias y financieras. (Nogueira, 2006).

Los fundamentos del EMS, son tres:

- a. La unidad monetaria europea.
- b. El indicador de divergencia.
- c. El sistema común de financiación.

En 1992 tras el Tratado de Maastricht se tenía un panorama bueno en el continente, sin embargo, a mediados del año comenzaron los problemas. Los daneses y franceses rechazaron aquél acuerdo resultando en fuertes tensiones en los mercados cambiarios, acrecentándose las presiones sobre la libra esterlina, la lira italiana y la peseta, las monedas más débiles del sistema a causa de la incertidumbre y el riesgo que esto provocaba, creando un estado de Crisis, y orillando a países como Suiza y Finlandia a proteger sus mercados.

El hecho de que la lira en dicho momento sufre una devaluación efectiva del 7 por ciento y que Alemania anuncia la rebaja de sus tasas de interés así como que los mercados siguieran apostando en contra del sistema dan comienzo a el fin. El llamado el “miércoles negro”, tras una jornada agobiante, Gran Bretaña anuncia el retiro de la libra del sistema y el Comité Monetario de la Comunidad Económica se reúne a la medianoche en medio de una tensa expectativa. En la madrugada del jueves 17 de septiembre de 1992, luego de una reunión que duró seis horas, el Comité dio a conocer un comunicado en el que informó sobre las decisiones adoptadas por Gran Bretaña e Italia de desvincular sus respectivas monedas del mecanismo de paridad cambiaria y, a

pedido de España, una realineación de su divisa dentro del sistema. La peseta fue devaluada en un 5 por ciento. (Nogueira, 2006).

No obstante, el SME entra en una etapa decisiva. Si no se hacen los ajustes necesarios el acuerdo europeo de cotización de monedas habrá llegado a su fin. El 2 de agosto de 1993 fue la fecha elegida, convirtiéndose ese día en otro hito importante en la historia de los sistemas cambiarios. Los funcionarios de la Unión Europea deciden, entonces, ampliar drásticamente la banda de fluctuación de las divisas, con las excepciones del marco alemán y el florín holandés, del 2,25 por ciento al 15 por ciento, en más o en menos. Termina así, en la más resonante frustración, el último intento de mantener indefinidamente un sistema de tipos de cambio fijos. (Nogueira, 2006) La tabla 1.1 compara tomando al peso mexicano como base con su equivalente con otras monedas de alta importancia y circulación, como el euro (EUR), el dólar australiano (AUD) el yen japonés (JPY) y el yuan chino (CNY), así como la libra británica a 7 días

Tabla 1.1
Comparación peso/monedas extranjeras

| Gráfico | | Tabla | | | | |
|----------------------------------|-----------|-----------|-----------|-----------|-----------|--|
| Tipos de COMPRA diarios @ +/- 0% | | | | | | |
| | MXN / EUR | MXN / AUD | MXN / CNY | MXN / JPY | MXN / GBP | |
| Periodo medio | 0,0551 | 0,0848 | 0,3835 | 7,32 | 0,0393 | |
| Periodo alto | 0,0557 | 0,0849 | 0,3850 | 7,38 | 0,0395 | |
| Periodo bajo | 0,0548 | 0,0847 | 0,3821 | 7,28 | 0,0393 | |
| 30 oct 2015 | 0,0548 | 0,0848 | 0,3827 | 7,28 | 0,0393 | |
| 31 oct 2015 | 0,0550 | 0,0848 | 0,3828 | 7,31 | 0,0393 | |
| 01 nov 2015 | 0,0550 | 0,0848 | 0,3821 | 7,31 | 0,0393 | |
| 02 nov 2015 | 0,0550 | 0,0849 | 0,3837 | 7,31 | 0,0393 | |
| 03 nov 2015 | 0,0553 | 0,0847 | 0,3847 | 7,35 | 0,0395 | |
| 04 nov 2015 | 0,0557 | 0,0847 | 0,3850 | 7,38 | 0,0395 | |

Fuente: OANDA (2015)

(GBP). Las figuras 1.1-1.5 muestran su comportamiento, esto con fines didácticos pues no es el tema a tratar en esta investigación:

Figura 1.1
Comparativo entre peso/euro



Fuente: OANDA (2015)

Figura 1.2
Comparativo peso/dólar australiano



Fuente: OANDA (2015)

Figura 1.3
Comparativo peso/yuan chino



Fuente: Fuente: OANDA (2015)

Figura 1.4
Comparativo peso/yen japonés



Fuente: OANDA (2015)

Figura 1.5
Comparativo peso/libra



Fuente: OANDA (2015)

1.3 Tipo de cambio a través del tiempo en México

En el caso de México, la paridad más importante que existe es la del peso (MXN) con respecto al dólar americano (USD), por relación de intercambio comercial que existe con Estados Unidos, la cantidad de inversión extranjera y el tipo de cambio directo que hay, esta relación ha tenido un contexto histórico resumido de manera general por una palabra: depreciación.

En 1820 y durante un periodo de 55 años, el peso costaba más de un dólar sin embargo esto cambiaría cuando Estados Unidos alcanzara el nivel de potencia mundial y Porfirio Díaz aceptara el patrón oro en 1904; durante la Revolución, hacia 1914, el peso ya se había devaluado hasta US\$0.3028, sin embargo estos periodos son de constante cambio e inestabilidad política por lo que los efectos sociales y económicos se dan a causa de dichos eventos internos y son la base de mucha de la historia posterior y sientan las bases del comercio tanto interno como externo, condiciones sociales y entorno en un futuro. (Romero, 2009)

Con Ávila Camacho, en 1948 el peso se estabilizó en \$4.85 por dólar posteriormente el presidente Ruiz Cortines anunció una devaluación de \$8.65 a \$12.50 por dólar como medida precautoria a la posible debilidad de las reservas del país la devaluación dejó al peso sustancialmente subvaluado, cosa que desempeñó un papel clave en la reactivación de la economía de México. Impulsó al país de un estado de recesión y un PNB negativo, hacia una etapa de crecimiento. La inversión extranjera aumentó y se inició así un prolongado periodo de estabilidad económico-financiera.

De 1958 a 1970 fue un periodo de rápido crecimiento económico combinado con estabilidad, la inflación anual en más de una ocasión fue menor que la de EU, el circulante creció en promedio anual de 11.5%, el sexenio de Echeverría, sus programas populistas y los continuos ataques al sector privado, erosionaron la confianza del público y provocaron una seria fuga de dólares.

En 1977, se llegó a \$19.95, la perspectiva general y social era más alentadora por los programas propuestos y los campos petrolíferos encontrados, pero se desató una euforia de gastos y préstamos que superó toda consideración prudente, y eso dio

origen a una serie de factores negativos que derrocaron la estabilidad haciendo que el medio circulante creciera exponencialmente: 502.5% en sólo seis años con la principal consecuencia; la inflación alcanzó también alturas insospechadas.

El precio promedio del dólar durante 1982, se habría multiplicado por 39.8 veces al terminar 1987 analizando el Índice Nacional de Precios al Consumidor, se aprecia que ascendió a 10,647.2, por lo que la inflación en ese periodo fue de 3,406.9%. Dicho en otra forma, el nivel general de precios se había multiplicado 35 veces respecto al nivel promedio registrado en 1982 disminuyendo claramente el poder adquisitivo de la población aumentando la desigualdad socio-económica. (Cárdenas, 2010)

Con Carlos Salinas de Gortari en 1988, se intenta crear un nuevo modelo político-económico dentro del sistema existente, pero tratando de no desestabilizar este último; El dólar pasó a \$2,686 al cierre de 1989 (incremento de 17.5%), 2.6 puntos más que el 14.9% de brecha inflacionaria México-EU, patrocinando el efecto Tequila, aumentando a niveles muy altos la desigualdad, creando situaciones desfavorables para los créditos personales y pequeñas empresas así como creando a uno de los hombres más ricos del mundo.

En el gobierno de Ernesto Zedillo se llegó a \$9.360 pesos al finalizar su periodo. Vicente Fox, pasó de \$9.360 a \$10.880. Felipe Calderón, de \$10.900 a \$11.350, al mes de mayo de 2011, aunque a principios de marzo de 2009, alcanzó los \$15.36 pesos por dólar, debido a la crisis.

Desde 1910 al periodo de Calderón, el peso se ha devaluado cerca de 7,500% y en la actualidad (agosto del 2015) el peso se acerca a los \$18 por dólar, con el Banco de

México haciendo maniobras como el inyectar dólares al mercado e impulsar inversión extranjera, para soportar las condiciones de Grecia, un dólar que cada día se hace más fuerte y condiciones de las bolsas asiáticas desfavorables. (Cárdenas, 2010)

Se aprecia en ese breve contexto histórico que desarrolla Octavio C. (2010), que el tipo de cambio influye de manera directa en la economía, la calidad de vida de la población, pues logra hacer mella en la inflación lo que disminuye el poder adquisitivo de ella. Golpeando seriamente al comercio interno (de manera positiva y negativa), aumenta o disminuye la desigualdad y crea una imagen del país mismo hacia el exterior, la única línea de defensa que se tiene, es la prevención y solo se previene a través de un buen pronóstico, preciso y capaz de entender el problema.

Las figuras siguientes muestran el comportamiento del tipo de cambio peso/dólar en diversos intervalos de tiempo a la fecha consultada (5 noviembre del 2015); a una semana (Figura 1.6), a un mes (Figura 1.7), así como el registro completo (Figura 1.8) y en las figuras 1.9-1.11, la línea temporal de los eventos.

Figura 1.6
Comparativo peso/dólar con periodicidad semanal



Fuente: Investing (2015)

Figura 1.7
Comparativo peso/dólar con periodicidad mensual



Fuente: Investing (2015)

Figura 1.8

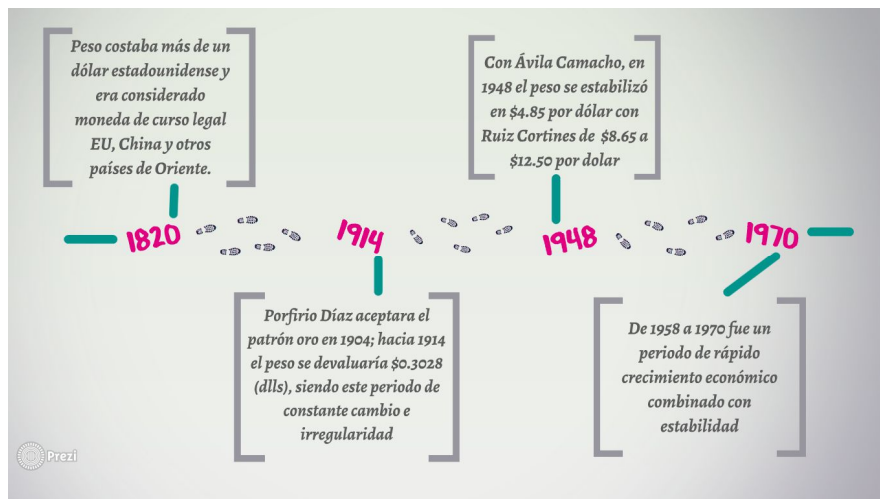
Serie dólar/peso, total de la serie al momento de consulta



Fuente: Investing (2015)

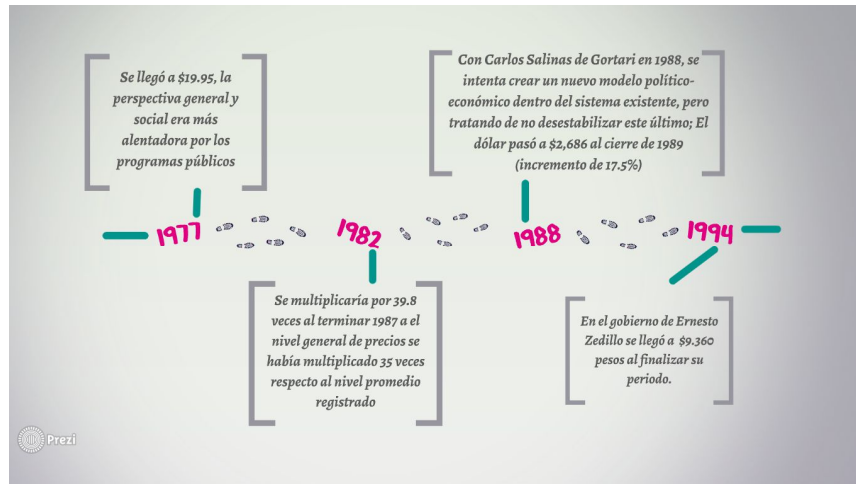
Figura 1.9

Línea temporal eventos (1)



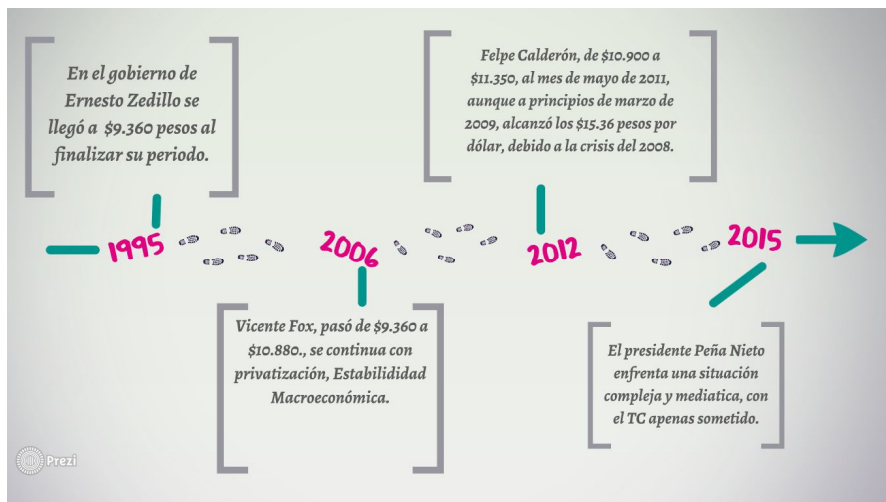
Fuente: Elaboración Propia.

Figura 1.10
Línea temporal eventos (2)



Fuente: Elaboración Propia.

Figura 1.11.
Línea temporal eventos (3)



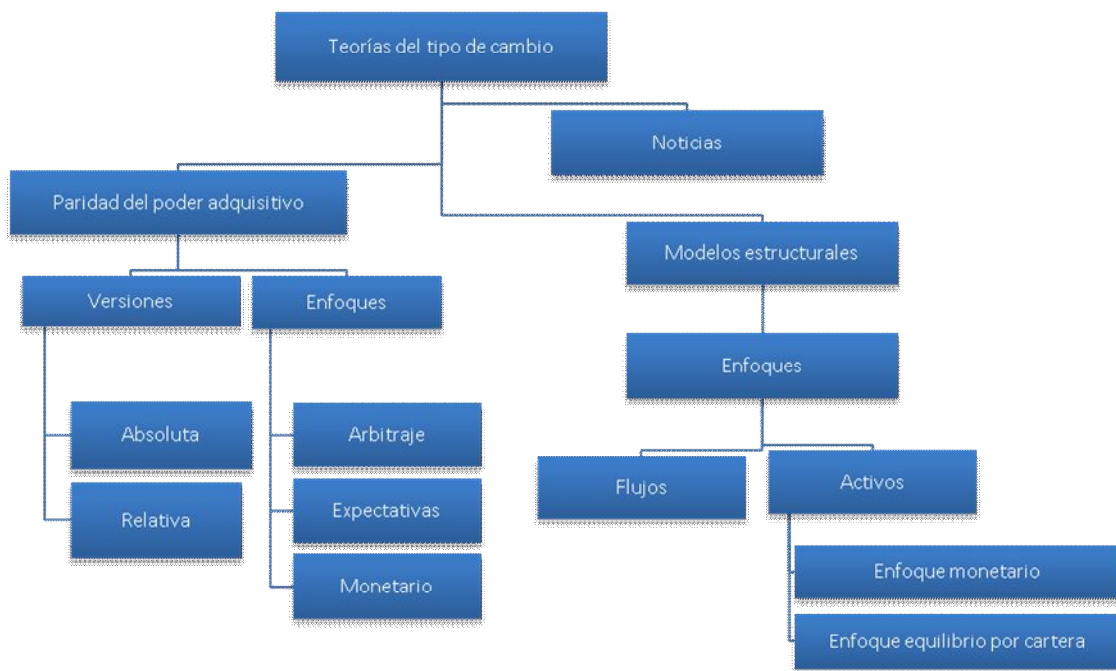
Fuente: Elaboración Propia.

1.4 Teorías del tipo de cambio

Existen varias teorías que tratan de dar una explicación del tipo de cambio como lo es el análisis fundamental, la paridad del poder adquisitivo (PPA), los modelos estructurales, el a causa de las nuevas corrientes teóricas ya obsoleto modelo Mundell-Flemming y a través de la balanza de pagos: en los desequilibrios entre la cuenta corriente y la cuenta de capital.

La figura 1.12 resume las más importantes teorías del tipo de cambio

Figura 1.12
Teorías del tipo de cambio



Fuente: elaboración propia

1.4.1 Enfoques de paridad del poder adquisitivo (PPA)

Esta teoría se basa en que el mismo producto debe tener el mismo valor en diferentes países. Relaciona los tipos de cambio al contado con la inflación. Cuando la Inflación aumenta, el tipo de cambio al contado lo hace también, la moneda se deprecia y viceversa. Dicho de otro modo, el tipo de cambio entre dos monedas se encuentra en equilibrio cuando se iguale el precio de una misma cesta de bienes y servicios en los dos países de los que las divisas son originarias. (Roll, 1979)

Hay dos versiones la absoluta y la relativa, la versión absoluta tiene la idea básica de que un producto cuesta lo mismo independientemente de cual sea la divisa que se utiliza para comprarlo o donde se vende de manera que es complejo que esta versión se cumpla pues existen otros factores que afectan al precio como: impuestos indirectos en diferentes países, barreras arancelarias, costes de transportes entre otros. Estos factores ayudan a favorecer la diferencia de precios de un bien en función del país en el cual se vende. (Roll, 1979)

Por otro lado, la relativa propone que la variación previsible de los tipos de cambio depende de las tasas esperadas de inflación. Con esta teoría el país con mayor inflación prevista verá como su moneda se deprecia con respecto a la del país con una inflación. Cuanto menor sea la inflación el tipo de cambio de su divisa debería aumentar.

Existen 3 principales enfoques de la PPA, que son: el enfoque del arbitraje, el de expectativas (también llamado enfoque de mercado eficiente) y el monetario, la versión relativa del PPA admite que difiera de los precios relativos a causa de impedimentos al

comercio internacional o costos de transporte. De manera similar a la versión absoluta, la versión relativa establece que si la tasa de inflación nacional excede a la extranjera se requiere un aumento del tipo de cambio para mantener el poder de compra, y viceversa. (Roll, 1979)

El enfoque del arbitraje establece que los precios de mismas mercancías en diferentes países deberían ser equivalentes bajo condiciones de flexibilidad de precios, competencia perfecta, ausencia de restricciones en intercambios e información perfecta. El tipo de compra debería balancear el poder de compra entre las monedas. De esta forma, si un bien fuese más barato en otro país, la demanda de este bien incrementaría su precio y, por consiguiente, balanceando el poder adquisitivo entre las monedas. (Roll, 1979)

El enfoque de expectativas, por otra parte, expresa las variables de la PPA en términos de sus expectativas y no de sus valores corrientes. Se basa en la hipótesis de Fisher y en la paridad descubierta de intereses. En este caso, si la tasa de inflación esperada nacional fuese inferior a la tasa de inflación extranjera esperada, entonces se esperaría una depreciación en la moneda nacional, y viceversa. Este diferencial de expectativas se suele obtener mediante predicciones en las tasas de inflación con modelos ARIMA o de filtros de Kalman.

Por último, el enfoque monetario de la PPA implica una neutralidad del dinero a largo plazo en el que, suponiendo fija la oferta de dinero de un país extranjero, una variación en la oferta de dinero nacionalmente originaría variaciones proporcionales en las variables nominales nacionales.

1.4.2 Modelos estructurales

Además del modelo de la PPA existen los modelos estructurales, los cuales se dividen a su vez en el enfoque tradicional de flujos y en el enfoque de activos. De acuerdo al enfoque de flujos, las variaciones en los tipos de cambio tienen por objeto equilibrar la oferta y demanda de divisas que se originan en los flujos de bienes y servicios internacionales, la condición de Marshall-Lerner asegura la estabilidad de los mercados cambiarios. (Lerner, 1952)

El enfoque por flujos postula además que:

- a. El aumento de precios en la economía nacional con respecto a los precios extranjeros dará lugar a una depreciación de la moneda nacional para compensar tal aumento. (Lerner, 1952)
- b. El aumento en el nivel de la renta nacional con respecto al nivel de renta extranjera dará lugar a un empeoramiento en la balanza por cuenta corriente que requeriría de la depreciación del tipo de cambio para recobrar el equilibrio. (Lerner, 1952)

El modelo por activos tiene dos enfoques: el monetario y el de equilibrio por cartera. En el enfoque monetario (Frenkel, 1976), tiene el supuesto de que los activos nacionales y extranjeros son sustitutos perfectos, además de una movilidad perfecta del capital entre la economía nacional y la extranjera. En este enfoque se tienen los siguientes efectos:

- a. El incremento en la oferta monetaria nacional generaría un exceso en la oferta, lo que incrementaría los precios nacionales proporcionalmente que resultaría en una depreciación del tipo de cambio a raíz de la PPA. (Lerner, 1952)
- b. El incremento en la renta real nacional generaría un exceso de la demanda, lo que produciría un decremento en los precios nacionales, proporcionalmente. Nuevamente, por la PPA, resultaría en la apreciación del tipo de cambio. (Lerner, 1952)
- c. El incremento en el tipo de interés nominal nacional, decrementaría la demanda de saldos reales, incrementaría precios y depreciaría el tipo de cambio.

1.4.3 Enfoque de equilibrio de cartera

En contraste con el enfoque monetario, en el equilibrio de cartera no supone que activos nacionales y extranjeros son sustitutos perfectos. Los controles de capital, riesgo político o solvencia son algunos factores que originan esta sustitución imperfecta. (Branson 1976)

En este enfoque se asigna la riqueza financiera en tres tipos de activos: moneda nacional (A), bonos nacionales (B) o bonos extranjeros (C). Este modelo señala como efectos:

- a. El incremento en la oferta en A tendría como resultado un incremento en la riqueza financiera proporcional a dicho incremento. Con esto, los

- inversores redistribuirían su riqueza lo que provocaría una caída en el tipo de interés nacional y una depreciación del tipo de cambio. (Branson 1976)
- b. El aumento en el precio de B, los bonos nacionales, tiene un efecto incierto que depende de qué tan buenos sustitutos sean los bonos nacionales y extranjeros de los activos nacionales. Como Branson (1976) muestra, si lo anterior ocurre, entonces el tipo de cambio se depreciaría, caso contrario si los activos nacionales son mejores sustitutos que los bonos nacionales y extranjeros. (Branson 1976)
 - c. Variaciones en el precio de C, los bonos extranjeros, no tendrían efecto en el tipo de cambio. (Branson 1976)
 - d. El aumento en el tipo de interés extranjero incrementaría la oferta de dinero como de bonos nacionales ocasionando un aumento en los activos extranjeros generando una depreciación en el tipo de cambio. (Branson 1976)

1.4.4 Modelo enfocado en noticias

El modelo enfocado en noticias investiga la influencia que tienen las noticias y sorpresas en las variables de los modelos económicos (Frankel, 1979) influidas por la cuantiosa cantidad de información con la que son bombardeados los mercados. Esta teoría postula que las expectativas sobre el tipo de cambio (forward) debería ser un buen predictor del tipo de cambio futuro. Almeida, Goodhart y Payne (1998) y Chaboud, Chernenko y Wright (2008) muestran evidencia de que noticias con contenido positivo sobre la economía originan una apreciación del tipo de cambio.

1.4.5 Teoría de Fisher cerrada

Relaciona inflación con tipos de interés nominales. Aumentos de la inflación están acompañados de aumentos de tipos de interés nominales y viceversa. Esta teoría postula que los tipos de interés nominales de un país reflejan, anticipadamente, los rendimientos reales exigibles ajustados por las expectativas de inflación. Además, en los diferentes países, los rendimientos reales deben tender a la igualdad por lo que las diferencias en las tasas nominales se deben a distintas expectativas de inflación.

1.4.6 Teoría de Fisher internacional o abierta

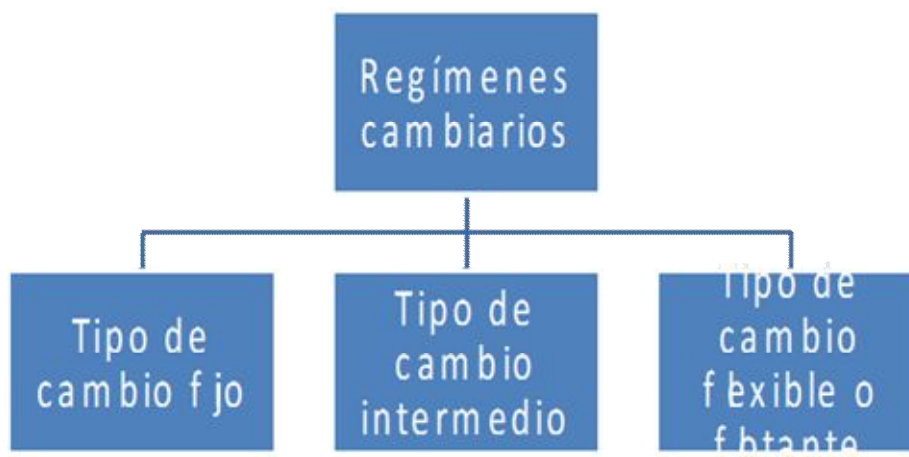
Esta teoría se basa en que los tipos de interés nominales reflejan los rendimientos reales ajustados por las expectativas de inflación. Relaciona tipos de cambio al contado con tipos de interés. A largo plazo, si aumenta el tipo de interés, lo hace también el tipo de cambio. Sin embargo, a corto plazo, el efecto es contrario. En esta teoría se postula que la rentabilidad total del inversor internacional, en diferentes países, debe ser igual a largo plazo.

En definitiva, la variación del tipo de cambio, entre dos monedas dadas, depende de los diferenciales de tipos de interés ofrecidos por dichas divisas en sus respectivos mercados, a mayor tipo de interés ofertado, la moneda tiende a debilitarse a largo plazo a fin de que a los inversores les sea indiferente invertir en una u otra moneda.

1.5 Regímenes Cambiarios

De acuerdo con el Fondo Monetario Internacional (FMI), existen 3 tipos de regímenes cambiarios (Figura 1.13) con los cuales se regulan los aspectos que impliquen transferencias o pagos de divisas y se dividen por el grado de flexibilidad en: tipo de cambio fijo, bandas de fluctuación y tipos de cambio móviles.

Figura 1.13
Regímenes cambiarios



Fuente: elaboración propia

1.5.1 Tipo de cambio fijo

En el tipo de cambio fijo la moneda ajusta su valor basándose en el de una divisa extranjera, o adoptar una medida, como el oro. Este es el régimen más utilizado por las economías emergentes debido a que presentan un grado insuficiente de en sus instrumentos de control monetario. En este caso ocurre que la autoridad monetaria de un país utilice una divisa extranjera delegando la política monetaria a las autoridades del país al que pertenece tal divisa. Un ejemplo de esto son países como El Salvador o Ecuador. (Gómez, 2014).

El tipo de cambio fijo se presentó también en el caso de la Unión Europea. En este caso los países integrantes adoptaron al euro como moneda en común. Aunque más tarde adoptaron un sistema de bandas de fluctuación, el cual se enuncia más adelante, en los tipos de cambio de flexibilidad intermedia. (FMI, 2015)

Una tercera opción que se presenta en los tipos de cambio fijos es de la creación de un comité monetario el cual anuncia el tipo de cambio frente a una divisa extranjera. Este comité tiene prohibido comprar activos nacionales por lo que la moneda está respaldada por reservas nacionales. Como ejemplos están Bulgaria, Estonia y Lituania. (Gómez, 2014).

1.5.2 Tipo de cambio intermedio

En el tipo de cambio intermedio se presentan 4 casos: un sistema de tipo de cambio vinculado a una cesta de divisas, como en el caso de Libia o las Bahamas; vinculados

con una cesta de divisas con paridad reptante, que es un caso muy parecido al anterior, pero en el que ajustan la paridad de anualmente dependiendo de factores como diferenciales de inflación, evolución de la balanza de pagos, etc. Ejemplos de esto son: Bolivia, Nicaragua o Costa Rica; tipo de cambio de bandas de fluctuación, en el que mantienen un tipo de cambio dos países dentro de ciertos límites, después de los cuales defienden la moneda. (Gómez, 2014).

Por último, se tienen las bandas de fluctuación reptantes, en el que se tiene el caso anterior, pero los límites se modifican dependiendo de factores similares a los enunciados en el caso de tipo de cambio reptante. (Gómez, 2014).

1.5.3 El tipo de cambio flexible

En este sistema el tipo de cambio fluctúa de manera libre en el mercado de divisas. A diferencia de los tipos de cambio intermedios, este último no tiene que defender un objetivo de definido para el tipo de cambio. Este tipo cambiario se denomina tipo de cambio flexible; en la práctica la autoridad interviene en ocasiones (tipo flexible administrado) cuando la moneda fluctúa excesivamente sin que esto implique un objetivo definido para el tipo de cambio. (Gómez, 2014).

1.6 Determinación teórica del tipo de cambio

La paridad del poder adquisitivo (PPA) es el modelo más sencillo para determinar el tipo de cambio. Su origen data del siglo XVI en la escuela de Salamanca.

Existen dos versiones del PPA: la versión absoluta postula que, a mayor nivel de precios nacionales en comparación con el nivel de precios extranjeros, se tiene un tipo de cambio depreciado para mantener el poder adquisitivo de la moneda nacional. La fórmula que expresa este modelo se muestra en la ecuación 3.1.

$$s = p - p^* \quad (1.1)$$

donde se representa el tipo de cambio como la cantidad de unidades de moneda nacional necesarias para adquirir una unidad de moneda extranjera; p y p^* son los niveles de precios nacional y extranjero, respectivamente. (Banco de México, 2013).

1.7 Variables que determinan el tipo de cambio

A continuación, se exponen las variables que se relacionan con el tipo de cambio tomando en cuenta los modelos y principios de política monetaria antes expuestos; así como también la descripción de tales variables y el poder predictivo que poseen con la variable de estudio. (Banco de México, 2013).

1.7.1 Variables macroeconómicas y su relación en la política monetaria

La política monetaria en México está a cargo del Banco de México que es la entidad responsable de proveer la moneda e instrumentar la política económica. Entre las autoridades monetarias en el mundo queda claro que la mejor contribución que tiene un

banco central es procurar la estabilidad de precios combatiendo la inflación (Banco de México, 2013).

El banco central no tiene control directo de los precios ya que estos son determinados por las leyes de oferta y demanda, por lo que utiliza canales en la política monetaria para influir en los precios. Tales efectos son conocidos como *mecanismos de transmisión de política monetaria*.

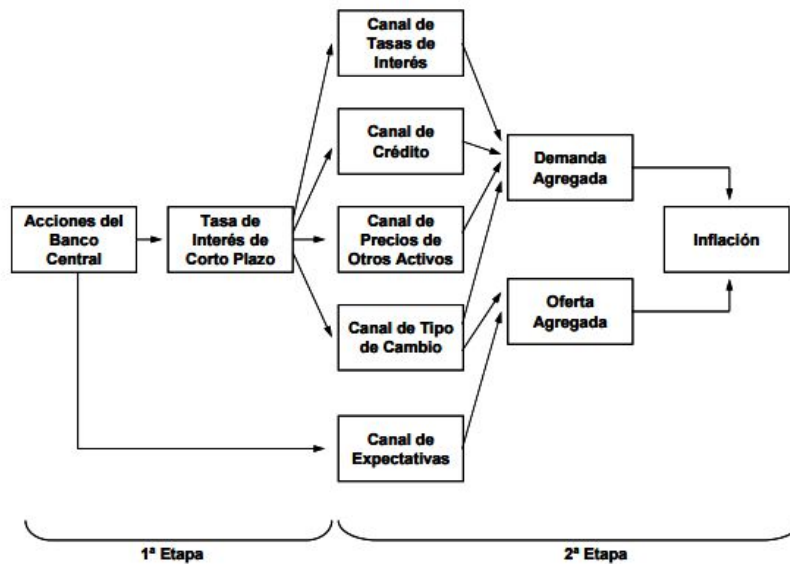
Dependiendo del curso que tenga de la política monetaria en determinado momento, así como el escenario macroeconómico que se presente, el tipo de cambio forma parte en la interacción entre los canales para lograr un objetivo en el nivel inflacionario; es la posición del tipo de cambio en este mecanismo de transmisión de la política monetaria y su relación con los precios lo que influye en su volatilidad.

1.7.2 Factores macroeconómicos relacionados con el tipo de cambio

De acuerdo al resumen documental de Patel (2000), existen 11 factores que afectan el tipo de cambio los cuales se observan en la figura 1.14

Figura 1.14

Mecanismo de transmisión de la Política monetaria.



Fuente: Banco de México (2013).

- a. Inflación: Si la tasa de inflación nacional es menor que la extranjera, entonces las exportaciones incrementarán, lo que conlleva un incremento en la demanda de esta moneda para la adquisición de bienes nacionales.
- b. Tasa de interés: Las inversiones nacionales se vuelven atractivas de manera proporcional a la tasa de interés nacional ya que los inversores

obtienen mejores rendimientos al invertir en bancos nacionales. Esto resulta en un incremento en el tipo de cambio nacional.

- c. Balance de capital: Un alto déficit para un país equivale a volúmenes más altos de importación de bienes y servicios lo que incrementa la oferta de la moneda nacional y disminuir el tipo de cambio.
- d. Especulación: Un especulador es una persona que puede asumir más riesgo en una inversión y tener un impacto mayor en el precio de un activo. Si un especulador cree que el precio de la moneda nacional incrementará, comenzará a demandar más moneda en este momento y viceversa.
- e. Costo de manufactura: Si el costo por producir un bien es bajo, entonces es posible vender a precios competitivos lo que incrementa las exportaciones. Este incremento en las exportaciones presiona el tipo de cambio hacia arriba.
- f. Deuda pública: Los países que invierten más en su sector público o en programas sociales, por ejemplo, tienden a incrementar su deuda pública. Aunque este tipo de inversiones estimulan la economía doméstica, puede, en niveles altos, resultar en una pérdida en el atractivo para los inversionistas extranjeros ya que conduce a un incremento en la inflación.
- g. Producto interno bruto: El producto interno bruto (PIB) es un indicador del crecimiento económico que tiene un país. Es por tal motivo que el bueno nivel en el PIB incrementa el atractivo de un país y a una mejor valuación de la moneda, pues más capital de los inversionistas llega a la nación.
- h. Estabilidad política: Los países que tienen un gobierno estable realizan de manera general de mejor forma los proyectos que tienen y generar crecimiento económico; al contrario, un país con un gobierno dividido en muchos partidos políticos, por ejemplo, no es capaz de tomar decisiones sólidas y pierde el atractivo de los inversionistas extranjeros.

- i. Empleo: En general, se observa que cuando la tasa de desempleo disminuye, el tipo de cambio se aprecia, sin embargo, también se ha observado que altas tasas de empleo producen un incremento en el poder adquisitivo de las personas e incrementan la inflación.
- j. Fuerza relativa de otras divisas: La fortaleza económica de otros países también influye en la divisa nacional ya que el dinero tiende a moverse a economías fuertes.
- k. Eventos macroeconómicos y políticos: Elecciones, guerra, crisis económicas son algunos eventos que incrementan fuertemente la volatilidad la moneda de una nación.

1.7.3 Punto de vista técnico en la predicción del tipo de cambio

Los factores que determinan el tipo de cambio, descritos anteriormente, se estudian en distintos aspectos y analizar cómo influyen en la tasa de cambio. Jonathan H. Wright (2008) considera que las variables determinantes del tipo de cambio, usadas en su modelo de pronóstico por Redes Bayesianas, son:

- a. Precios de mercado
- b. Diferenciales de precios de mercado
- c. Tasa de interés a largo plazo
- d. Tasa de interés a corto plazo
- e. El diferencial entre las tasas de interés de corto y largo plazo
- f. El precio del petróleo
- g. Diferenciales en el precio del petróleo
- h. Tipo de cambio del periodo inmediato anterior

- i. El signo del diferencial en el tipo de cambio
- j. El producto interno bruto real desestacionalizado
- k. El cambio en el producto interno bruto real desestacionalizado
- l. La oferta monetaria desestacionalizada
- m. El diferencial en la oferta monetaria desestacionalizada
- n. Nivel de precios al consumidor
- o. Tasa de inflación
- p. Proporción de la cuenta corriente con respecto al PIB

Rout (2013), en su estudio sobre el *pronóstico de tipos de cambio con redes neuronales recurrentes*, hizo uso de indicadores técnicos utilizados por los intermediarios bursátiles en las casas de bolsa, reduciendo las variables analizadas a 10. Los indicadores técnicos son una clase de métricas cuyo valor es derivado de la actividad de precios de una divisa.

A continuación, se listan las variables que usó, omitiéndose la *aceleración de precio de cierre* por su ambigüedad con el *cambio en la tasa de precios*:

- *Media móvil simple*:

$$\frac{1}{N} \sum_{i=1}^N x_i,$$

$N =$ Num. de días, $x_i =$ precio de hoy **(1.2)**

- *Media móvil exponencial:*

$$A = \frac{2}{N+1}, P = \text{Precio actual}, A = \text{factor de suavización}, N = \text{Periodos de tiempo} \quad (1.3)$$

- *Indicador de acumulación/distribución:*

$$\frac{(PC - PB) - (PA - PC)}{(PA - PB) \times (\text{Volumen del periodo})}$$

PC = Precio de cierre, PA = Precio más alto, PB = Precio más bajo (1.4)

- *Oscilador estocástico:*

$$S = 100 \times \left(\frac{VC - Min}{Max - Min} \right)$$

S = oscilador estocástico, VC = Valor de cierre de la última sesión, Max, Min = valores máximo y mínimo de la cotización en el periodo (1.5)

- *Volumen de equilibrio:*

$$BV = BV_{\text{previo}} + \begin{cases} \text{volumen} & \text{si } PC > PC_{\text{previo}} \\ 0 & \text{si } PC = PC_{\text{previo}} \\ -\text{volumen} & \text{si } PC < PC_{\text{previo}} \end{cases}$$

PC = Precio de cierre (1.6)

- *Indicador R de William:*

$$\%R = \frac{PA - PC}{PA - PB} \times 100$$

PA = Precio de la cotización más alta, PC = Precio de cierre, PB = Precio de la cotización más baja **(1.7)**

- *Indicador de fuerza relativa:*

$$IFR = 100 - \frac{100}{1 + (\frac{U}{D})}$$

U = Media móvil de un cambio al alza, D = Media móvil de un cambio a la baja **(1.8)**

- *Cambio en la Tasa de precios:*

$$\frac{PC_t - PC_{t-x}}{PC_{t-x}} \times 100$$

PC = Precio de cierre **(1.9)**

- *Aceleración de cierre de precios:*

$$\frac{PA_t - PA_{t-n}}{PA_{t-n}} \times 100$$

PA = Precio de la cotización más alta **(1.10)**

1.8 Artículos y Literatura revisada como preámbulo

Se observó un incremento en el interés e importancia por el análisis del tipo de cambio a través de diferentes metodologías, desde su aparición y necesidad gracias al comercio internacional cobra un papel fundamental en la economía y el avance tecnocientífico que se mantiene en continuo avance hace posible el desarrollo, prácticamente diario, de nuevas metodologías para entender el comportamiento de un fenómeno o predecir incluso su cauce.

Al hacer una búsqueda de material referencial, se consultaron las bases de datos de Scopus y Redalyc para hallar artículos que usen redes neuronales artificiales como metodología para el pronóstico del tipo de cambio, se encontró que el resultado propuesto por sus buscadores es muy pobre cuando se especifica la ramificación que se desea consultar y muy poco precisa cuando se hace una búsqueda genérica.

Así, se decide el consultar buscadores online especializados tales como:

- a. Google Académico o *Google Scholar*,
- b. *Microsoft Academic Search*
- c. ERIC El Centro de información de recursos educativos, ERIC (*Education Resources Information Center*) del Instituto de Ciencias de la Educación
- d. RefSeek Todavía en beta, es un motor de búsqueda para estudiantes o investigadores
- e. Science Research Science Research
- f. *World Wide Science*

g. Scielo La Biblioteca Científica Electrónica en Línea.

Así, se logró un vasto surtido de artículos y estudios de carácter científico publicados en libros, revistas científicas y webs especializadas junto a la consulta de Tesis, proyectos de Titulación y trabajos finales del equivalente de licenciatura en otros países relacionados con la técnica de las redes neuronales artificiales para el pronóstico, o se estudien fenómenos económicos con la misma técnica.

De los trabajos y escritos buscados alrededor del 15 por ciento abordan una problemática relacionada bajo el enfoque de la técnica de las RNA's, principalmente en la rama económica de estudio, la gran cantidad de estudios se enfoca en las aplicaciones médicas, ingenieriles o de patrones, sin embargo, algunos se aventuran a ello, destacando los de procedencia asiática.

Se centró la revisión – mas no limitó - a un conjunto de quince documentos resumidos a continuación, que destacan entre los demás, por su calidad su manejo de la técnica, su conocimiento del tema, así como la finalidad del mismo para demostrar y hacer notar la importancia del tópico como sustento de la investigación.

- a. Nogueira (2006), hace un breve trayecto del tipo de cambio del dólar contra otras monedas y plantea el uso de un tipo de cambio libre, controlado o flexible, ya en contexto más actual.
- b. Se revisará el Capítulo 4, del libro: “Redes Neuronales en la Predicción”, así como el texto: “Introducción a los Algoritmos Genéticos y la programación Genética” de Marcos Gesta (et. al.) junto a estar en permanente lectura de publicaciones internacionales que expongan trabajos de inteligencia artificial

con fines de comprender al máximo tanto las características como las propiedades, fuerzas y debilidades de la técnica propuesta, para que posteriormente sea posible la estimación del modelo y la interpretación de resultados.

- c. Gómez (2010), genera el pronóstico de una serie temporal usando redes neuronales de las demandas máximas mensuales de energía eléctrica proporcionados por la Comisión Federal de Electricidad de 1994 al 2006 y lo compara contra la metodología *Box Jenkins*, concluye que los errores de la aproximación por series de tiempo son mayores, se incrementan en el paso del tiempo, y además las predicciones tienden a una constante mientras se incrementa el periodo de predicción.
- d. Gómez (2007), realiza un trabajo que consta de tres modelos para la predicción del comportamiento de las divisas, con redes neuronales artificiales multicapa como principal Metodología aplicada de 3 formas diferentes, dividiendo por periodos los datos usados. Un modelo GARCH(1,1) como la mejor opción paramétrica; y los modelos inteligentes como opción un 35% más eficientes.
- e. Méndez (2008); presenta un modelo de rezagos junto a uno de redes neuronales artificiales en el pronóstico de la tasa nominal de cambio colombiana, unidad equivalente al tipo de cambio nominal mexicano, y concluye que los modelos no lineales logran predecir correctamente el signo del 80% de los cambios de la tasa de cambio, mientras que el modelo lineal lo hace un 75% de las veces. Por el contrario, la medida del error porcentual absoluto medio señala alguna ventaja del modelo lineal sobre los modelos no lineales.
- f. Parisi (2003), Analiza la capacidad de las redes neuronales para predecir el signo de las variaciones del dólar a precios de cierre diario. Los modelos de RNA a pesar de las condiciones adversas para el modelaje como el bajo

número de agentes, alta volatilidad y una marcada Influencia del banco central son primera opción ante los modelos paramétricos de manera general al hacer selección de una metodología de estimación.

- g. Zapata (2008), predice la relación peso colombiano con el dólar con una RNA multicapa alimentada hacia delante con mecanismo de aprendizaje supervisado por corrección de errores y hetero-asociación representada en forma de valores continuos con un error promedio de 0.0614%.
- h. Benedetti et. al., (2008), predice y replica el índice Merval (índice bursátil argentino) a través de RNA's.
- i. Morales (2008), compara un modelo ARIMA contra uno de redes neuronales artificiales en el estudio de los CETES mexicanos (certificados de la tesorería) se menciona a los modelos ARCH como destacados, a los ARIMA como débiles para el pronóstico y la mejor opción un mixto de RNA con configuración ARCH para que así se pueda extender el análisis a otros derivados.
- j. Bonilla M. (2002), predice la volatilidad del tipo de cambio de la peseta, la capacidad predictiva de las RNA's diseñadas es superior de acuerdo a los resultados a la de los modelos tipo ARCH y de manera general las redes híbridas es decir las que tienen variables numéricas en conjunto a variables de serie de tiempo son las más eficientes.
- k. Barrera (2010) predice el tipo de cambio diario peruano, donde las RNA's muestran eficientes capacidades para predecir con mejoría a través del tiempo.
- l. Rudra (2010), concluye que las RNA captan mejor los fenómenos y resultan en excelentes predictores para el tipo de cambio hindú por encima de los métodos lineales. La RNA resulta hábil para recolectar información oculta en la serie de datos, y útil para los hacedores de política al tomar mejores decisiones en búsqueda metas de crecimiento.

- m. Pacelli (2011), usa RNA y algoritmos genéticos para predecir el tipo de cambio euro/dólar con variables macroeconómicas fundamentales. El pronóstico encontrado muestra que el proceso de formación del tipo de cambio no es completamente ruido ni totalmente aleatorio y si predecible.
- n. Kadilar (2009), usa las redes neuronales artificiales en diferentes configuraciones con fines de pronosticar el tipo de cambio de la moneda turca respecto al dólar y las contrarresta con modelos de tipo ARIMA y ARCH. Las redes neuronales artificiales son superiores según su resultado en pruebas RMSE (raíz del error cuadrático medio), MAPE y MAE (error promedio de media).
- o. Simon (2002), Pronostica el tipo de cambio extranjero usando redes neuronales artificiales sin embargo como las monedas son tan diferenciadas encuentra poca correlación entre sí junto a una relación aceptada y dada con el euro.
- p. Gradojevic (2000), pronostica el tipo de cambio canadiense respecto al dólar americano. El resultado muestra que los modelos de RNA son eficientes para generar el pronóstico sobre los de caminata aleatoria de manera que si se encuentra la configuración apropiada para la red se comportara mejor que cualquier modelo lineal.

Así se da sustento teórico a la investigación respecto a contexto, desarrollo y forma, así como, queda definido el objeto de estudio desde su concepto, historia, y la exposición de teoría que lo analiza estructuralmente como fenómeno.

Debido a su clara importancia, es necesario usar metodologías más modernas y eficientes para su pronóstico como las no paramétricas en el campo de la inteligencia

artificial específicamente las redes neuronales artificiales, metodología desarrollada en el capítulo 2.

Capítulo 2

Capítulo 2

Introducción a la metodología de las Redes Neuronales Artificiales

En este capítulo se analizaron conceptos sobre la técnica empleada como principal en esta investigación, las Redes Neuronales Artificiales; el resto de las técnicas empleadas no son explicadas pues se asume su conocimiento previo antes de la lectura de este documento.

En esencia las RNA reproducen el funcionamiento teórico del cerebro humano específicamente el funcionamiento de las neuronas en organismos vivos. El capítulo se dividió en cuatro partes. Los conceptos generales, la distinta clasificación de las RNA's, 3 Aplicaciones y por ultimo algún breve análisis de *softwares* que utilizan esta aplicación no paramétrica.

2.1 Definiciones de inteligencia artificial y redes neuronales artificiales

La inteligencia artificial es una rama de la computación que busca relacionar un fenómeno natural con una analogía artificial a través de software y desarrollo matemático. En ella se han desarrollado los sistemas expertos, que reproducen la capacidad mental del hombre y relacionan reglas de sintaxis del lenguaje hablado y escrito con base en la experiencia para emitir juicios acerca de un problema, cuya solución se logra con mejores juicios y en menor tiempo que el ser humano. (Loaiza, 2007)

Otras técnicas con auge son: Búsqueda del estado requerido en el conjunto de los estados producidos por las acciones posibles, algoritmos genéticos (análogo al proceso de evolución de las cadenas de ADN), razonamiento mediante una lógica formal análogo al pensamiento abstracto humano y por supuesto, claro es, las Redes Neuronales Artificiales.

Las Redes Neuronales Artificiales, RNA están inspiradas en las redes neuronales biológicas del cerebro humano y constituido por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes, por ejemplo, las RNA's aprenden de la experiencia, generalizan de ejemplos previos a nuevos y abstraen las características principales de una serie de datos. (Basogain, 2014).

Lara (2008), define a las RNA's como modelos matemáticos inspirados en sistemas biológicos, adaptados y simulados en una computadora, básicamente un sistema de computación compuesto por un gran número de elementos simples, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas capaces de resolver problemas, de forma individual o combinada con otros métodos como los son tareas de clasificación, identificación, diagnóstico, optimización o predicción.

Matich, (2001). Menciona que el proceso de comparación entre los modelos de diferente tipo y redes neuronales; comprende de las siguientes etapas:

- a. Una fase de preparación de la información con la que se alimentarán los modelos

- b. Una fase en la que se aplicó un criterio con el cual se hizo una submuestra de la información en tres porciones para realizar: el entrenamiento, el ajuste de parámetros en modelos y la validación
- c. La fase del entrenamiento en sí misma
- d. La fase de ajuste de los modelos
- e. Fase de validación

2.2 Historia de las redes neuronales artificiales

Alan Turing es el primero en estudiar el cerebro como si este fuese una computadora sin embargo las RNA's tienen un primer antecedente en los años 40s, con la computadora electrónica. Los estudios teóricos importantes en el comienzo de las redes neuronales se deben a los trabajos del neurofisiólogo Mc Coulloc y del matemático Pitts en 1943, quienes presentaron un modelo de neurona biológica y sus componentes conceptuales para circuitos que podían llevar tareas de cálculo. (Lara, 1998).

McCulloch: (1943) afirma que cualquier función aritmética podía ser modelada con una red neuronal, sin embargo el modelo original carecía de una forma de ajustar los parámetros de la red por lo que se contaba con un estático que requería que los pesos de las señales y los sesgos tuvieran que ser ajustados de forma manual y Rosenblatt (1950) añadió un algoritmo de aprendizaje al modelo, este es un procedimiento automático que se encarga de ajustar los pesos y sesgos apoyándose en los datos de entrenamiento; es esta dupla la que provee a la red con el contexto del fenómeno, para usar el algoritmo de entrenamiento en ajustar los parámetros a este contexto y devolver una señal de salida estimada que se ajuste de forma óptima a los valores etiqueta del

fenómeno. El autor mostró que el algoritmo convergía a una solución siempre y cuando existieran parámetros que permitieran solucionar el problema.

Frank Rosenblatt comenzó el desarrollo del *perceptrón de dos capas* (entrada y salida) y en 1957 se desarrolló la red neuronal más antigua utilizada hoy en día para aplicaciones como identificar patrones. En 1958 introduce el primer modelo neuronal concreto, y participa en la construcción del primer neurocomputador exitoso, el *Mark I*. (Martínez, 2000)

En 1960 se dan los primeros pasos del *perceptrón multicapa* (PMC) con falta de un algoritmo de aprendizaje adecuado causado por las limitaciones tecnológicas de la fecha por lo que Marvin Minsky y Seymour Papert probaron matemáticamente que el perceptrón no era capaz de resolver problemas como el aprendizaje de una función no-lineal. (Aguilar, 2009)

En 1974 Werbos introduce el llamado algoritmo de retro-propagación (*backpropagation*), y en 1986 Rummelhart y Mclelland publican su algoritmo general para un perceptrón multicapa. (Aguilar, 2009)

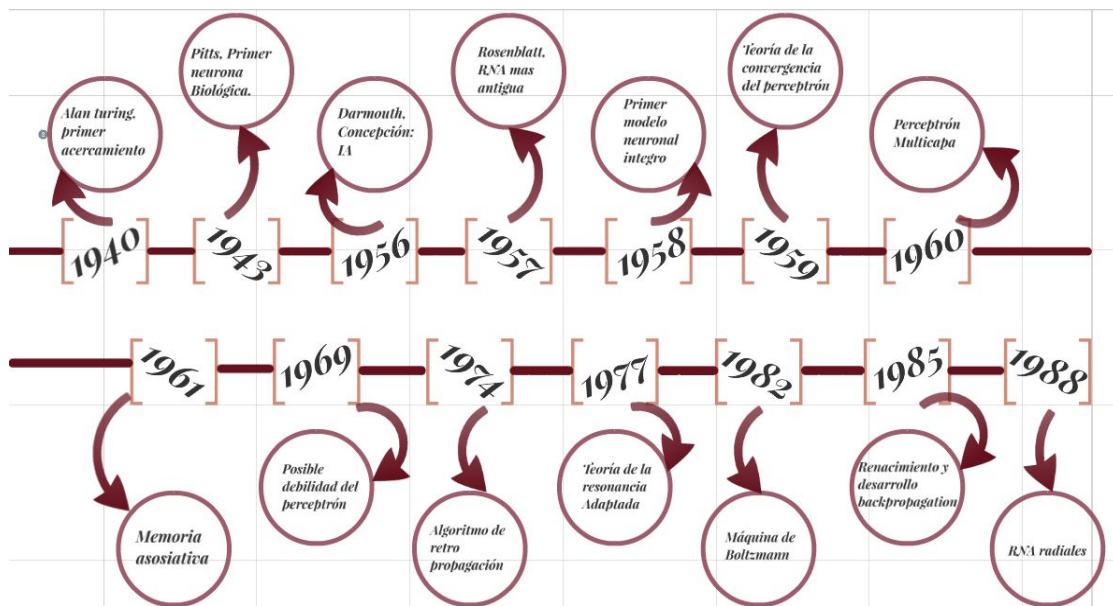
En 1977 Stephen Grossberg publica la *Teoría de Resonancia Adaptada* (ART) que simula memoria a largo y corto plazo el desarrollo de ART continuó a los modelos de red más avanzados *ART II* y *ART III* y en 1985, John Hopfield Provocó el renacimiento popular de las redes neuronales con su libro: "*Computación neuronal de decisiones en problemas de optimización.*" (Aguilar, 2009)

Las Redes de Función de Base Radial (RBF) fueron desarrolladas por Broomhead y Lowee en 1988 y Los Mapas Auto organizativos (SOM) presentados por Kohonen en 1982 una clase de mapa topológico que se auto organiza, con base en los patrones de entrada con los que es entrenada. (Martínez, 2000)

En la actualidad, son numerosos los trabajos que se realizan cada año en la inteligencia artificial con aplicación en la informática, finanzas, medicina e ingeniería, así como en el área de control, junto al software principalmente para simulación.

Figura 2.1

Línea del tiempo de los diferentes tipos de redes neuronales artificiales



Fuente: Elaboración Propia

En la figura 2.1 se observa una línea del tiempo que resume la evolución de las redes neuronales artificiales a través del tiempo.

2.3 Analogía entre una RNA's y cerebro humano.

Para entender la metodología de las redes neuronales artificiales es necesaria la comparación análoga entre ella y el cerebro humano de donde proviene, junto a los conceptos de computación "normal" y la "biológica" para así entender la diferencia de una máquina Von Neumann contra una máquina de inteligencia artificial. (Lara, 1998).

2.3.1 Computación Tradicional y Biológica

Lara (1998), menciona en su texto que la computación convencional se caracteriza por un previo entendimiento del problema, el desarrollo de una estructura matemática para él, un algoritmo para implementar una solución, codificación del mismo en una máquina específica y por último la ejecución de dicho código.

Este tipo de procesamiento es muy exitoso para resolver modelos matemáticos complejos y de simulación, para tareas repetitivas, rápidas y bien definidas las cuales se llevan a cabo dentro de la arquitectura convencional en un componente de hardware llamado unidad lógico-matemática (ALELU), siendo realizada en un procesador dedicado distribuyendo los procesos en dos memorias principales: una de uso en tiempo real de carácter temporal (RAM) y una de carácter permanente (HD), conformando así una máquina Von Neumann.

Esa arquitectura es incapaz de resolver eficientemente problemas de carácter de reconocimiento, de clasificación o de interpretación como el de reconocimiento de: imágenes, de voz, y de lenguaje natural, así como tampoco es hábil en problemas de percepción, adaptación y aprendizaje (Martínez, 2010)

La computación biológica que se basa en el estudio de los sistemas biológicos vistos como si estos fuesen una computadora en cómo estos resuelven problemas; se caracteriza por ser masivamente paralela, adaptativa, lenta, altamente interconectada y tolerante al ruido en el medio ambiente y en sus componentes. (Gómez, 2010).

2.3.2 Neurona

La neurona es la unidad mínima y más simple del sistema nervioso (en particular del cerebro). Cada neurona es una unidad procesadora que recibe y combina señales desde y hacia otra de manera que si la combinación de entradas a esa neurona es suficientemente fuerte la salida de la neurona se activa. (Lara, 1998)


Biológicamente consiste de tres partes: las dendritas que introducen las señales nerviosas, el cuerpo celular y el axón que envía dichas señales desde el cuerpo celular hacia otras neuronas. A nivel de la membrana plasmática celular existe una concentración de cargas negativas (al interior) y positivas (al exterior) que genera una diferencia de potencial bioeléctrico resultado de la concentración de varios aniones con cationes dentro y fuera de la célula, que depende en última instancia de las propiedades de permeabilidad de la membrana externa y del transporte activo de los iones, especialmente sodio y potasio. (Lara, 1998)

Cuando una neurona recibe estímulo de otras neuronas el proceso electroquímico involucrado causa que su voltaje varíe, cuando excede un cierto umbral resulta en una descarga del impulso nervioso de forma rápida que viaja hacia el axón estimulando a otras neuronas, en ese momento la neurona se ha activado. (Aguilar, 2010)

Las redes o circuitos neuronales están formados por grupos de neuronas unidas a través de los brazos terminales del axón y cierran el circuito con las dendritas de otras neuronas, el proceso de contacto entre las componentes de dos neuronas se llama *sinapsis*. Las señales pueden o no pasar, de acuerdo a la actividad conjunta de neuronas y la importancia del estímulo inicial con resultado en una acción específica. (Martínez, 2010)

La figura 2.2 obtenida del *Children's Hospital Boston*, muestra los componentes, partes e impulsos de una neurona de manera didáctica y multimedia.

Figura 2.2
Neurona



Fuente: Children's Hospital Boston (2015)

2.3.3 Ventajas de las redes neuronales artificiales

Debido a su constitución y fundamentos, las RNA's presentan un gran número de características semejantes a las del cerebro, por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante.

Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen:

- a. Aprendizaje adaptativo: las RNA's llevan a cabo ciertas tareas mediante un entrenamiento y aprenden a diferenciar patrones mediante ejemplos, no es necesario elaborar modelos a priori ni necesidad de especificar funciones de distribución de probabilidad; son adaptables debido a la capacidad de auto ajuste en los elementos procesales (neuronas) que componen el sistema pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones por lo que la función del diseñador es únicamente la obtención de la arquitectura apropiada (un buen algoritmo de aprendizaje) y no como el cómo la red aprenderá a discriminar.
- b. Auto-organización: las redes neuronales organizan automáticamente la información que reciben durante el aprendizaje, esto consiste en la modificación de la RNA completa para llevar a cabo un objetivo específico lo que resulta en la generalización, que es la facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a las que no había sido expuesta anteriormente

- c. Tolerancia a fallos: las RNA son los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos comparados con los sistemas tradicionales que pierden su funcionalidad cuando sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un número pequeño de neuronas no sufre una caída repentina. Hay dos aspectos importantes respecto a la tolerancia a fallos, el primero menciona que las RNA's aprenden a reconocer patrones con ruido, distorsionados o incompletos. (tolerancia a fallos respecto a los datos) y el segundo, que las redes neuronales siguen realizando su función (con cierta degradación) aunque se destruya parte de la red pues tienen la información distribuida en las conexiones entre neuronas con cierto grado de redundancia en este tipo de almacenamiento.
- d. Fácil operación e inserción entre la tecnología existente: las redes tienen un rápido tiempo de respuesta debido a su implementación paralela. Con las herramientas computacionales existentes actualmente es en poco tiempo comprobada, verificada y trasladada a una ejecución en hardware de bajo coste sin dificultades para la inserción en aplicaciones específicas como el control, el reconocimiento y la predicción. (Aguilar, 2010)

2.3.4 Neurona y red neuronal artificial.

Schalkoff, (1997) Escribe que la unidad análoga a la neurona biológica es el elemento procesador, PE (*process element*) o neurona artificial que tiene varias entradas y las combina en una suma básica. La suma de las entradas es modificada por una función de transferencia y el valor de la salida de esta función pasa directamente a la salida del elemento procesador la cual se conecta a las entradas de otras neuronas artificiales

mediante conexiones ponderadas correspondientes a la eficacia de la sinapsis de las conexiones neuronales.

Una red neuronal artificial se asemeja a una biológica en dos aspectos principales: el conocimiento es adquirido a través de un proceso de aprendizaje y este, se halla en la interrelación de unidades simples de procesamiento llamadas neuronas.


En un modelo de red neuronal se identifican 3 elementos básicos:

1. Un conjunto de enlaces sinápticos o conexiones en el que cada uno es caracterizado por estar ponderado por un peso o fuerza.
2. Un sumador que combina (típicamente una combinación lineal) las señales de entrada ponderándolas por sus sinapsis de entrada.
3. Una función de activación que limita la amplitud de la salida o rango de una neurona.

Así, está compuesta de una cantidad definida de unidades mínimas y elementales simples interconectadas (neuronas artificiales), cada unidad posee una característica de entrada/salida e implementa un proceso local o función, la salida a su vez está determinada por su característica de entrada/salida, su interconexión con otras unidades, y de sus entradas externas así la red desarrolla una funcionalidad general a través de entrenamiento (Schalkoff, 1997).

En la figura 2.3 se muestra la neurona artificial realizada por McCulloch y Pitts

Figura 2.3
Neurona artificial



Fuente: Salas (2009).

(1943), y usada por Salas (2009).

El modelo de una neurona artificial también conocido como *McCulloch—Pitts* (1943),

en reconocimiento su trabajo, define una neurona i de la siguiente manera:

(2.1)

$$y_i = \varphi(v_i), v_i = u_i + b_i, u_i = \sum_{j=1}^m w_{ij}x_j$$

donde v_i se denomina “campo inducido local”; x_1, x_2, \dots, x_m son las señales de entrada; w_1, w_2, \dots, w_m son los pesos o ponderaciones; u_i es el sumador; b_i es el sesgo φ ; es la función de activación y y_i es la salida de la neurona.

Con un vector de pesos $\underline{w} = (w_1, \dots, w_d)^T$ equivalente a las conexiones sinápticas en una neurona real, w_0 es el umbral de acción o activación, el vector “ \mathbf{x} ” es la entrada y el escalar “ \mathbf{y} ” la salida de la unidad. Salas (2009).

La actividad consiste en generar una única salida y a partir de la aplicación de la función de activación “ γ ” a la suma ponderada entre el vector de entrada:

(2.2)

$$\underline{x} = (x_1, \dots, x_m)^T$$

y el vector de pesos:

(2.3)

$$\underline{w} = (w_1, \dots, w_m)^T$$

más un sesgo w_0 , obteniéndose la siguiente expresión:

(2.4)

$$y = \gamma \left(\sum_{i=1}^m w_i x_i + w_0 \right)$$

Posteriormente, existen los siguientes tipos de función de activación en una neurona artificial:

a. Función de umbral:

(2.5)

$$\varphi = \begin{cases} 1, & \text{si } v \geq 0 \\ 0, & \text{si } v < 0 \end{cases}$$

donde φ es la función de activación y v es el campo inducido local de la neurona.

b. Función selectiva lineal la cual resulta de una ampliación del modelo original teniendo

(2.6)

$$\varphi = \begin{cases} 1, & \text{si } v \geq 1/2. \\ v, & \text{si } -1/2 \leq v < 1/2. \\ 0, & \text{si } v < -1/2. \end{cases}$$


c. Función Sigmoidal: típicamente se utiliza y es la función sigmoidal o logística definida como

(2.7)

$$\varphi(v) = \frac{1}{1 + \exp(-\alpha v)}$$

donde α es el parámetro de la pendiente de la función sigmoidal, con variación del parámetro se obtienen funciones con diferentes pendientes como se observa en la figura 2.4. Una propiedad importante de la función sigmoidal es su diferenciabilidad, mientras que la función umbral no lo es, dicha propiedad permite definir un método de adaptación con el cual el modelo neuronal irá mejorando progresivamente sus respuestas a medida que sea alimentado con más datos de entrenamiento. Salas (2009).

Figura 2.4.
Función sigmoidea



Fuente: Física USC (2016)

Salas (2009), menciona que el último componente requerido en es una función cuyo valor resultante es la salida de la neurona “ i ”. Para determinar qué valor se transfiere a las neuronas vinculadas se define un umbral si la función de activación está por debajo de él, ninguna salida se pasa a la neurona subsiguiente, sin embargo, no cualquier valor es permitido como una entrada para una neurona, pues estos están comprendidos en el rango $[0, 1]$ o $[-1, 1]$ o de tipo binarios $\{0, 1\}$ o $\{-1, 1\}$.


Por consiguiente, el interés de las RNA no reside solamente en el modelo del elemento PE sino en las formas en que se conectan estos elementos procesadores, generalmente están organizados en grupos llamados niveles o capas por lo que una red

típica consiste en una secuencia de capas con conexiones entre capas adyacentes consecutivas. Existen dos capas de manera general con conexiones con el mundo exterior. Una capa de entrada, donde se presentan los datos a la red, y una capa de salida que mantiene la respuesta de la red a una entrada el resto de las capas reciben el nombre de capas ocultas. (Salas, 2009),

La propiedad más importante de las redes neuronales artificiales es su capacidad de encontrar un modelo que ajuste los datos de manera automática a partir de datos de entrenamiento ya observados de manera que estos son la información histórica del contexto en las que se desarrolla el fenómeno que se pretende analizar y a cada evento se le asocia un resultado de tal evento (el fenómeno en sí). (Mehryar et al., 2012).

Un resumen Gráfico de una red neuronal es mostrado, por el Children Boston

Figura 2.5
Red neuronal



Fuente: Children Boston Hospital (2015)

Hospital online, que se observa en la figura 2.5

Donde los cuadros azules son la capa de entrada siendo estímulos o variables de entrada, las células serían los PE, las filas representan las capas ocultas, las conexiones la función de transferencia y el círculo verde la capa de salida.


2.4 Clasificación de las RNA's de acuerdo a su topología y aplicación

Hasta ahora se ha descrito el funcionamiento de una neurona individual, sin embargo, el modelo de red neuronal basa su funcionamiento, poder y versatilidad en la suma de esfuerzos de múltiples neuronas, la conexión entre los datos de entrada y la forma en la que las neuronas van ponderando la importancia de tales entradas, así como la relación que se establece entre cada neurona, es lo que permite obtener un modelo robusto y sofisticado. Basogain (2014).

La topología o arquitectura de una red neuronal consiste en la organización y disposición de las neuronas en la misma, formando capas o agrupaciones de neuronas alejadas de la entrada y salida de dicha red, de tal forma, existen dos tipos de red neuronal: de una sola capa o de varias capas (multicapa) por lo que los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. Matich (2001).

La arquitectura de una capa se observa en la figura 2.6 donde destaca la sencillez con la que se conforma. Cada señal de entrada está conectada con todas las neuronas de la capa.


Figura 2.6
RNA, una capa



Fuente: Elaboración propia con base en: Arte e inteligencia artificial

La segunda tipología es la multicapa, ilustrada en la figura 2.7, que se distingue por la presencia de una o más “redes escondidas” ubicadas entre la capa conectada a las señales de entrada y la capa de salida (la que arroja el valor pronosticado u objetivo). En estas redes, las señales de entrada viajan por las sinapsis de las neuronas de la primera capa en las que son procesadas para posteriormente emitir un valor resultado el cual, a su vez, sirve como valor de entrada para las neuronas de la capa escondida. El proceso se repite con la siguiente capa, que puede ser otra capa escondida o bien, la capa de salida. En la capa de salida, el resultado es la estimación del valor de la etiqueta. Basogain (2014).

Figura 2.7
RNA multicapa



Fuente: Elaboración propia con base en: Arte e inteligencia artificial (2011)


Se pueden encontrar las siguientes variantes:

- a. El perceptrón: es una forma de RNA mono capa útil para el caso en que pretenda modelar un fenómeno de clasificación cuyas señales de salida se encuentren en el conjunto de valores binario "0" ó "1" mientras que los perceptores multicapa tienen la ventaja de ser capaces de modelar

funciones no-lineales. Su característica principal es que están organizadas en varias capas de neuronas, esta técnica fue descrita por Werbos (1974) y también por Rumelhart, et al., (1980).

- b. Redes recurrentes: en este caso, los valores de salida de las neuronas son también de entrada para una capa previa, de forma que se crea un bucle o ciclo de retroalimentación. En la figura 2.8 se observa un ejemplo de esta red. Consiste en una red neuronal de una sola capa en la que la señal de salida también funge como señal de entrada para las demás neuronas. Basogain (2014).

Figura 2.8
RNA recurrente



Fuente: Fuente: Elaboración propia con base en: Arte e inteligencia artificial (2011)

c. Propagación-hacia-atrás: propuesto por Rumelhart, et al., (1980), el algoritmo simula el proceso mediante el cual una red neuronal biológica aprende un comportamiento. Primero, existe un ciclo de propagación en el que se reciben las señales de entrada que viajan a través de las capas de la red neuronal hasta llegar a la señal de salida de la última capa. Segundo, la señal de salida obtenida se compara con el verdadero resultado del estímulo registrado, que es la variable etiqueta. En esta comparación se utiliza un criterio para verificar que tan similares son ambos valores (el criterio de mínimos cuadrados es el criterio típicamente utilizado). En tercer término, de tal comparación surge una señal de error que se propaga hacia atrás en cada una de las neuronas de las capas de la red, relativa a la contribución que tuvo cada neurona en el error de la señal de salida. Finalmente se actualizan los pesos de las entradas de cada neurona con el objetivo de minimizar el error que existe entre la señal de salida y la variable etiqueta.

Basogain (2014), en su texto hace un resumen práctico, donde clasifica los tipos de redes neuronales con base en la utilidad, los problemas y situaciones que estas son capaces de realizar o resolver y aplicar (Tabla 2.1).

Tabla 2.1

Tipos de RNA de acuerdo al problema que resuelve y características de diseño

| Red | Problema | Año | Diseñador | Características |
|-----------------------------------------------------|-------------------|---------|----------------------------|----------------------------------------------------------------------------------------------|
| Adaline y Madaline | Predicción | 1960 | Bernard Widrow | Técnicas de Adaptación para el Reconocimiento de Patrones. |
| Adaptive Resonance Theory Networks (ART) | Conceptualización | 1960-86 | Carpenter, Grossberg | Reconocimiento de Patrones y Modelo del Sistema Neuronal. Concepto de Resonancia Adaptativa. |
| Back-Propagation | Clasificación | 1985 | Rumelhart y Parker | Solución a las limitaciones de su red predecesora el Perceptron. |
| Bi-Directional Associative Memory (BAM) Networks | Asociación | 1987 | Bart Kosko | Inspirada en la red ART. |
| The Boltzmann Machine | Asociación | 1985 | Ackley, Hinton y Sejnowski | Similar a la red Hopfield. |
| Brain-State-in a Box | Asociación | 1970-86 | James Anderson | Red Asociativa Lineal. |
| Cascade-Correlation-Networks | Asociación | 1990 | Fahhman y Lebiere | Adición de nuevas capas ocultas en cascada. |
| Counter-Propagation | Clasificación | 1987 | Hecht-Nielsen | Clasificación Adaptativa de Patrones. |
| Delta-Bar-Delta (DBD) Networks | Clasificación | 1988 | Jacobb | Métodos Heurísticos para Acelerar la Convergencia. |
| Digital Neural Network Architecture (DNNA) Networks | Predicción | 1990 | Neural Semiconductor Inc | Implementación Hardware de la función Sigmoid. |
| Directed Random Search (DRS) Networks | Clasificación | 1965-81 | Maytas y Solis | Técnica de valores Random en el mecanismo de Ajuste de Pesos. |
| Functional-link Networks (FLN) | Clasificación | 1989 | Pao | Versión mejorada de la red Backpropagation. |
| Hamming Networks | Asociación | 1987 | Lippman | Clasificador de vectores binarios utilizando la Distancia Hamming. |
| Hopfield Networks | Optimización | 1982 | Hopfield | Concepto de la red en términos de energía. |
| Learning Vector Quantization (LVQ) Networks | Clasificación | 1988 | Kohonen | Red Clasificadora. |
| Perceptron Networks | Predicción | 1950 | Rosenblatt | Primer modelo de sistema Neuronal Artificial. |
| Probabilistic Neural Network (PNN) | Asociación | 1988 | Spetcht | Clasificación de Patrones utilizando métodos estadísticos. |
| Recirculation Networks | Filtrado | 1988 | Hinton y McClelland | Alternativa a la red Backpropagation. |
| Self-Organizing Maps (SOM) | Conceptualización | 1979-82 | Kohonen | Aprendizaje sin supervisión |
| Spatio-Temporal-Pattern Recognition (SPR) | Asociación | 1960-70 | Grossberg | Red clasificadora Invariante en el espacio y tiempo. |

Fuente: Basogain (1998)

2.5 Ejemplos y Aplicaciones de las redes neuronales

En esta sección se mostrarán algunos casos en los que se ha registrado dentro de la plataforma *Kaggle's data science competitions*. la poderosa herramienta que son las redes neuronales en la predicción de fenómenos de diversa índole:

a. Para el desarrollo de medicamentos seguros y efectivos:

Este proyecto surge de la problemática que se tiene en la industria farmacéutica en el desarrollo de medicamentos que sean efectivos en el tratamiento de los padecimientos, y al mismo tiempo, que minimicen el riesgo de generar efectos secundarios negativos en los pacientes que los ingieren. Predecir las reacciones biológicas que tienen las moléculas que conforman los agentes activos en los fármacos antes de ser probados en un paciente fue el objetivo del proyecto que se menciona, y en el cual, las redes neuronales fueron una herramienta decisiva.

b. *National Data Science Bowl*:

El plancton es un elemento que tiene una importancia crítica en el ecosistema del planeta pues contribuye, por ejemplo, en fijar más de la mitad del dióxido de carbono en la tierra y es la base de la alimentación para una diversidad de especies marinas. La medición de las poblaciones de plancton permite tener una buena idea de la salud de los océanos y sus ecosistemas.

Para ello se realizó una competencia que consistía en clasificar imágenes de plancton en una de 121 clases diferentes. Tales imágenes fueron tomadas con una cámara submarina. Los investigadores usan estas imágenes para determinar qué especies concurren en un área, sin

embargo, el trabajo suele ser bastante extenso ya que se deben clasificar antes de poder sacar alguna conclusión.

El uso de redes neuronales que pudieran distinguir las imágenes y reconocer los diferentes tipos de plancton fue crucial para permitir a los científicos ahorrar mucho tiempo de investigación y aumentar la precisión de sus conclusiones.

c. *The Galaxy Zoo Challenge:*

Día a día los telescopios en la tierra capturan más y más imágenes de galaxias lejanas. Más y mejores telescopios son desarrollados y contribuyen a la explosión de información recabada. Gracias a estas imágenes nosotros tenemos un mejor y más amplio entendimiento de las leyes físicas que rigen nuestro universo, pero antes es necesario realizar una clasificación de éstas.

En este proyecto, se realizó una serie de preguntas a un grupo numeroso de participantes en las cuales se les solicitaba describir la morfología de las galaxias por medio de una serie de imágenes. Preguntas tales como "¿Qué tan redonda es esta galaxia?" o "¿Tiene una masa central?" son algunos ejemplos de ellas que los usuarios tuvieron que responder.

Como era de esperarse, no todos clasificaron las galaxias de la misma forma, aun así, la respuesta agregada de los participantes, y los porcentajes de cómo algunos describieron una imagen y la catalogaron en un tipo de galaxia, mientras que otros lo hicieron en otra, permitieron obtener un modelo de cómo la multitud "percibe" a una galaxia.

Con esta información fue alimentada una red neuronal que aprendió este modelo de percepción de galaxias y que realiza ahora la clasificación reduciendo los costos y el tiempo invertido.

d. Predicción de salarios:

El uso de las redes neuronales permite dar usos revolucionarios, y un ejemplo es el sector de los recursos humanos. Empresas intermediarias entre la fuerza laboral y las empresas se valen de anuncios en internet para acercar a estos dos grupos.

Los anuncios a menudo son generados por el empleador que describe las aptitudes que se requieren para cubrir el puesto y no siempre informan sobre el salario remunerado. El salario es un dato que muchos solicitantes toman en cuenta para decidir entre una vacante y otra.

Las redes neuronales son usadas para entrenarse a partir de los anuncios de vacantes de trabajo y generar un pronóstico del salario que podría ofrecer el empleador, ayudando así al usuario que busca empleo a tomar mejores decisiones.

e. Predicción del costo de alquiler de una propiedad:

La empresa Deloitte patrocina una competencia cuya finalidad era resolver la problemática de estimar el costo de alquiler de una propiedad en Australia. Los precios de alquiler se ven afectados por múltiples factores, los cuales pueden ser objetivos, como la proximidad a hospitales, escuelas, supermercados; u otros más subjetivos, como el valor estético del patio, por ejemplo.

La estimación del costo de alquiler de una propiedad, tiene un gran valor para entender otras cuestiones económicas como la tasa de desempleo o los ingresos.

Las redes neuronales tienen un punto de oportunidad en esta competencia, al tratarse de un modelo robusto que es capaz de trabajar con múltiples datos no lineales.

2.6 Softwares capaces de usar RNA.

Se describe a continuación las herramientas que se tienen al alcance al momento de realizar esta investigación con fines de mostrar un panorama posible de acción de nuestra parte y para cualquier lector que quiera reproducir los resultados.

2.6.1 Herramientas de RNA en software libre

El software libre, es un conjunto de programas de computadoras desarrollados con fines de que estos logren el mayor alcance posible entre los usuarios, siendo estos gratuitos tanto de uso, como de adquisición junto a modificación, así como de distribución.

a. Framework joone

Es un software con implementación en java para la creación de redes neuronales artificiales, pensado para desarrolladores técnicos que no conocen a profundidad de la teoría de las RNA, permite entrenar un conjunto de redes en paralelo que facilita su extensión al usar algoritmos de entrenamiento, así como la libertad de modificación que permite la licencia libre.

b. SNNS

Es un simulador practico y útil entorno desarrollado para creación, uso en investigación de redes neuronales diseñado en Alemania, específicamente en la universidad de Stuttgart, programado para cualquier entrono Linux.

c. Pythia

Pythia es un editor de redes neuronales de propagación hacia atrás, un tipo de red donde los nodos corrigen su activación a partir de la discrepancia entre los valores iniciales y los valores deseados (que deben ser dados de antemano). Para ello, Pythia es capaz de importar un fichero con el patrón de datos iniciales y finales, siendo solo capaz de resolver ese tipo de arquitectura-

d. R

R, al ser un lenguaje de programación orientado objetos de carácter estadístico, cuenta con algunas librerías interesantes para el uso de redes neuronales, algunas como:

- Package 'nnet': Software para RNA Alimentadas hacia adelante, de capa simple o multicapa
- Package 'Rweka': es una colección de algoritmos de aprendizaje máquina para minería de datos escrito en java, conteniendo herramientas para el pre procesamiento de datos, clasificación, regresión, creación de clusters, reglas de asociación y visualización.
- Package 'AMORE': Se crea tras el nacimiento del algoritmo TAO robusto de redes neuronales, para usuarios de R, haciéndolos capaz de incluir sus propios algoritmos de entrenamiento.

2.6.2 Software de pago

Como su nombre lo indica, estos requieren de una licencia de costo para ejecutarse y acceder a sus funciones, muchas veces los programas incluyen licencia gratis de prueba limitada con posibilidad de poder adquirir una al nivel que el usuario requiere.

a. Neuronal Tools de Apalissade

NeuralTools se usa para tomar decisiones de préstamo de crédito al pronosticar la probabilidad de que un nuevo prestatario devuelva su préstamo. Se usa para reducir el riesgo de las transacciones al identificar las transacciones bancarias o de tarjeta de crédito que tienen mayor probabilidad de ser fraudulentas.

Los centros de atención telefónica lo usan para establecer sus estrategias de personal al predecir el volumen de las llamadas. Los profesionales médicos usan NeuralTools para diagnosticar tumores desconocidos y otros problemas.

b. PSS

SPSS Statistics es un sistema global para el análisis de datos. El módulo adicional opcional Redes neuronales proporciona las técnicas de análisis adicionales.

El módulo adicional Redes neuronales se debe utilizar con el sistema Base de SPSS Statistics y está completamente integrado en dicho sistema.

c. SAS

Es un lenguaje de programación desarrollado por *SAS Institute* a finales de los años sesenta. Existen dos intérpretes de dicho lenguaje: uno desarrollado por *SAS Institute* y otro por la empresa *World Programming*. Es en la actualidad uno de los softwares más importantes y poderosos respecto a sus capacidades estadísticas.

Requiere ser corrido desde una máquina virtual pre programada, en su versión de estudiantes, en su versión de carácter profesional necesita un servidor firmado para su uso.

d. Easynn

Es un software que promete ser sencillo y práctico, capaz de predicción, clasificación y proyección de series de tiempo, además de contar con un amplio soporte de importación de datos, como es el de texto directo o imágenes, además de poder validar las redes a pocos clicks. El software tiene un costo de 79 dólares.

El definir que software es mejor o peor es algo subjetivo pues muchas veces esto depende de la habilidad del usuario para el desarrollo y programación desde su interpretación del problema hasta la implementación de las herramientas descritas. En el caso de esta investigación, se usó R como herramienta para el desarrollo por su facilidad, por su crecimiento, por su fácil implementación en cualquier plataforma y para poder tener acceso libre a él.

Con esto se da por terminado la presentación de la técnica con la que se llevó a cabo esta investigación, siendo el uso de la misma el mayor aporte, se empleó R como herramienta por su facilidad, su crecimiento, capacidad de implementación en cualquier plataforma y para poder tener acceso libre a él. Así damos paso al capítulo 3, la estimación y desarrollo de los modelos

Capítulo 3

Capítulo 3

Modelos basados en RNA para determinar el comportamiento del Tipo de Cambio Mexicano y su contraste con modelo GLM y GARCH

En este capítulo se desarrolló la estimación de los modelos, primero se da paseo por las variables macroeconómicas a usar mostrando sus propiedades básicas, posteriormente se muestra el tipo de tratamiento que se dio junto al entrenamiento requerido y el tipo de validación que se dio a los modelos estimados, dando paso a la estimación y características de los modelos y por último las conclusiones de la investigación.

3.1 Variables

Con base en las teorías y los artículos revisados se ocuparon 16 variables totales, todas descargadas del banco de información económica del INEGI disponible al 25 de noviembre del 2015, las cuales son resumidas en la tabla 3.1 y a continuación desarrolladas, así como una décimo séptima variable usada; el tipo de cambio con un rezago, creada por nosotros para fines de la investigación.

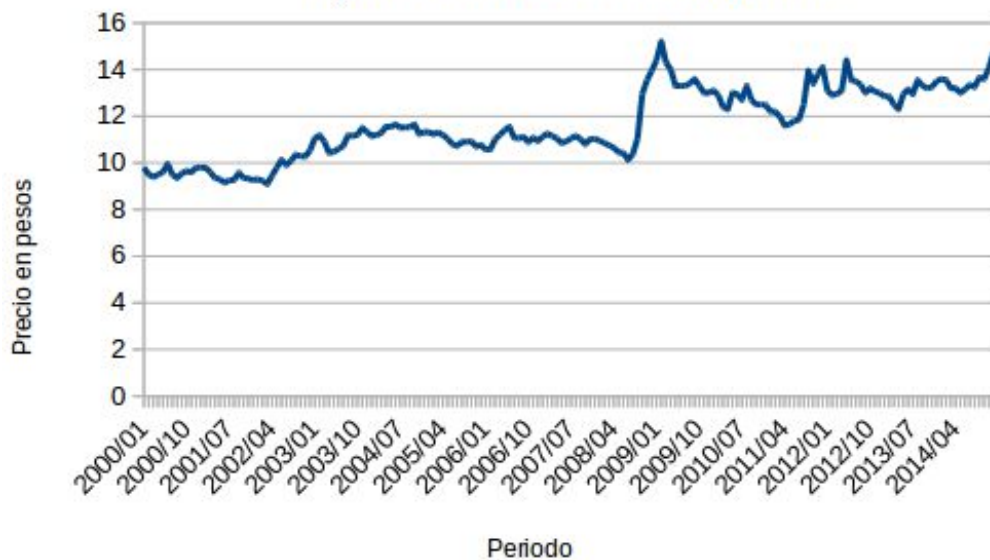
Tabla 3.1
Resumen de variables.

| Nombre de la Variable | Carácter | Tipo | Periodicidad | Unidad |
|------------------------------------------------------------------------|---------------|----------------------------------------------------------------------|--------------|----------------------------------------|
| Tipo de cambio bancario | Dependiente | Indicador Financiero y Bursátil | Mensual | Pesos |
| Producto Interno Bruto | Independiente | Indicador Económico de Coyuntura | Trimestral | Millones de pesos a precios de 2008. |
| Balanza de pagos | Independiente | Sector externo, cuenta corriente | Trimestral | Millones de Dólares |
| Balanza de pagos USA | Independiente | Indicadores internacionales | Trimestral | Miles de millones de Dólares |
| Inversión extranjera total | Independiente | Sector externo, Balanza de pagos | Trimestral | Millones de Dólares |
| Inversión Directa USA | Independiente | Indicadores internacionales | Trimestral | Miles de millones de dólares |
| Ingresos del sector público | Independiente | Finanzas Públicas | Mensual | Millones de pesos a precios corrientes |
| Ingresos del sector público Gobierno | Independiente | Finanzas Públicas | Mensual | Millones de pesos a precios corrientes |
| Gasto Presupuestal Total | Independiente | Finanzas Públicas | Mensual | Millones de pesos a precios corrientes |
| Tasa de Interés interbancaria de equilibrio | Independiente | Indicadores económicos de coyuntura, indicadores financieros | Mensual | Tasa anual |
| Tasa de fondos federales (efectiva) | Independiente | Tasa de interés en los mercados internacionales, tasa de interés USA | Mensual | Tasa anual |
| Deuda externa total | Independiente | Sector externo, Saldo de la deuda externa bruta del sector público | Mensual | Millones de Dólares |
| Saldo de deuda externa, reestructurada | Independiente | Sector externo, según fuentes de financiamiento | Mensual | Millones de dólares |
| Saldo de la deuda externa bruta del sector público, Comercio exterior. | Independiente | Sector externo, según fuentes de financiamiento | Mensual | Millones de dólares |
| Banca de desarrollo | Independiente | Sector externo | Mensual | Millones de Dólares. |

Fuente: Elaboración Propia.

- a. Tipo de cambio: se usó el precio de venta del tipo de cambio bancario como variable dependiente, surge de la cotización del dólar en el mercado cambiario nacional previo a la especulación y venta interbancaria, INEGI (2015) muestra de fuente a INTERCAM. La figura 3.1 muestra el comportamiento de la serie del tipo de cambio en niveles, se aprecia una tendencia positiva, y una variación importante debido a la crisis del 2008, el dato más bajo presentado es el de marzo del 2003, con un valor de \$9.09 y el más alto es el de Febrero del 2009 con valor de \$15.2, algo bajo considerando el precio actual, pero no es tópico de esta investigación, así como un valor promedio de \$11.64.

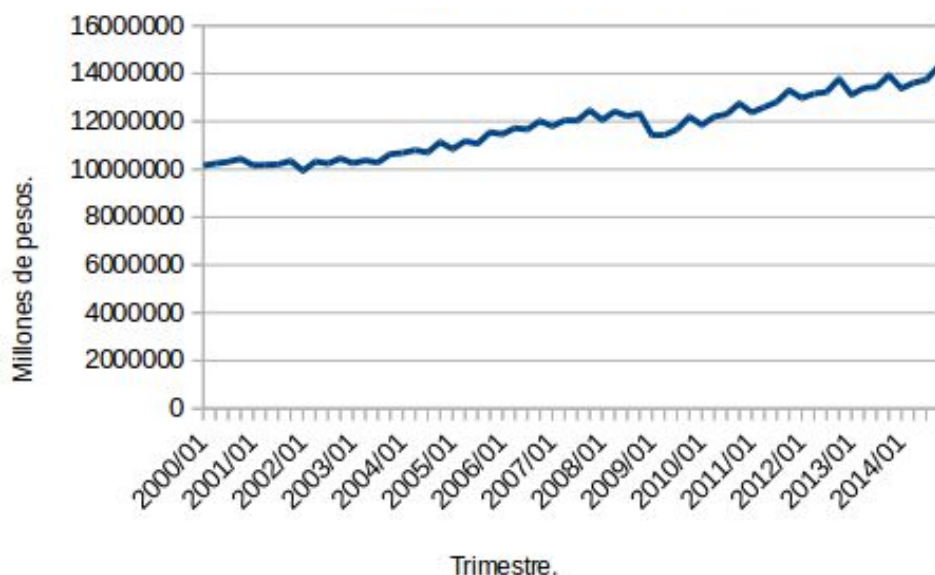
Figura 3.1
Tipo de cambio peso/dólar a la venta



Fuente: Elaboración propia, con base en INEGI (2015).

b.Producto Interno mexicano: valor del PIB donde se reflejan los valores finales de los productos producidos dentro del país, tiene una periodicidad trimestral por lo que se interpolará los valores intermedios para generar así una serie mensual, la serie original tiene elaboración del INEGI (2008). En la figura 3.2 se muestran los datos de PIB por cada trimestre desde el 2000 al 2014, es una serie con tendencia positiva, mostrando claramente la crisis del 2008 y algunas recuperaciones positivas en años posteriores. El dato menor es el correspondiente al primer trimestre del 2002 con 9'937,775.01 mmd y el más alto con 14'307,437.326 el último trimestre del 2014, el promedio es: 11'763,298.37.

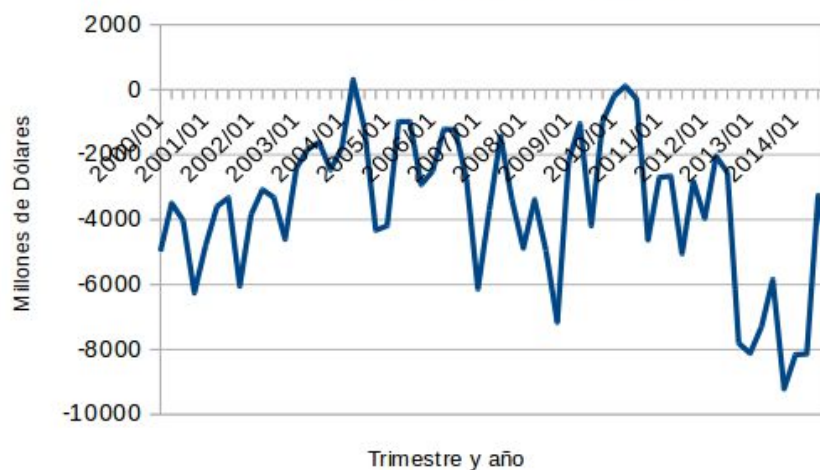
Figura 3.2
Producto Interno Bruto



Fuente: Elaboración propia, con base en INEGI (2015).

c. Balanza de Pagos, total de cuenta corriente: específicamente el componente de la balanza de pagos del país (figura 3.3), la variable está medida en millones de dólares, de periodicidad trimestral por ser interpolará geométricamente, es generada por el banco de México y consultada en INEGI (2015). En la figura no se muestra una tendencia definida, el componente predominante es el cíclico, con dos grandes incrementos pertenecientes al comienzo de año del 2005 y del 2011; el dato menor, sería el logrado en 2013 para el cuarto trimestre, y el más alto sería: 306.801 en el segundo trimestre del 2004. El promedio está definido por: -3,616.12 millones de dólares.

Figura 3.3
Total de cuenta corriente



d. Balanza de pagos para Estados Unidos (USA) saldo en cuenta corriente: se consideran las contra partes de las variables que determinan el ecosistema y entrono del peso en Estados Unidos usando las series públicas en INEGI (2015) dentro de sus secciones de indicadores internacionales (figura 3.4). Está medida en miles de millones de dólares con base en cifras del Fondo Monetario Internacional (FMI). En el periodo de estudio, la serie no muestra una tendencia clara, sin embargo, en el componente cíclico existe una caída para el año 2007 – 2008, resultado de la crisis americana dada en ese año – periodo. El dato menor es: -231.748 miles de millones del tercer trimestre del 2006, el más alto el del primer trimestre del 2014 con -73.162 miles de millones de dólares; el promedio es: -131.36 miles de millones.

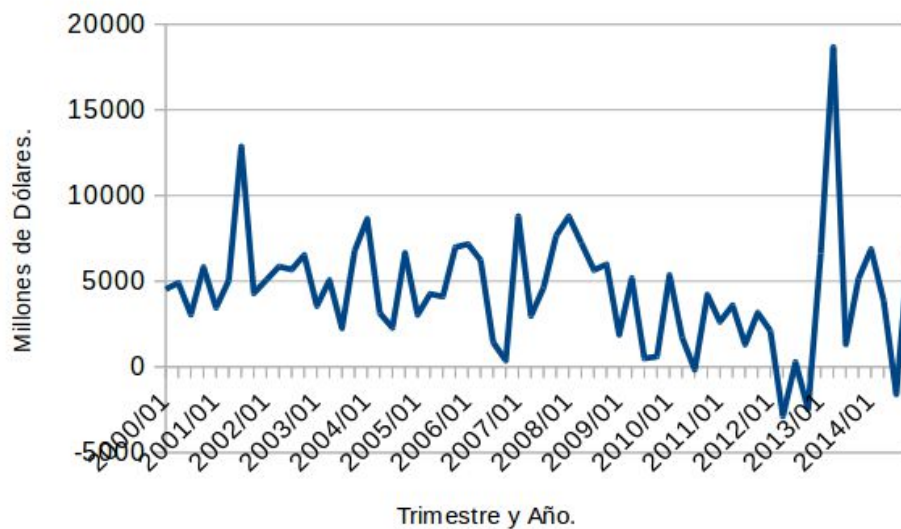
Figura 3.4
Saldo de Cuenta corriente USA



Fuente: Elaboración propia, con base en INEGI (2015).

e. Inversión extranjera (total) directa en México: La serie de datos de la inversión extranjera directa en México pertenece a la balanza de pagos mexicana, específicamente, a la cuenta financiera (figura 3.5), está medida en millones de dólares y es creada por el banco de México y publica por INEGI (2015), de periodicidad trimestral así que requerirá interpolación para generar una serie mensual. El dato más bajo es: -2,878.54 perteneciente al segundo trimestre del 2012, el más alto 18,665.68, para el segundo trimestre del 2013, así como el promedio es: 4,422.03 millones de dólares.


Figura 3.5
Inversión extranjera México



Fuente: Elaboración propia, con base en INEGI (2015).

- f. Inversión directa Estados Unidos: aquella que se canaliza a los sectores productivos y puede traducirse en nuevas inversiones o reinversiones. (El signo menos indica un débito) INEGI (2015). Esta variable es parte de la balanza de pagos con periodicidad trimestral por lo que al igual que las otras variables trimestrales necesita tratamiento, está medida en miles de millones de dólares y su fuente es el fondo monetario internacional (Figura 3.6). El dato menor es: -165.109, perteneciente al primer trimestre del 2014, el más alto es: 107.396, el valor promedio: -19.96.

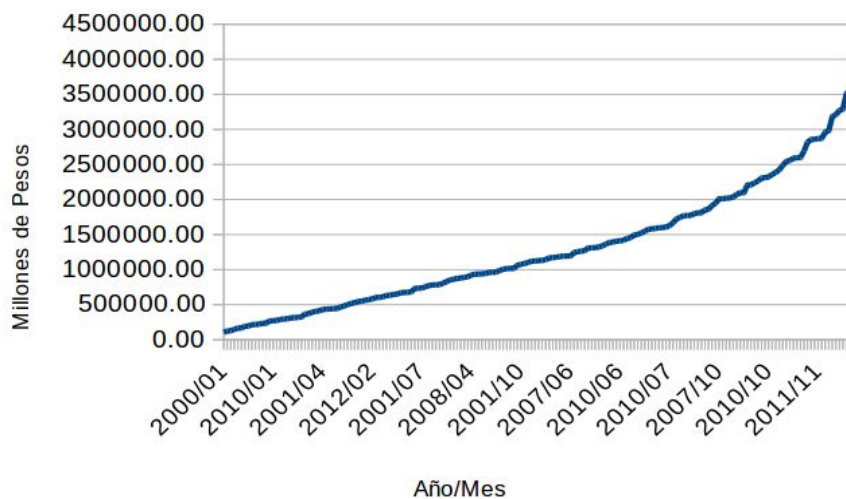
Figura 3.6
Inversión directa USA



Fuente: Elaboración propia, con base en INEGI (2015).

g. Ingresos del Sector Público: esta serie (Figura 3.7) muestra el total registrado por mes correspondiente al ingreso del sector público se encuentra disponible en la sección de finanzas públicas del INEGI (2015) y medido en millones de pesos corrientes; su fuente es: SHCP (en la dirección general adjunta de estadística). Se observa en un incremento progresivo de los ingresos públicos, donde el dato menor fue registrado en enero del 2000 con 106082.50 millones de pesos corrientes y el más alto en diciembre del 2014 con 3983411.60 millones de pesos corrientes; el Promedio es: 1304261.95

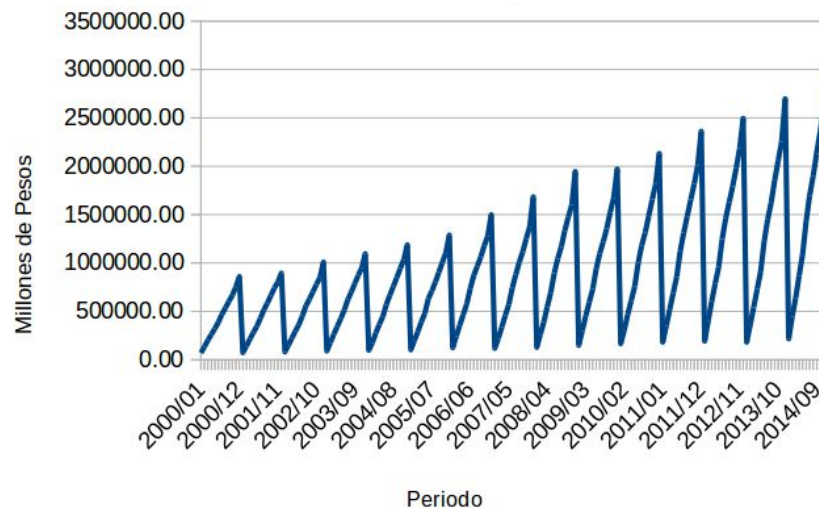
Figura 3.7
Ingresos del sector Público total



Fuente: Elaboración propia, con base en INEGI (2015).

h. Total de ingresos del sector público; gobierno federal: estos datos corresponden a los gastos reportados por todo el sector público, tienen una periodicidad mensual y fuente: “SHCP. Dirección General Adjunta de Estadística de la Hacienda Pública. Unidad de Planeación Económica de la Hacienda Pública” (INEGI, 2015). Son cifras acumuladas de manera que se excluye a las empresas denominadas *chiquillería*. En la Figura 3.8 se muestra un aumento progresivo y un retroceso amplio debido a las características de cálculo de la variable; el valor más bajo es: 88732.20 del primer mes del 2000, el más alto es: 2888059.58 del último mes del 2014, así como el promedio es: 952464.31.


Figura 3.8
Total de ingreso presupuestado de gobierno



Fuente: Elaboración propia, con base en INEGI (2015).

- i. Gasto total presupuestal de gobierno: esta serie (Figura 3.9) muestra el gasto excluyendo las aportaciones del gobierno federal al ISSSTE y las transferencias a entidades bajo control directo presupuestario. Tiene por fuente “SHCP. Dirección General Adjunta de Estadística de la Hacienda Pública. Unidad de Planeación Económica de la Hacienda Pública” (INEGI, 2015). Está medido en Millones de pesos a precios corrientes, el dato más pequeño es enero del 2000 el mayor es de diciembre del 2014, al igual que la anterior, es una serie creciente en el tiempo reportando datos bajos al inicio de los años y datos altos en los finales de ellos.

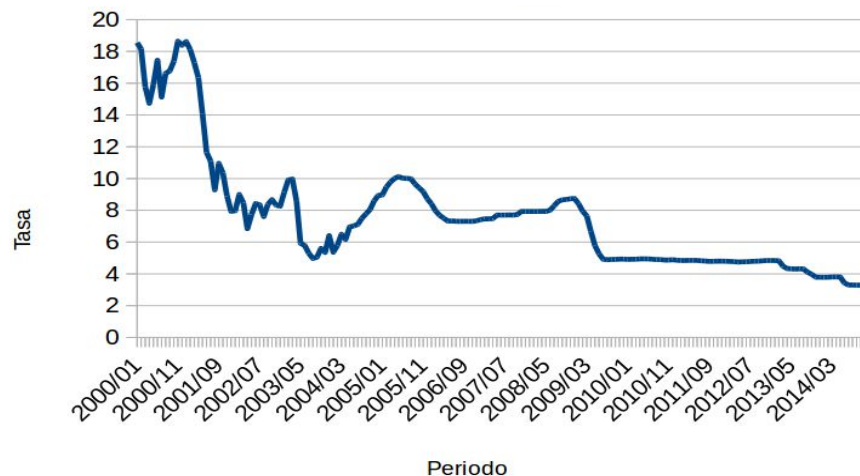
Figura 3.9
Gasto del sector público total



Fuente: Elaboración propia, con base en INEGI (2015).

- j. Tasa de interés interbancaria de equilibrio (TIIE): serie mensual creada con el objeto de establecer una tasa que refleje mejor las condiciones del mercado. El Banco de México la dio a conocer a través del diario oficial de la federación y la determina con base en las cotizaciones que presentan las instituciones de crédito. (Figura 3.10) muestra un comportamiento decreciente a través del tiempo, y a partir del 2009 un comportamiento estable. El dato más pequeño es el reportado es 09 de 2014 con 3.29, el más alto en noviembre del 2000, con 18.64 y el valor promedio: 7.552.


Figura 3.10.
Tasa de interés interbancaria de equilibrio



Fuente: Elaboración propia, con base en INEGI (2015).

k. Tasa de interés de los Estados Unidos (fondos federales): disponible en la página del INEGI en su sección de indicadores económicos y financieros (Figura 3.11). Tiene una periodicidad mensual y fuente al Banco de México, la serie al igual que la tasa interbancaria de equilibrio mexicana posee una tendencia a la baja, sin embargo, presenta un pico de recuperación de valor a finales del 2005 y hasta el 2008, donde nuevamente se ve disminuida. El valor más pequeño es reportado en Julio del 2011 con 0.07 y el más alto el de julio del 2000 con 6.54; el valor promedio es 2.01.


Figura 3.11
Tasa de interés fondos federales



Fuente: Elaboración propia, con base en INEGI (2015).

- I. Saldo total de la deuda externa bruta (sector público). Esta serie (Figura 3.12) muestra el total de adeudo con el sector exterior por parte del sector público, está medido en millones de dólares, así como posee una periodicidad mensual. El INEGI especifica su elaboración en la Unidad de Crédito Público. La serie, no posee una tendencia marcada, a la baja en una primera etapa alrededor de la crisis del 2008 y posteriormente un incremento al final del periodo de análisis traducida en poca estabilidad macroeconómica del país (INEGI, 2015). El dato mayor es el de octubre de 2014 y el más bajo se presentó en noviembre del 2008, el saldo promedio es: 91255.982 millones de pesos.


Figura 3.12
Saldo de deuda externa



Fuente: Elaboración propia, con base en INEGI (2015).

m. Deuda externa según fuentes de financiamiento del comercio exterior: muestra el saldo desde el punto de vista del sector externo. Es generada por la *Secretaría de Hacienda y Crédito Público* específicamente en la *Unidad de Crédito Público*, (Figura 3.13). La serie mensual y medida en millones de dólares muestra un comportamiento a la baja hasta llegar al año 2008 donde la crisis americana provoca un incremento. INEGI (2015), el dato menor es noviembre del 2008, y el mayor diciembre del 2010 con un promedio de: 7966.35 millones de dólares.


Figura 3.13
Deuda externa, financiamiento del comercio exterior



Fuente: Elaboración propia, con base en INEGI (2015).

n. Banca de desarrollo: serie publicada en INEGI (2015) parte del sector externo y en la toma de decisiones del comercio de forma repercute en el tipo de cambio pues lo alienta. En esta serie (Figura 3.14), se observa que, a partir del 2004, el apoyo a través de esta banca fue de picada, tocando su punto más bajo en octubre del 2008, el INEGI muestra como fuente: “público”, esta medida en millones de dólares y una periodicidad mensual con promedio de 7210.44.

Figura 3.14.
Banca de desarrollo



Fuente: Elaboración propia, con base en INEGI (2015).

- o. Deuda Externa Reestructurada: serie correspondiente a la deuda externa bruta del sector público desde el punto de vista de fuentes de financiamiento después de los ajustes dados por las entidades gubernamentales correspondientes (INEGI, 2015)
- p. Tipo de cambio con rezago y *growth domestic product* (GDP): por último y para ampliar el análisis, se empleará la serie de tipo de cambio original usada como variable dependiente, pero aplicando un rezago en ella, esto para poder hacer el modelado en forma de serie de tiempo, así como el equivalente al PIB, el GDP americano.

3.2 Tratamiento de datos, preparación y submuestreo de la información para su modelación

Los datos en las series expuestas anteriormente son mayormente mensuales, sin embargo, algunas como el caso de PIB mexicano, el *growth domestic product* (GDP) americano, la tasa de interés interbancaria de equilibrio, son trimestrales, para lo cual se interpolaron geoméricamente los datos faltantes (Véase comienzo del código en el anexo 1) así hacer que la base de datos sea introducida como una matriz cuadrada sin datos del tipo *NA (not available)*, En ella, se definió al tipo de cambio real de México como la variable objetivo a estimar y se dispuso que las columnas fueran las variables y las filas las observaciones en forma de serie de tiempo.

Tras haber preparado los datos es permisible dividir en submuestras con la intención de asegurar se cuente con un modelo que sea general y que tenga la capacidad de emitir estimaciones del tipo de cambio a partir de eventos aún no registrados. En los modelos de RNA la muestra llamada *muestra de entrenamiento* tiene la finalidad de que

el modelo aprenda el comportamiento de los datos, mientras que la muestra de validación permite elegir de forma el conjunto de parámetros del modelo que den óptimos resultados. Finalmente, la muestra de prueba es la submuestra que se utiliza para medir el desempeño en cuanto a la capacidad predictiva de los modelos y así realizar una comparación entre ellos.

El criterio usado para determinar la extensión de las submuestras se basó en el estudio de Guyon (1997), en el, enuncia que la proporción de la muestra de validación debe ser inversamente proporcional al cuadrado del número de parámetros libres observables del modelo. Un ejemplo de esto sería: Si se cuenta con 16 parámetros ajustables en el modelo, la raíz cuadrada de este número de parámetros es 4; por tanto, se concluye que la proporción debería ser $1/4 = 0.25$. Aproximadamente, un 25% de los datos deberían ser reservados para la submuestra de prueba y el 75% restante para la submuestra de entrenamiento del modelo. Del 75% restante para el entrenamiento de datos, se realizó una validación-cruzada de 10 pliegues, como sugiere el estudio de Kohavi (1995)

3.3 Validación de los modelos

A los modelos de RNA y al modelo lineal se les realizó una primera validación en cruz que consiste en primero dividir la muestra en grupos o "pliegues" (definidos por el usuario) y entrenar a los modelos con todos los grupos a excepción de 1, que se utiliza para calificar o "validar" el desempeño del entrenamiento, este proceso se repite sustituyendo la submuestra de validación en cada iteración y como último paso se promedian los resultados para obtener una estimación confiable de la calificación.

La paquetería elige la función y parámetros necesarios que toma de una lista con posibles valores los cuales se prueban de manera iterativa para obtener la mejor configuración y los valores óptimos de dichos parámetros (así lograr la mejor calificación conjunta). En el caso del modelo GARCH la librería RUGARCH realiza el tratamiento y pruebas pertinentes para lograr una estimación firme (Véase anexo 2), no se profundizará en ello pues no es el objetivo de esta investigación.

El contraste entre ellos se realizó utilizando el criterio de **la raíz del error cuadrado medio** (RMSE, por sus siglas en inglés); el error cuadrático medio (MSE) mide el promedio de los errores al cuadrado, es una función de riesgo, correspondiente al valor esperado de la pérdida del error al cuadrado o pérdida cuadrática. La diferencia se produce debido a la aleatoriedad o porque el estimador no tiene en cuenta la información que podría producir una estimación más precisa. (Lehmann et.al., 1998)

El MSE es el segundo momento del error por lo tanto incorpora tanto la varianza del estimador, así como su sesgo. Para un estimador insesgado, el MSE es la varianza del estimador. Al igual que la varianza, el MSE tiene las mismas unidades de medida que el cuadrado de la cantidad que se estima. En una analogía con la desviación estándar, tomando la raíz cuadrada del MSE produce el error de la raíz cuadrada de la media o la desviación de la raíz cuadrada media (RMSE), que tiene las mismas unidades que la cantidad que se estima; para un estimador insesgado, el RMSE es la raíz cuadrada de la varianza, conocida como la desviación estándar, se define de la siguiente manera:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y)^2}{n}} \quad (3.1)$$

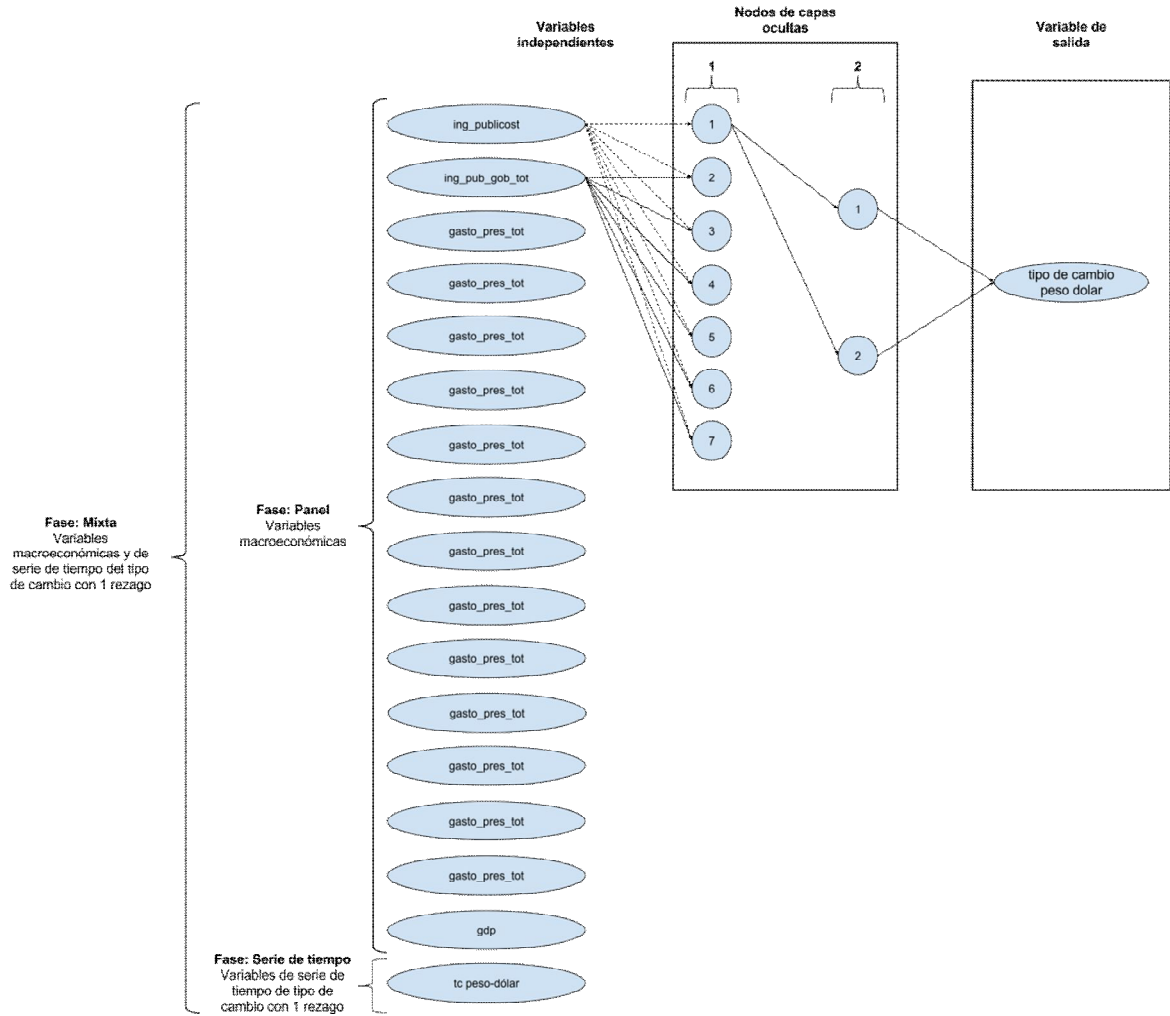
Se aplicó RMSE a los valores de salida de los modelos para comparar su desempeño y se sacó un error de estimación con base en el valor real del periodo estimado como pronóstico. (Lehmann et.al., 1998)

3.4 Estimación de los modelos

Como se comentó, el trabajo sustenta su diseño y desarrollo en programación haciendo uso del paquete de software estadístico R, actualmente existe un creciente uso de este lenguaje en las áreas económico-administrativas, por ello esta tesis es impulsor de futuras investigaciones en el uso continuo de este lenguaje en nuestra facultad. Se codificó una rutina de programación con esta herramienta, (véase Anexo 1) y cuya operación se resumen en el diagrama del de flujo de la figura 3.15

Figura 3.15

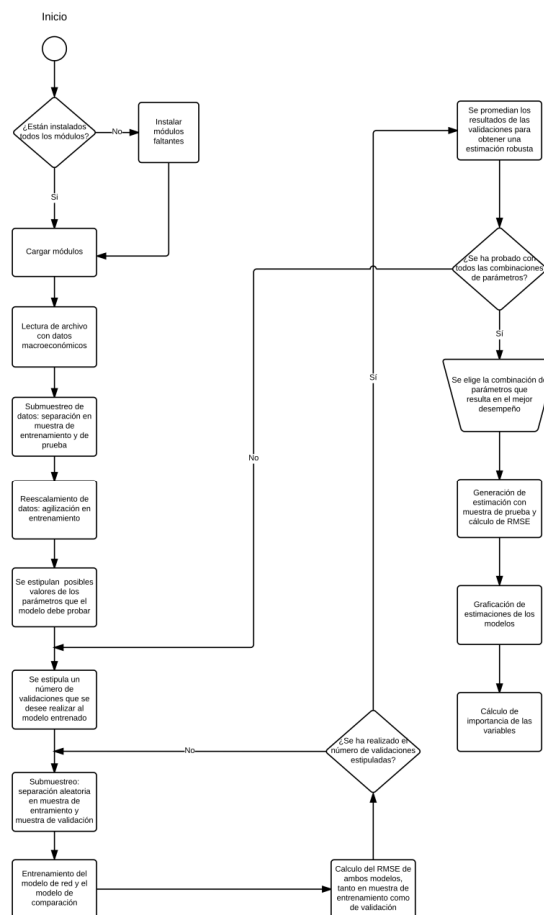
Modelos RNA's para el tipo de cambio y las fases de estimación



Fuente: Elaboración Propia.

El procedimiento (Figura 3.16) mediante el cual se determinó la estructura óptima de la red en todos los modelos de RNA's fue de "prueba-error automatizado", en el cual el sistema conservó la estructura que le daba un mejor rendimiento. Este procedimiento se validó iterativamente con el método cruzado realizando 20 fases de validación únicas

Figura 3.16
Diagrama de Flujo



Fuente: Elaboración Propia

para los tres modelos de RNA's.

Durante la estimación de todos los modelos de la tesis, se usaron las siguientes librerías:

- a. *Neuralnet*: librería que contiene las herramientas necesarias para generar, entrenar y aplicar una red neuronal.
- b. *Plyr*: Es una librería auxiliar para el tratamiento de datos previo a la realización de gráficas y comparación de diagramas.
- c. *Reshape* y *reshape2*: Las librerías *reshape* son auxiliares para el paquete *plyr* y *ggplot*.
- d. *Scales*: *Scales* es una librería que contiene funciones para el re-escalamiento y normalización de datos en tablas.
- e. *Ggplot*: Consta de un lenguaje y herramientas para producir gráficos.
- f. *Rugarch*: Es una librería para generar modelos de series de tiempo de tipo GARCH, así como las pruebas necesarias para ello.
- g. *Glm*: Requerido en la realización de modelos lineales y sus validaciones.

La estimación se dividió en 3 etapas, en la primera se estimó un modelo de redes neuronales artificiales en forma de panel, donde los nodos de entrada son las variables independientes previamente descritas en este capítulo y es comparado con un modelo de predicción lineal. En la segunda, se estima un modelo de RNA's aplicándole un rezago (ya que solo un rezago, es el óptimo según los datos de entrada determinado por la paquetería) y es comparado con un modelo GARCH a través del mismo criterio. Y, por último, a la red neuronal de panel de la primera fase se le agrega como variable

independiente la propia serie de tiempo del tipo de cambio, con el rezago que es usado en la segunda fase, para ver si el resultado mejora o no.

3.4.1 Primera fase: Estimación de RNA de panel y modelo lineal para su comparación

Se determinó después del proceso de validación, de normalización y establecer los conjuntos de entrenamiento y error, una red del tipo perceptrón multicapa capaz de interpretar el comportamiento del tipo de cambio en forma de panel con arquitectura: 16:7:2:1 de autoaprendizaje con funciones de transferencia tipo logística en ambas capas la tasa de aprendizaje se fijó en 0.01, los demás parámetros se conservaron en sus valores por defecto según la paquetería. De manera paralela, el modelo lineal solo requiere ser alimentado por un conjunto de datos y definir el tipo de las variables puesto que si un cambio de estructura de datos o tratamiento es requerido la paquetería lo realiza automáticamente y arroja un objeto directo con los cuales se obtiene el pronóstico junto a un error que mide su precisión y sus gráficos.

En promedio, los errores para el modelo lineal fueron de \$ 1.28 y \$ 1.26 pesos para el entrenamiento y validación, respectivamente; para para la red neuronal de panel fueron \$ 0.038 y \$ 0.064 de entrenamiento y validación respectivamente con un RMSE de 0.16. Lo anterior se aprecia en la tabla 3.2

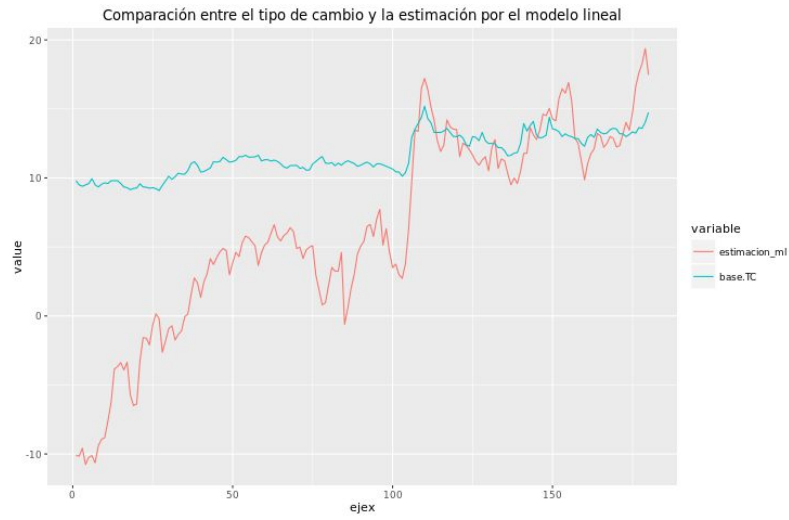
Tabla 3.2
RNA vs modelo GLM

| no. validación | modelo lineal | | red neuronal | |
|----------------|---------------|------------|---------------|------------|
| | entrenamiento | validación | entrenamiento | validación |
| 1 | 1.30135 | 0.86804 | 0.03458 | 0.05641 |
| 2 | 1.24760 | 1.86690 | 0.03895 | 0.04514 |
| 3 | 1.27872 | 1.87881 | 0.04995 | 0.02979 |
| 4 | 1.30721 | 1.24150 | 0.03436 | 0.06705 |
| 5 | 1.27477 | 1.22083 | 0.04239 | 0.15525 |
| 6 | 1.27576 | 1.41985 | 0.03357 | 0.13486 |
| 7 | 1.28466 | 1.48330 | 0.03671 | 0.05371 |
| 8 | 1.29114 | 1.53233 | 0.04769 | 0.08919 |
| 9 | 1.25380 | 1.71813 | 0.03831 | 0.06927 |
| 10 | 1.29217 | 1.03431 | 0.03174 | 0.06265 |
| 11 | 1.30428 | 1.14548 | 0.03519 | 0.04283 |
| 12 | 1.29822 | 0.90270 | 0.03615 | 0.05889 |
| 13 | 1.28562 | 1.48375 | 0.03812 | 0.04793 |
| 14 | 1.28994 | 0.85314 | 0.04240 | 0.07911 |
| 15 | 1.29879 | 0.49634 | 0.03105 | 0.03549 |
| 16 | 1.28327 | 1.51765 | 0.03073 | 0.03904 |
| 17 | 1.25744 | 1.11518 | 0.03859 | 0.06290 |
| 18 | 1.29822 | 0.60783 | 0.04680 | 0.06068 |
| 19 | 1.27280 | 1.53402 | 0.03681 | 0.04357 |
| 20 | 1.29476 | 1.30208 | 0.04580 | 0.05320 |
| RMSE prom | 1.28452 | 1.26111 | 0.03849 | 0.06435 |

Fuente: Elaboración Propia

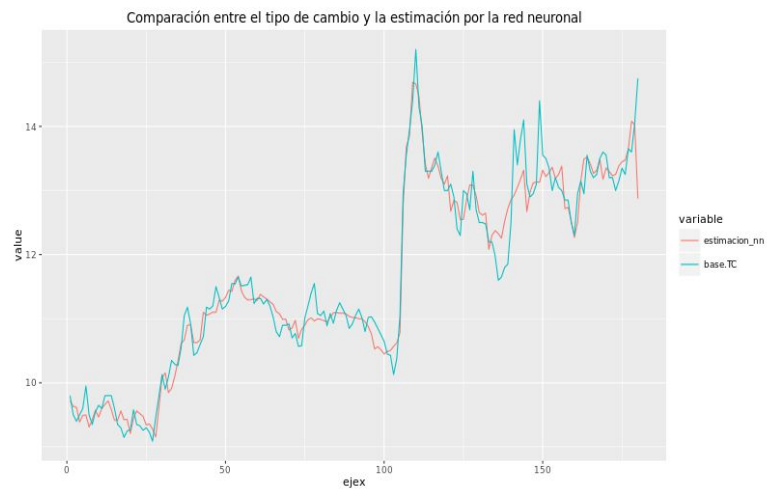
Las figuras 3.17 y 3.18 muestran los valores reales del tipo de cambio contra los estimados por el modelo lineal y por la red neuronal.

Figura 3.17
Modelo lineal y serie original



Fuente: Elaboración Propia.

Figura 3.18
RNA de panel vs serie original



Fuente: Elaboración Propia

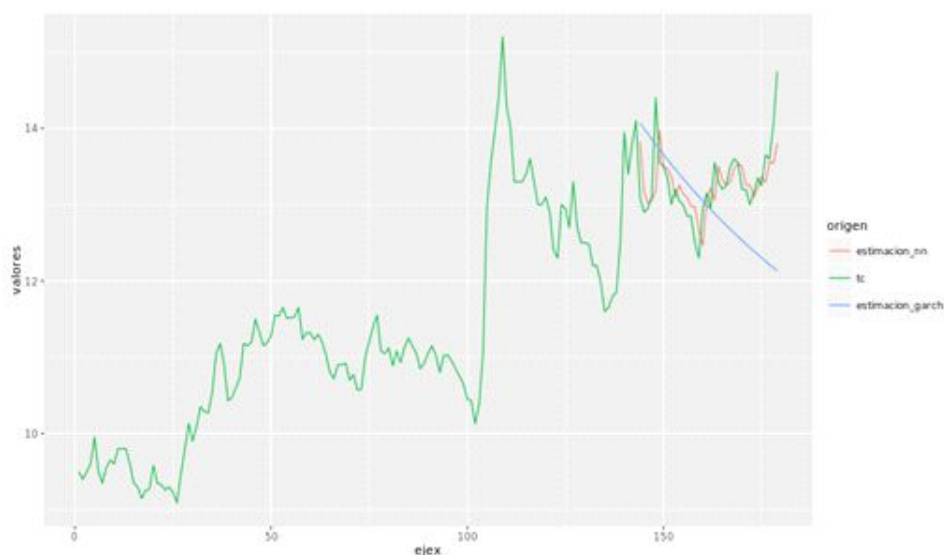
3.4.2 Segunda fase: estimación de modelo RNA con rezago y GARCH

En esta fase se estimó primero el modelo GARCH pues dentro de los parámetros calculados por la paquetería está el rezago óptimo por aplicar según las propiedades de la serie junto a la estructura del modelo siendo un rezago el óptimo y un modelo GARCH(1,1) los resultantes, dicho rezago se aplicó a la serie del tipo de cambio y con ella el cómputo es alimentado para la estimación de la RNA. *RUGARCH*, requiere un objeto del tipo serie de tiempo es decir una variable explicada por sus observaciones en el tiempo y como resultado arroja un objeto operado listo para poder hacer un pronóstico junto a los resultados de las pruebas se les aplicaron a las variables y al modelo.

La RNA tuvo un RMSE de 0.0796, mientras que el modelo GARCH tuvo un RMSE de 0.7741. La comparación entre estimaciones de los modelos se muestra en la Figura 3.19.

Figura 3.19

RNA rezago, GARCH(1,1) y serie original del tipo de cambio



Fuente: Elaboración Propia.

El modelo GARCH muestra un ajuste con respecto a la tendencia en aproximadamente 18 meses a futuro, a partir de ese punto las estimaciones comienzan a desviarse de manera significativa. Por otra parte, la red neuronal parece ajustarse mejor a los datos, sin embargo, se observó que la red se limita a estimar como valor futuro el tipo de cambio inmediato anterior, tal y como se muestra en la figura 3.19. Lo anterior podría ser un indicio de desviaciones en estimaciones con valores “no vistos” por la red neuronal haciéndola para este caso poco eficiente.

3.4.3 Tercera Fase: RNA doble

Se realizó una última corrida usando la librería de *neuralnet*, con su respectiva normalización, validación en cruz, impresión de resultados y gráficas pero esta vez se añadió a la base de datos la propia serie de tiempo del tipo de cambio con un rezago usada en la fase 2 haciendo mixta la estimación de la misma con arquitectura 17:7:2:1, esta dio por resultado en el error de entrenamiento 0.042, mientras que su error de validación fue de 0.049. Al igual que el modelo de panel, se le aplicó una prueba final con el 20% restante de los datos para simular el comportamiento que tendría con datos nuevos y su RMSE fue de 0.0887 (resumidos en la tabla 3.3)


Tabla 3.3
Resultados RNA mixta

| no. validación | red neuronal | |
|----------------|---------------|------------|
| | entrenamiento | validación |
| 1 | 0.04754 | 0.03716 |
| 2 | 0.04344 | 0.02075 |
| 3 | 0.04324 | 0.05776 |
| 4 | 0.04665 | 0.01593 |
| 5 | 0.04325 | 0.05466 |
| 6 | 0.04369 | 0.02115 |
| 7 | 0.04015 | 0.05891 |
| 8 | 0.03781 | 0.06223 |
| 9 | 0.04479 | 0.03987 |
| 10 | 0.03954 | 0.02998 |
| 11 | 0.04308 | 0.04252 |
| 12 | 0.04548 | 0.04799 |
| 13 | 0.03796 | 0.07280 |
| 14 | 0.04292 | 0.02547 |
| 15 | 0.03738 | 0.03780 |
| 16 | 0.04700 | 0.06013 |
| 17 | 0.03601 | 0.05062 |
| 18 | 0.03731 | 0.04897 |
| 19 | 0.03866 | 0.08767 |
| 20 | 0.04436 | 0.11803 |
| RMSE prom | 0.04201 | 0.04952 |

Fuente: Elaboración Propia.

En la Figura 3.20, se compara la estimación de la RNA mixta con respecto a los valores reales del tipo de cambio

Figura 3.20
RNA mixta y serie original del tipo de cambio



Fuente: Elaboración Propia.

Así quedan desarrollados, los modelos y sus resultados, objetivo planeado al comienzo de esta investigación. Se muestra a continuación el resumen de las principales conclusiones

Conclusiones

Se estimaron de manera total dos modelos de RNA de tipo multicapa (16:7:2:1 y 17:7:2:1), uno en forma de serie de tiempo, así como dos modelos para contrastar un lineal GLM y un GARCH(1,1) (los cuales no se desarrollan teóricamente pues no es el objetivo de esta investigación), esto dividido en 3 etapas una primera con enfoque de panel, una segunda con enfoque de series de tiempo, y una última donde se estimó una RNA mixta. Utilizando como criterio de comparación RMSE y el error de estimación haciendo uso del valor real del tipo de cambio para enero del 2015 (Tabla c1).

Tabla c1
Resumen de resultados

| | <i>Error RMSE</i> | | <i>Pronóstico</i> | | <i>Error de Estimación</i> | |
|--------------------------------|-------------------|-----------|-------------------|------------|----------------------------|-----------|
| | RNA | GLM | RNA | GLM | RNA | GLM |
| <i>Primera fase</i> | | | | | | |
| RNA Vs. GLM | \$ 0.0644 | \$ 1.2611 | \$ 13.7609 | \$ 13.4180 | \$ 1.4391 | \$ 1.7820 |
| <i>Segunda Fase</i> | | | | | | |
| RNAs Vs. GARCH | \$ 0.1416 | \$ 0.7742 | \$ 14.1237 | \$ 12.0900 | \$ 1.0763 | \$ 3.1100 |
| <i>Tercera Fase</i> | | | | | | |
| Doble | \$ 0.0490 | | \$ 14.3987 | | \$ 0.8013 | |
| Tipo de Cambio (Ene-15) | \$ 15.2000 | | | | | |


Fuente: Elaboración Propia.

El modelo más eficiente es la RNA mixta de la tercera etapa con un error de 80 centavos de peso, mientras que de menor precisión es el GARCH(1,1), con error de 3 pesos con 11 centavos, todos los modelos son las versiones más simples usadas por las librerías de R por lo que los resultados pueden optimizarse aún más, sin embargo, ese ya no es el objetivo de este trabajo de investigación.

El mejor pronóstico fue de \$ 14.40 contra los \$15.20 reales, existe un margen de mejora en dicho pronóstico el cuál puede darse mejorado los datos, integrando más series, usar más fuentes de información incluso autogenerada o usando software más potentes invitaciones abiertas a futuros trabajos, sin embargo no hay que perder de vista que un pronóstico del futuro 100% preciso, es imposible porque el simple hecho de intentar pronosticas provoca una alteración del presente que se ve reflejado en el futuro mismo

Se nota entonces, que los modelos de inteligencia artificial específicamente los de RNA's de manera general se ajustan mejor, son más prácticos, eficientes y precisos, una herramienta que debe y necesita mayor atención; sin embargo, no fue posible estimar una red neuronal artificial con solo la serie de tiempo del tipo de cambio pues esta es demasiado intuitiva y sabe cómo los resultados están basados La figura c1, muestra el peso porcentual de las variables usadas en el pronóstico del tipo de cambio arrojado por las redes neuronales.

Figura c1
Peso de las variables en el comportamiento del tipo de cambio



Fuente: Elaboración Propia

De acuerdo a ella, las variables de mayor peso y trascendencia en el valor final del tipo de cambio son: la reestructuración de la deuda externa (DEUD_EXT_REEST) por encima del 15%, seguida de la tasa de interés americana de fondos federales (TSA_INT_FF_USA) superando el 12.5%, la inversión americana en territorio nacional con 10% mismo porcentaje alcanzado por la deuda externa comercio exterior (DEUDA_COM_EXT).

La deuda externa (DEUDA_COM_EXT) vista como el saldo total deudor adquirido como entidad ante otra da un panorama de la estabilidad del país, de su imagen como productor, exportador importador y que tan dependiente es su economía. Dicha variable

es influenciada a través de decisiones respecto a la forma, plazo y proceder para su reestructuración (DEUD_EXT_REEST), su adquisición y disminución. Así, esta repercutirá en el valor del tipo de cambio haciendo vitales dichas políticas para contrarrestar fluctuaciones o bien la búsqueda de metas de valor en el mismo.

La tasa de interés americana (TSA_INT_FF_USA) es una variable utilizada en los Estados Unidos para influenciar su economía y si bien no es posible que esta sea manipulada de manera directa en México, es útil y pertinente el saber que tiene gran peso en valor porcentual sobre el tipo de cambio con nuestro, y debe ser empleada como foco de alerta, cada vez que dicha tasa reciba ajustes se deben llevar a cabo medidas pertinentes en nuestro país para saber la medida, trascendencia y posible afectación en la pérdida de valor de nuestra moneda para así contrarrestar dichos efectos.

Por último, la inversión extranjera (INV_USA2), esta influye de manera rápida a la población porque es generadora de empleos, de infraestructura y de posible derrama económica; la manera en que se fomenta la inversión en México por parte de Estados Unidos, así como la repartición de dicha inversión repercutirán entre sus muchas consecuencias, en el tipo de cambio

Es clara la necesidad de abrir el panorama a los métodos actuales de pronóstico y de tratamiento de datos a todo campo; sobretodo comprender la aplicabilidad en el campo de la economía y de la prevención de riesgos.

Se vive en un mundo completamente estocástico, cambiante y volátil, lleno de información cíclica y renovada segundo a segundo, haciendo crecientes los

requerimientos que un estudiante de la licenciatura en economía o en actuaría necesita para comprender su entorno, modelar la realidad y así ejercer su finalidad y función.

La programación, los métodos de simulación y de inteligencia artificial son herramientas con destacada importancia, y están en aplicación a muchos campos siendo de necesario aprendizaje en el campo económico que pretende entender con base en abstracciones de la realidad el entorno para la toma de decisiones requiriendo un mayor sustento y enseñanza de ellos a nivel licenciatura.

Económicamente el país es dependiente de los estados unidos de América, a multinivel y sobretodo en ámbitos de comercio donde el tipo de cambio es el punto referencial de ambas monedas siendo uno de los factores vitales en la toma de decisiones de este campo; los métodos de inteligencia artificial son recursos vitales y muy útiles para esto.

En el desarrollo de este trabajo de tesis se tuvo oportunidad de aplicar técnicas y conocimientos vistos en la carrera de Actuaría y Economía, teniendo, por ejemplo, la aplicación de la técnica de la simulación, hecha para generar un ambiente de prueba para el modelo de red neuronal en el que se enfrentara a datos “no vistos” y se pudiera validar su con-fiabilidad.

La estrategia utilizada para validar los datos fue la de la validación en cruz, la cual es una técnica de muestreo que permite obtener estimaciones más robustas para una variable a medir, en nuestro caso, el desempeño de la red neuronal.

Por otra parte, este trabajo representa una oportunidad de extender el uso de la probabilidad y estadística, y unir estos conocimientos a las nuevas tecnologías para conseguir así modelos de carácter macroeconómico que permitan representar de mejor forma a la realidad, tomando en cuenta una mayor cantidad de variables a la vez, conservando parsimonia en el momento de generarlos y también al interpretarlos.

El uso de redes neuronales para la estimación del precio del tipo de cambio supone una técnica innovadora y confiable que reduce el riesgo de emitir estimaciones desviadas del valor real gracias a su gran poder predictivo. Esta técnica puede ser usada en una variedad de situaciones dentro del ámbito actuarial, como en la estimación del riesgo en los seguros, estimación del comportamiento demográfico.

Es preciso mencionar como limitaciones de la investigación el hecho de que los modelos estimados están en la expresión más simple de las librerías usadas y ninguno se perfeccionó con fines de una comparación justa, así como la selección de variables y su periodo puesto que al comienzo de esta las series estaban en construcción.

Se invita al lector a replicar la metodología implementados cambios, optimizando el código (véase anexo 1), incluyendo más variables y actualizándolas e incluso incluir cualquier cambio pertinente.

Anexos

Anexo 1 Código

```
rm(list=ls())
set.seed(100)
# En el siguiente código se omite el uso de acentos y letras con tilde
# propias del lenguaje castellano con la finalidad de evitar errores
# con el programa
# Carga de librerías y definición de funciones -----
  if ("neuralnet" %in% rownames(installed.packages()) == FALSE)
  {
    install.packages("neuralnet")
  }
  if ("plyr" %in% rownames(installed.packages()) == FALSE)
  {
    install.packages("plyr")
  }
  if ("reshape2" %in% rownames(installed.packages()) == FALSE)
  {
    install.packages("reshape2")
  }
  if ("scales" %in% rownames(installed.packages()) == FALSE)
  {
    install.packages("scales")
  }
  if ("ggplot2" %in% rownames(installed.packages()) == FALSE)
```

```

{
  install.packages("ggplot2")
}
if ("rugarch" %in% rownames(installed.packages()) == FALSE)
{
  install.packages("rugarch")
}
# Neuralnet es la libreria que contiene las herramientas necesarias para
# generar, entrenar y aplicar una red neuronal
library("neuralnet")
# Plyr es una libreria auxiliar para el tratamiento de datos previo a
# la graficacion y comparacion de diagramas
library("plyr")
# Las librerias reshape son auxiliares para el paquete plyr y ggplot
library("reshape")
library("reshape2")
# Scales es una libreria que contiene funciones para el reescalamiento
# y normalizacion de datos en tablas
library("scales")
# Ggplot consta de un lenguaje y herramientas para producir graficos
library("ggplot2")
# rugarch es una libreria para generar modelos de series de tiempo
# de tipo garch
library("rugarch")
# ubicacion de funcion gar fun
path_base <- "Bases/juanita4.csv"
# definicion de funcion de validacion en cruz con N pliegues

```

```

crear_pliegues <- function(pliegues, datos, parametro)
{
  # La funcion "crear pliegues" realiza una validacion en cruz a los modelos
  # de red neuronal y al modelo lineal.
  # Primero divide a la muestra en grupos o "pliegues" (definido por el usuario)
  # y entrena a los modelos con todos los grupos a excepcion de 1, que utiliza
  # para calificar o "validar" el desempeno del entrenamiento. Este proceso se
  # repite sustituyendo la submuestra de validacion en cada iteracion y
  # como ultimo paso se promedian los resultados para obtener una estimacion
  # confiable de la calificacion.
  #
  # De manera adicional, la funcion toma una lista de posibles valores para
  # un parametro, estipulado dentro de la misma funcion, los cuales se probaran
  # para obtener el optimo que resulte en la mejor calificacion de validacion
  #
  # Parametros de la funcion:
  #
  # pliegues Denota el numero de submuestras en las que se dividiran los datos
  # datos Representa la tabla con los datos de entrenamiento
  # parametro Es una lista de posibles valores del parametro para optimizar
  # Se definen los subgrupos de la muestra
  index_validacion <- sample(seq(1, pliegues), dim(datos)[1], replace= TRUE)
  # Inicializacion de calificaciones de entrenamiento y validacion
  errorMedioEntrenamiento_lineal <- 0
  errorMedioValidacion_lineal <- 0
  errorMedioEntrenamiento <- 0
  errorMedioValidacion <- 0

```

```

# Iteracion de entrenamiento-validacion para cada uno de los subgrupos o
# pliegues
for (fase in 1:pliegues)
{
  # Se generan el grupo de validacion y el de entrenamiento para la iteracion
  validacion = datos[index_validacion == fase,]
  entrenamiento = datos[index_validacion != fase,]

  # Entrenamiento de los modelos
  n <- names(datos)
  f <- as.formula(paste("TC ~", paste(n[!n %in% "TC"], collapse = " + ")))

  # Modelo lineal
  ml <- glm(f, family = binomial(), data = entrenamiento)

  # Modelo NN
  nn <- neuralnet(f, data= entrenamiento, hidden= c(7,2), linear.output=T)
  nn <- neuralnet(f, data= entrenamiento, hidden= parametro, linear.output=T)

  # Observamos que la funcion de transferencia logistica es mejor que
  # la de tangente hiperbolica.

  # Las tasas de aprendizaje y el de umbral son los valores por defecto de la
  # funcion (NULL y 0.01, respectivamente)

  # La funcion de error usada es la de Suma de errores de los cuadrados

  # ERROR DE ENTRENAMIENTO

  # Calculo del error de entrenamiento para la red neuronal y el modelo lineal.
  # Tras haber reescalado los datos con anterioridad, se transforma de manera
  # inversa para obtener los resultados sin-normalizacion max-min.
  objetivo <- (entrenamiento$TC)*(max(datos$TC)-min(datos$TC))+min(datos$TC)

  # Error de entrenamiento de ML

```

```

prediccionBruta_lineal <- predict(ml, entrenamiento)
prediccion_lineal <- prediccionBruta_lineal*(max(datos$TC)-min(datos$TC))+min(datos$TC)
MSEentrenamiento_lineal <- sum((objetivo - prediccion_lineal)^2)/nrow(entrenamiento)
# Error de entrenamiento de NN
prediccionBruta <- compute(nn, entrenamiento[, 2:dim(datos)[2]])
prediccion <- prediccionBruta$net.result*(max(datos$TC)-min(datos$TC))+min(datos$TC)
MSEentrenamiento <- sum((objetivo - prediccion)^2)/nrow(entrenamiento)
# ERROR DE VALIDACION
# Calculo del error de validacion para la red neuronal y el modelo lineal.
# Tras haber reescalado los datos con anterioridad, se transforma de manera
# inversa para obtener los resultados sin-normalizacion max-min.
objetivo <- (validacion$TC)*(max(datos$TC)-min(datos$TC))+min(datos$TC)
# Error de validacion de ML
prediccionBruta_lineal <- predict(ml, validacion)
prediccion_lineal <- prediccionBruta_lineal*(max(datos$TC)-min(datos$TC))+min(datos$TC)
MSEvalidacion_lineal <- sum((objetivo - prediccion_lineal)^2)/nrow(validacion)
# Error de validacion de NN
prediccionBruta <- compute(nn, validacion[, 2:dim(datos)[2]])
prediccion <- prediccionBruta$net.result*(max(datos$TC)-min(datos$TC))+min(datos$TC)
objetivo <- (validacion$TC)*(max(datos$TC)-min(datos$TC))+min(datos$TC)
MSEvalidacion <- sum((objetivo - prediccion)^2)/nrow(validacion)
# IMPRESION EN PANTALLA DE RESULTADOS
print(paste("Para la fase ", fase, ":"))
print(paste(" El error de entrenamiento es: ", sqrt(MSEentrenamiento_lineal), " (ml), ",
sqrt(MSEentrenamiento), " (nn)"))
print(paste(" El error de validacion es: ", sqrt(MSEvalidacion_lineal), " (ml), ", sqrt(MSEvalidacion),
" (nn)"))
# PROMEDIO DE VALIDACIONES

```

```

# Se promedian los resultados de cada iteracion de entrenamiento-validacion
# para obtener una estimacion mas confiable (en este paso solo se agregan las
# calificaciones).

# ml
errorMedioEntrenamiento_lineal <- sqrt(MSEentrenamiento_lineal) +
errorMedioEntrenamiento_lineal

errorMedioValidacion_lineal <- sqrt(MSEvalidacion_lineal) + errorMedioValidacion_lineal

# nn
errorMedioEntrenamiento <- sqrt(MSEentrenamiento) + errorMedioEntrenamiento
errorMedioValidacion <- sqrt(MSEvalidacion) + errorMedioValidacion
}

writeLines("\n")

print("=====")

print(paste("Resultados crossvalidacion:"))

print(paste(" El error de entrenamiento es: ", errorMedioEntrenamiento_lineal/pliegues, " (ml) ",
errorMedioEntrenamiento/pliegues, " (nn)"))

print(paste(" El error de validacion es: ", errorMedioValidacion_lineal/pliegues, " (ml) ",
errorMedioValidacion/pliegues, " (nn)"))

print("=====")

writeLines("\n")

writeLines("\n")

# El valor de retorno de la funcion es el modelo neuronal unicamente
return(nn)
}

# Ejecucion de proceso principal. Generacion y validacion de modelos -----

# Lectura de base de datos de panel
base <- read.csv2(file= path_base, sep= ";", dec = ",")

# Creacion de base como serie de tiempo a 1 rezago

```



```

tc <- base$TC
base_serie <- base[2:180,]
base_serie$TC_1lag <- tc[1:179]
base_serie <- base_serie[,c('TC', 'TC_1lag')]
#base_serie$tiempo <- c(1:179)
# Creacion de base como panel+serie de tiempo
base_p_s <- base[2:180,]
base_p_s$TC_1lag <- tc[1:179]
# transformacion de datos de tipo factorial a numerico
for (columna in names(base))
{
  # panel
  base[,columna] <- as.numeric(as.character(base[,columna]))
}
for (columna in names(base_serie))
{
  # serie
  base_serie[,columna] <- as.numeric(as.character(base_serie[,columna]))
}
for (columna in names(base_p_s))
{
  # panel+serie
  base_p_s[,columna] <- as.numeric(as.character(base_p_s[,columna]))
}
# separacion en muestra de entrenamiento y muestra de prueba

# panel

```

```

index <- sample(1:nrow(base),round(0.80*nrow(base)))

train <- base[index,]
test <- base[-index,]

# serie
index <- sample(1:nrow(base_serie),round(0.80*nrow(base_serie)))

train_serie <- base_serie[index,]
test_serie <- base_serie[-index,]

# panel+serie
index <- sample(1:nrow(base_p_s),round(0.80*nrow(base_p_s)))

train_p_s <- base_p_s[index,]
test_p_s <- base_p_s[-index,]

# se realiza un reescalamiento max-min para agilizar el computo de la red

# panel
maxs <- apply(base, 2, max)
mins <- apply(base, 2, min)
scaled <- as.data.frame(scale(base, center = mins, scale = maxs - mins))

train_ <- scaled[index,]
test_ <- scaled[-index,]

# serie
maxs_serie <- apply(base_serie, 2, max)
mins_serie <- apply(base_serie, 2, min)

scaled_serie <- as.data.frame(scale(base_serie, center = mins_serie, scale = maxs_serie -
mins_serie))

train_serie_ <- scaled_serie[index,]
test_serie_ <- scaled_serie[-index,]

# panel+serie
maxs_p_s <- apply(base_p_s, 2, max)

```

```

mins_p_s <- apply(base_p_s, 2, min)
scaled_p_s <- as.data.frame(scale(base_p_s, center = mins_p_s, scale = max_p_s - mins_p_s))
train_p_s_ <- scaled_p_s[index,]
test_p_s_ <- scaled_p_s[-index,]
# Optimizacion de parametros por prueba-error aplicando la funcion de
# validacion en cruz
for (estructura in list(c(5,3), c(7, 2)))
{
  cat("Para el parametro: ", estructura)
  writeLines("\n")
  print("PARA LA RED DE PANEL:")
  # panel
  nn <- crear_pliegues(20, train_, estructura)
  writeLines("\n")
  writeLines("\n")
  print("PARA LA RED DE SERIE:")
  # serie
  nn_serie <- crear_pliegues(20, train_serie_, estructura)
  writeLines("\n")
  writeLines("\n")
  # panel+serie
  print("PARA LA RED DE PANEL + SERIE:")
  nn_p_s <- crear_pliegues(20, train_p_s_, estructura)
}
# Calculo de error cuadratico medio de red neuronal para la muestra de prueba.
# Tras haber entrenado la red neuronal, se realiza una validacion final
# con una muestra completamente nueva para el modelo y se verifica el desempeno

```

```

# que tendria en una situacion real de uso.
#
# Panel
pr.nn_test <- compute(nn, test_[, 2:dim(base)[2]])
pr.nn_test_ <- pr.nn_test$net.result*(max(base$TC)-min(base$TC))+min(base$TC)
test.r <- (test_$TC)*(max(base$TC)-min(base$TC))+min(base$TC)
MSE.nn_test <- sum((test.r - pr.nn_test_)^2)/nrow(test_)
print(paste("El error cuadratico medio en la muestra de prueba de panel: ",MSE.nn_test))
# serie
pr.nn_test <- compute(nn_serie, test_serie_[, 2:dim(base_serie)[2]])
pr.nn_test_ <- pr.nn_test$net.result*(max(base_serie$TC)-min(base_serie$TC))+min(base_serie$TC)
test.r <- (test_serie_$TC)*(max(base_serie$TC)-min(base_serie$TC))+min(base_serie$TC)
MSE.nn_test <- sum((test.r - pr.nn_test_)^2)/nrow(test_serie_)
print(paste("El error cuadratico medio en la muestra de prueba de serie: ",MSE.nn_test))
# panel+serie
pr.nn_test <- compute(nn_p_s, test_p_s_[, 2:dim(base_p_s)[2]])
pr.nn_test_ <- pr.nn_test$net.result*(max(base_p_s$TC)-min(base_p_s$TC))+min(base_p_s$TC)
test.r <- (test_p_s_$TC)*(max(base_p_s$TC)-min(base_p_s$TC))+min(base_p_s$TC)
MSE.nn_test <- sum((test.r - pr.nn_test_)^2)/nrow(test_p_s_)
print(paste("El error cuadratico medio en la muestra de prueba de panel+serie: ",MSE.nn_test))

# Generacion de modelo lineal para comparar
n <- names(scaled)
f <- as.formula(paste("TC ~", paste(n[!n %in% "TC"], collapse = " + ")))
ml <- glm(f, family=binomial(link='logit'), data = scaled)
# Graficando estimaciones de los modelos neuronal y lineal
ejex <- 1:dim(scaled)[1]

```

```

# Estimacion lineal
prediccionBruta_lineal <- predict(ml, scaled)
estimacion_ml <- prediccionBruta_lineal*(max(base$TC)-min(base$TC))+min(base$TC)

# Estimacion NN
prediccionBruta <- compute(nn, scaled[, 2:dim(base)[2]])
estimacion_nn <- prediccionBruta$net.result*(max(base$TC)-min(base$TC))+min(base$TC)

# Estimacion NN PANELserie
prediccionBruta <- compute(nn_p_s, scaled_p_s[, 2:dim(base_p_s)[2]])
estimacion_nn_p_s <- prediccionBruta$net.result*(max(base_p_s$TC)-
min(base_p_s$TC))+min(base_p_s$TC)

df <- data.frame(ejex, estimacion_nn, estimacion_ml, base$TC)
df_panel <- data.frame(ejex[2:180], estimacion_nn_p_s, estimacion_ml[2:180], base$TC[2:180])
#df <- melt(df, id.vars = 'ejex')
#View(df)

#names(df) <- c('ejex', 'fuente', 'valor')
#modificación de para pronosticos

# Graficacion de estimaciones de modelos -----

df <- melt(df, id.vars = 'ejex')
df_panel <- melt(df_panel, id.vars = 'ejex.2.180.')

#names(df) <- c('ejex', 'fuente', 'valor')

p <- ggplot() + geom_line(aes(x= ejex, y= value, color= variable), data= df[df$variable !=
'estimacion_ml',])#, color= fuente), data= df)

#p <- p + geom_line(aes(x= ejex, y= base.TC), data= df)

```

```

p <- p + labs(title= 'Comparación entre el tipo de cambio y la estimación por la red neuronal')
#p <- p + scale_colour_manual(values=c("green", "yellow"))

p

#names(df) <- c('ejex', 'fuente', 'valor')

p <- ggplot() + geom_line(aes(x= ejex.2.180., y= value, color= variable), data=
df_panel[df_panel$variable != 'estimacion_ml.2.180.'], #, color= fuente), data= df)
#p <- p + geom_line(aes(x= ejex, y= base.TC), data= df)

p <- p + labs(title= 'Comparación entre el tipo de cambio y la estimación por la red neuronal')
#p <- p + scale_colour_manual(values=c("green", "yellow"))

p

p <- ggplot() + geom_line(aes(x= ejex, y= value, color= variable), data= df[df$variable !=
'estimacion_nn',.])#, color= fuente), data= df)
#p <- p + geom_line(aes(x= ejex, y= base.TC), data= df)

p <- p + labs(title= 'Comparación entre el tipo de cambio y la estimación por el modelo lineal')
#p <- p + scale_colour_manual(values=c("green", "yellow"))

p

# Obtencion de la importancia de las variables
pesos = rep(0, dim(base)[2] - 1)
# Iterar para cada variable
for (variable in seq(from= 1, to= dim(base)[2] - 1))
{
  # Iterar para cada nodo de la primera capa
  cont_c1 = 1
  for (nodo_c1 in nn$weights[[1]][[1]][-1,][variable, ])
  {

```

```

# Iterar para cada nodo de la segunda capa
cont_c2 = 1
for (nodo_c2 in nn$weights[[1]][[2]][-1,][cont_c1, ])
{
  for (nodo_s in nn$weights[[1]][[3]][-1,][cont_c2])
  {
    pesos[variable] <- pesos[variable] + abs(nodo_c1 * nodo_c2 * nodo_s)
  }
  cont_c2 <- cont_c2 + 1
}
cont_c1 <- cont_c1 + 1
}
}

# Graficacion de importancia de las variables
pesos <- pesos * 100 / sum(pesos)
df_imp <- data.frame(names(base)[-1], pesos)
colnames(df_imp) <- c('variables', 'pesos')
p <- ggplot() + geom_bar(aes(x= variables, weights= pesos), data= df_imp)#, color= fuente), data= df)
p <- p + theme(axis.text.x = element_text(angle = 90, hjust = 1))
p

# Modelo de series de tiempo garch -----

tc <- base_serie$TC
indice_entrena <- 1:(length(tc)-round(179*0.20))
indice_valida <- (length(tc)-round(179*0.20) + 1):length(tc)

```

```

tc_entrena <- tc[indice_entrena]
tc_valida <- tc[indice_valida]

spec = ugarchspec(variance.model = list(model = 'eGARCH'))
setstart(spec) <- list(shape = 5)
setbounds(spec) <- list(shape=c(4.1, 40), alpha1=c(0, 1))

fit = ugarchfit(spec, tc_entrena, solver = 'hybrid')

forc <- ugarchforecast(fit, n.ahead=36)
forc <- head(fitted(forc), n= 36)

#scaled_p <- scaled_serie
#scaled_p$TC_1lag[1:173] <- 0

# Estimacion NN
prediccionBruta <- compute(nn_serie, scaled_serie[indice_valida, 2:dim(base_serie)[2]])
estimacion_nn <- prediccionBruta$net.result*(max(base_serie$TC)-
min(base_serie$TC))+min(base_serie$TC)
#estimacion_nn[1:173] <- 0

df_nn <- data.frame(ejex= c(indice_valida), valores= estimacion_nn, origen= 'estimacion_nn')
df_tc <- data.frame(ejex= c(1:179), valores= base_serie$TC, origen= 'tc')
df_garch <- data.frame(ejex= c(indice_valida), valores= forc, origen= 'estimacion_garch')
names(df_garch) <- c('ejex', 'valores', 'origen')
df <- rbind(df_nn, df_tc)
df <- rbind(df, df_garch)

```



```

# df <- data.frame(ejex, estimacion_nn, estimacion_ml, base_serie$TC)
# #df <- melt(df, id.vars = 'ejex')
# #View(df)
#
# #names(df) <- c('ejex', 'fuente', 'valor')
#
# p <- ggplot() + geom_line(aes(x= ejex, y= valores, color= origen), data= df)#, color= fuente), data= df)
# #p <- p + geom_line(aes(x= ejex, y= base_serie.TC), data= df)
# p <- p + labs(title= 'Comparación entre el tipo de cambio y la estimación por la red neuronal')
# p <- p + scale_colour_manual(values=c("green", "yellow"))
# p

p <- ggplot() + geom_line(aes(x= ejex, y= valores, color= origen), data= df)#, color= fuente), data= df)
p

MSE.garch_test <- sum((as.numeric(forc) - tc_valida)^2)/length(tc_valida)

print(paste("El error cuadratico medio en la muestra de prueba de GARCH: ",MSE.garch_test))

# Pronósticos.....

prediccionBruta <- compute(nn_serie, scaled_serie[indice_entrena, 2:dim(base_serie)[2]])
estimacion_nn <- prediccionBruta$net.result*(max(base_serie$TC)-
min(base_serie$TC))+min(base_serie$TC)

```

```
sum((as.numeric(estimacion_nn) - tc_entrena)^2)/length(tc_entrena)
```

```
path_base2 <- "Bases/juanita6.csv"
```

```
base2 <- read.csv2(file= path_base2, sep= ",", dec = ",")
```

```
base2 <- base2[181,]
```

```
base2$TC <- as.numeric(as.character(base2$TC))
```

```
base2$ING_PUBLICOST <- as.numeric(as.character(base2$ING_PUBLICOST))
```

```
base2$ING_PUB_GOB_TOT <- as.numeric(as.character(base2$ING_PUB_GOB_TOT))
```

```
base2$GASTO_PRES_TOT <- as.numeric(as.character(base2$GASTO_PRES_TOT))
```

```
base2$GAS_PRES_GOB_TOT <- as.numeric(as.character(base2$GAS_PRES_GOB_TOT))
```

```
base2$TIIE <- as.numeric(as.character(base2$TIIE))
```

```
base2$TSA_INT_FF_USA <- as.numeric(as.character(base2$TSA_INT_FF_USA))
```

```
base2$DEUDA_EXT_TOT <- as.numeric(as.character(base2$DEUDA_EXT_TOT))
```

```
base2$DEUD_EXT_REEST <- as.numeric(as.character(base2$DEUD_EXT_REEST))
```

```
base2$DEUDA_COM_EXT <- as.numeric(as.character(base2$DEUDA_COM_EXT))
```

```
base2$B_DESARROLLO <- as.numeric(as.character(base2$B_DESARROLLO))
```

```
base2$BP_TOTAL2 <- as.numeric(as.character(base2$BP_TOTAL2))
```

```
base2$BP_USA2 <- as.numeric(as.character(base2$BP_USA2))
```

```
base2$INV_EXTR_TOTAL2 <- as.numeric(as.character(base2$INV_EXTR_TOTAL2))
```

```
base2$INV_USA2 <- as.numeric(as.character(base2$INV_USA2))
```

```
base2$PIB2 <- as.numeric(as.character(base2$PIB2))
```

```
base2$PIBPORCENTUAL <- as.numeric(as.character(base2$PIBPORCENTUAL))
```

```
base2$GDP <- as.numeric(as.character(base2$GDP))
```

```
scaled_2015 <- as.data.frame(scale(base2, center = mins, scale = maxs - mins))
```

```

base_serie2 <- base2
base_serie2$TC_1lag <- 14.7490
base_serie2 <- base_serie2[,c("TC", "TC_1lag")]
scaled_serie_2015 <- as.data.frame(scale(base_serie2, center = mins_serie, scale = maxs_serie -
mins_serie))

base_p_s2 <- base2
base_p_s2$TC_1lag <- 14.7490
scaled_p_s_2015 <- as.data.frame(scale(base_p_s2, center = mins_p_s, scale = maxs_p_s - mins_p_s))

#prediccionBruta <- compute(nn, scaled_serie_2015[, 2:dim(base_serie2)[2]])
#estimacion_nn_2015 <- prediccionBruta$net.result*(maxs[1]-mins[1])+mins[1]

#prediccionBruta_lineal <- predict(ml, scaled__serie_2015)
#estimacion_ml <- prediccionBruta_lineal*(maxs_serie[1]-m[1])+mins[1]

prediccionBruta <- compute(nn_serie, scaled_serie_2015[, 2:dim(base_serie2)[2]])
estimacion_nn_serie_2015 <- prediccionBruta$net.result*(maxs_serie[1]-mins_serie[1])+mins_serie[1]

prediccionPS <- compute(nn_p_s, scaled_p_s_2015[, 2:dim(base_p_s2)[2]])
estimacion_nn_Ps_2015 <- prediccionPS$net.result*(maxs_p_s[1]-mins_p_s[1])+mins_p_s[1]

```

Anexo 2 Test's GARCH

| GARCH Model Fit | | | | |
|-------------------------------|---------------|------------|---------|-----------|
| Conditional Variance Dynamics | | | | |
| GARCH Model | eGARCH(1,1) | | | |
| Mean Model | ARFIMA(1,0,1) | | | |
| Distribution | norm | | | |
| Optimal Parameters | | | | |
| | Estimate | Std. Error | t value | Pr(> t) |
| mu | 9.56046 | 0.203741 | 46.9246 | 0.000000 |
| ar1 | 0.98407 | 0.013699 | 71.8370 | 0.000000 |
| ma1 | 0.14676 | 0.048180 | 3.0461 | 0.002318 |
| omega | -0.98855 | 0.308641 | -3.2029 | 0.001360 |
| alpha1 | 0.29737 | 0.142888 | 2.0811 | 0.037421 |
| beta1 | 0.62898 | 0.104599 | 6.0132 | 0.000000 |
| gamma1 | 0.61750 | 0.229587 | 2.6896 | 0.007153 |
| Robust Standard Errors: | | | | |
| | Estimate | Std. Error | t value | Pr(> t) |
| mu | 9.56046 | 0.137033 | 69.7675 | 0.000000 |
| ar1 | 0.98407 | 0.019712 | 49.9220 | 0.000000 |
| ma1 | 0.14676 | 0.089317 | 1.6432 | 0.100346 |
| omega | -0.98855 | 0.274450 | -3.6019 | 0.000316 |
| alpha1 | 0.29737 | 0.181877 | 1.6350 | 0.102049 |
| beta1 | 0.62898 | 0.090882 | 6.9208 | 0.000000 |
| gamma1 | 0.61750 | 0.241499 | 2.5570 | 0.010559 |

LogLikelihood : -14.4509531

| Information Criteria | |
|----------------------|---------|
| Akaike | 0.30001 |
| Bayes | 0.44505 |
| Shibata | 0.29551 |
| Hannan-Quinn | 0.35895 |

| Weighted Ljung-Box Test on Standardized Residuals | | |
|---------------------------------------------------|-----------|---------|
| | statistic | p-value |
| Lag[1] | 0.06502 | 0.7987 |
| Lag[2*(p+q)+(p+q)-1][5] | 0.99642 | 1 |
| Lag[4*(p+q)+(p+q)-1][9] | 2.51592 | 0.9502 |

d.o.f=2

H0 : No serial correlation

| Weighted Ljung-Box Test on Standardized Squared Residuals | | |
|-----------------------------------------------------------|------------|---------|
| | statistic | p-value |
| Lag[1] | 0.00003091 | 0.9956 |
| Lag[2*(p+q)+(p+q)-1][5] | 1.00977817 | 0.8575 |
| Lag[4*(p+q)+(p+q)-1][9] | 2.2356328 | 0.8751 |

d.o.f=2

| Weighted ARCH LM Tests | | | | |
|------------------------|-----------|-------|-------|---------|
| | Statistic | Shape | Scale | P-Value |
| ARCH Lag[3] | 1.487 | 0.5 | 2 | 0.2226 |
| ARCH Lag[5] | 1.585 | 1.44 | 1.667 | 0.5703 |
| ARCH Lag[7] | 2.515 | 2.315 | 1.543 | 0.6093 |

| Nyblom stability test | |
|-----------------------|--------|
| Joint Statistic: | 1.0085 |

| Individual Statistics: | |
|------------------------|----------|
| | Columna2 |
| mu | 0.16409 |
| ar1 | 0.06628 |
| ma1 | 0.06608 |
| omega | 0.50645 |
| alpha1 | 0.07212 |

| | | | |
|-----------------------------------------------|------------------|---------------------|------------|
| beta1 | 0.43872 | | |
| gamma1 | 0.06431 | | |
| Asymptotic | | | |
| Critical Values | 10% | 5% | 1% |
| Joint Statistic: | 1.69 | 1.9 | 2.35 |
| Individual Statistic: | 0.35 | 0.47 | 0.75 |
| Sign Bias Test | | | |
| | t-value | prob | sig |
| Sign Bias | | 0.7478 | 0.4558 |
| Negative Sign | Bias | 0.5099 | 0.6109 |
| Positive Sign | Bias | 0.184 | 0.8543 |
| Joint Effect | | 2.1091 | 0.5501 |
| Adjusted Pearson Goodness-of-Fit Test: | | | |
| group | statistic | p-value(g-1) | |
| 1 | 20 | 23.29 | 0.2247 |
| 2 | 30 | 28.82 | 0.4746 |
| 3 | 40 | 32.94 | 0.7416 |
| 4 | 50 | 47.56 | 0.5316 |

Elapsed time : 0.777204752

Referencias

Referencias

- AGUILAR, J. "Introducción a las Redes Neuronales Artificiales" [en línea]. 2009.[fecha de consulta: 30 de mayo del 2016] disponible en <http://www.flacsoandes.edu.ec/comunicacion/aaa/imagenes/publicaciones/pub_25.pdf>
- ALMEIDA, A. (1998) "High-Frequency Exchange Rate Behavior", Journal of Financial and Quantitative Analysis, volumen 33, 383-408 pp.
- ANDERSEN, T; et al. (2007): "Real-Time Price Discovery in Global Stock, Bond, and Foreign Exchange Markets", Journal of International Economics, volumen 73, 251-277pp.
- BALASSA, B. (1964) "The Purchasing Power Parity Doctrine: A Reappraisal", Journal of Political Economy, Volumen72, 584-596pp.
- BANCO DE MÉXICO. "Efectos de la Política Monetaria sobre la economía", México, 2015. [fecha de consulta: 30 de mayo del 2016]. Disponible en <<http://www.banxico.org.mx/politica-monetaria-e-inflacion>>
- BARTOLINI, L.; GOLDBERG, Y. SACARNY, A. (2008) "How Economic News Moves Markets", Current Issues in Economics and Finance, volume 14, número 6, Federal Reserve Bank of New York.
- BASOGAIN, X. "Redes Neuronales Artificiales y sus Aplicaciones" [en línea]. 2014. Escuela Superior de Ingeniería de Bilbao, EHU. [fecha de consulta: 30 de mayo del 2016] Disponible en <http://www.ciberesquina.una.edu.ve:8080/2014_2/350_E.pdf>
- BENEDETTI F., BAIGÚN A., YANGUAS M. (2008) "Predicciones de Series de Tiempo con Redes Neuronales: Trading usando el Índice Merval", número 10.
- BILSON, J. (1978c) "The Current Experience with Floating Exchange Rates: An Appraisal of the Monetary Approach", American Economic Review, volumen 68, 392-397pp
- BILSON, J. (1978a) "Rational Expectations and the Exchange Rate", en J. A. FRENKEL y H.
- BILSON, J. (1978b) "The Monetary Approach to the Exchange Rate: Some Empirical Evidence", International Monetary Fund Staff Papers, volumen 25, 48-75pp.

- BONILLA, M. (2002) "Redes neuronales artificiales: predicción de la volatilidad del tipo de cambio de la peseta", España, 47pp.
- CARLOS, R., BARRERA, C. (2010) "Redes neuronales para predecir el tipo de cambio diario", Perú, 32pp
- DEL CARPIO GALLEGOS, J. (2005) "Las redes neuronales artificiales en las finanzas", 31pp.
- GÓMEZ, G. (2007), "Métodos de predicción para los mercados de divisas", Tesis, 128pp.
- GÓMEZ, X. "La diferencia entre una devaluación y una depreciación" [en línea]. 2014. Editorial, Periódico, El dinero en Imagen.[fecha de consulta: 2 de agosto del 2016] Disponible en <<http://www.dineroenimagen.com/2014-12-10/47664>>
- GÓMEZ, W. (2010), "Pronóstico de una serie temporal usando redes neuronales", Tesis, 112pp.
- GRADOJEVIC N. (2000)., "The Application of Artificial Neural Networks to Exchange Rate Forecasting: The Role of Market Microstructure Variables" Artículo del Banco de Canada, 36pp
- HERNÁNDEZ Y. (2014) "Reducción de ruido aplicando redes neuronales artificiales" Hilera
- MARTINEZ V. (2000) "Redes neuronales artificiales", PTR Prentice Hall, Inc.
- INEGI, "Banco de Información Económica" [en línea]. México [fecha de consulta: 30 de octubre del 2016]. Disponible desde <<http://www.inegi.org.mx/Sistemas/BIE/Default.aspx?Topic=0&idserPadre=102000260020#D102000260020>>
- INVERSTING [en línea]. México. "Guía de cotización Peso-Dólar". [fecha de consulta: 30 de mayo del 2016]. Base de datos disponible en <<http://mx.investing.com/currencies/usd-mxn>>
- JOHNSON G (1978) "The Economics of Exchange Rates: Selected Studies", Reading, MA: Addison-Wesley, 75-96pp
- KADILAR C. (2009), "forecasting the exchange rate series with ann: the case of turkey", Turquía. 17-29pp
- LEHMANN, E. (1998) "Theory of Point Estimation". Nueva York, Ed Springer, segunda edición.

- LELART, M. (1998) "El sistema monetario internacional". 14-34pp.
- MAJHI, R. (2009) "Development and performance evaluation of FLANN based model for forecasting of stock markets". Expert Systems with Applications, 36pp
- MATICH, J. "Redes Neuronales: Conceptos Básicos y Aplicaciones" [en línea]. Universidad Tecnológica Nacional Rosario, Argentina, 2001 [fecha de consulta: 30 de mayo del 2016] Disponible en <http://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/matich-redesneuronales.pdf>
- MÉNDEZ J. (2008) "Microestructura y dinámica de la tasa de cambio nominal en Colombia: una aproximación con redes neuronales artificiales y sistemas neurodifusos", 37pp.
- MORALES A. (2008) "Pronósticos mediante redes neuronales artificiales y modelos arima: el caso de los cetes en México", UNAM, 794pp
- NOGUEIRA J. (2009) "Las Reglas del Juego. Mercado de Cambios y Operaciones con Divisas" Argentina, 230pp
- OLABE, X. (1998) "Redes Neuronales Artificiales y sus Aplicaciones". Publicaciones de la Escuela de Ingenieros 101pp
- PARISI F. (2003) "Modelos de redes neuronales aplicados a la predicción del tipo de cambio del dólar observado en Chile.", Estudios de administración, Universidad de Chile, Vol. 10 No 1, 24pp
- PATEL, P. (2000) "Factors affecting Currency Exchange Rate, Economical Formulas and Prediction Models". 234pp.
- PATRICIA, A. (2002) "Del bimetallismo al patrón de oro. México: la reforma monetaria de 1905" (Tesis de pregrado). UNAM, México.
- ROMERO S. (2007) "Teorías del tipo de cambio", 12pp
- ROUT, A. (2013). "Efficient Forecasting of Exchange rates with Recurrent FLANN. IOSR" Journal of Computer Engineering, 13(6), 21–28.
- RUDRA P. (2010), "Forecasting Exchange Rate in india: An Application of Artificial Neural Network Model", Journal of Mathematics Research Vol. 2, No. 4; India, 7pp.

- SIMON E. (2002), "Pronostico del tipo de cambio extranjero usando redes neuronales artificiales." Neuchatel, 87pp.
- SALAS, R. "Redes Neuronales Artificiales" [en línea]. Universidad de Valparaíso ,2009. [fecha de consulta: 30 de mayo del 2016]. Disponible en <https://www.inf.utfsm.cl/~rsalas/Pagina_Investigacion/docs/Apuntes/Redes%20Neuronales%20Artificiales.pdf>
- TIPOS DE CAMBIO HISTÓRICOS [en línea]. Canadá ULC Corps, simulador de tipo de cambio. [fecha de consulta: 30 de mayo del 2016]. Base de datos disponible en <<https://www.oanda.com/lang/es/currency/historical-rates/>>
- VILARIÑO, A. "Algunos problemas en el empleo de los métodos econométricos" [en línea]. Publicaciones Europa, 2001. [fecha de consulta: 30 de mayo del 2016] Disponible en <http://www.angelvila.eu/publicaciones_pdf/problemas_metodos_econometricos.pdf>
- VINCENZO P. (2011) "An Artificial Neural Network Model to Forecast Exchange Rates", Journal of Intelligent Learning Systems and Applications, 3 Italia., 57-69pp
- WITKER, J. (1982) "El Sistema monetario internacional contemporáneo." Boletín mexicano de derecho comparado. México, 45pp
- WRIGHT, J. (2008) "Bayesian model averaging and exchange rate forecasts. Journal of Econometrics", 146(2), 329-341.
- ZAPATA L. (2008), "Predicción del tipo de cambio peso-dólar utilizando Redes Neuronales Artificiales (rna)", Pensamiento & Gestión, Colombia, núm. 24, julio, 29-42pp.