

**SISTEMA DE PRONÓSTICOS BASADO EN REDES NEURONALES
ARTIFICIALES PARA PREDECIR LA DEMANDA DE PRODUCTOS
FARMACÉUTICOS QUE SON AFECTADOS POR CAMPAÑAS
PROMOCIONALES.**

**DANIEL ESTEBAN ARAGÓN CARDONA
VÍCTOR HUGO ORTEGA PORTILLA**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA INDUSTRIAL
SANTIAGO DE CALI, 2014**

**SISTEMA DE PRONÓSTICOS BASADO EN REDES NEURONALES
ARTIFICIALES PARA PREDECIR LA DEMANDA DE PRODUCTOS
FARMACÉUTICOS QUE SON AFECTADOS POR CAMPAÑAS
PROMOCIONALES.**

**DANIEL ESTEBAN ARAGÓN CARDONA
VÍCTOR HUGO ORTEGA PORTILLA**

PROYECTO DE GRADO

**DIRECTOR
JULIO CÉSAR LONDOÑO ORTEGA MSc.**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA INDUSTRIAL
SANTIAGO DE CALI, 2014**

CONTENIDO

1. PLANTEAMIENTO DEL PROBLEMA	10
2. OBJETIVOS.....	17
2.1. OBJETIVO GENERAL.....	17
2.2. OBJETIVOS ESPECÍFICOS.....	17
3. JUSTIFICACIÓN	18
REVISIÓN BIBLIOGRÁFICA.....	19
4. PROCESO METODOLÓGICO	26
5. MARCO TEÓRICO	28
5.1. ARQUITECTURA DE LAS RNA	30
5.1.1. Neuronas de entrada.....	31
5.1.2. Número de capas ocultas	31
5.2. FUNCIÓN DE ACTIVACIÓN.....	33
5.3. APRENDIZAJE	34
5.3.1. Fase de entrenamiento	34
5.3.2. Fase de ejecución y prueba	35
5.3.3. Topología de las redes neuronales.....	36
5.4. CASO DE ESTUDIO	36
5.5. SELECCIÓN DE FACTORES DE ENTRADA A LAS RNA.	37
Factor 1: Tipo de promoción.....	38
Oferta real.....	38
Tipo de promoción general	40
Factor 2: Temporada (Mes).....	40
Factor 3: Punto de Venta.	41
Factor 4: Duración de la promoción	42
Factor 5: Período de duración.....	42
6. MODELO DE PRONÓSTICOS BASADO EN REDES NEURONALES	

ARTIFICIALES	44
6.1. DEFINICIONES	44
6.2. DESCRIPCIÓN DE LA RED NEURONAL UTILIZADA	46
6.3. ENTRENAMIENTO Y PRUEBA	46
6.3.1. Captura de datos	46
6.3.1.1. Codificación de los productos	46
6.3.1.2. Codificación de los puntos de venta	47
6.3.1.3. Clasificación de los tipos de promociones	49
6.3.2. Entrenamiento	49
6.3.3. Prueba	50
6.3.4. Experimentos de entrenamiento y prueba	50
6.4. PREDICCIÓN PARA LA OFERTA Y LA DEMANDA REGULAR	54
6.4.1. Etapa 1	54
6.4.2. Etapa 2	55
6.5. PREDICCIÓN	55
6.6. PRUEBA DE PRONÓSTICOS CON MODELOS TRADICIONALES	61
6.6.1. Modelo de pronósticos tradicionales: Suavización Exponencial Doble (SED) 62	
6.6.2. Método de Lee et al. (2007)	62
6.7. DISCUSIÓN ACERCA DE LOS RESULTADOS	63
7. CONCLUSIONES	65
BILIOGRAFÍA	66
ANEXOS	70

LISTA DE TABLAS

<i>Tabla 1. Los sistemas de pronósticos y el patrón de demanda observado</i>	<i>11</i>
<i>Tabla 2. Descripción de RNA más conocidas.</i>	<i>31</i>
<i>Tabla 3. Características de los algoritmos de entrenamiento más conocidos.</i>	<i>35</i>
<i>Tabla 4. Tipos de promoción y Ofertas.....</i>	<i>39</i>
<i>Tabla 5. Cantidad de promociones por mes y frecuencia de ocurrencia</i>	<i>40</i>
<i>Tabla 6. Período de duración de promociones y mes en que inician</i>	<i>42</i>
<i>Tabla 7. Principales características del software.</i>	<i>45</i>
<i>Tabla 8. Codificación de los productos y número de veces que fue implementada una promoción.....</i>	<i>47</i>
<i>Tabla 9. Código de zona geográfica</i>	<i>48</i>
<i>Tabla 10. Codificación del Punto de Venta y número de veces que fue implementada la promoción.....</i>	<i>48</i>
<i>Tabla 11. Tipos de promociones</i>	<i>49</i>
<i>Tabla 12. Configuraciones y resultados de redes neuronales.....</i>	<i>51</i>
<i>Tabla 13. Configuraciones y resultados de redes neuronales.....</i>	<i>53</i>
<i>Tabla 14. Factores (variables) para el proceso de predicción de la etapa 1.</i>	<i>55</i>
<i>Tabla 15. Factores (variables) para el proceso de predicción de la etapa 2.</i>	<i>55</i>
<i>Tabla 16. Resultados de Indicadores del escenario 1.</i>	<i>58</i>
<i>Tabla 17. Resultados de Indicadores del escenario 2.</i>	<i>59</i>
<i>Tabla 18. Resultados de Indicadores del escenario 2.</i>	<i>60</i>
<i>Tabla 19. Indicadores de error para la SED</i>	<i>62</i>
<i>Tabla 20. Indicadores de error para el método de Lee et al. (2007).....</i>	<i>63</i>

LISTA DE GRÁFICAS

Gráfica 1. Comparación de demanda regular y oferta respecto al tipo de promoción .	38
Gráfica 2. Comparación de demanda regular y promoción respecto a la época del año.	41
Gráfica 3. Comparación de demandas en Punto de venta.....	41
Gráfica 4. Impactos asociados a los factores en el proceso de entrenamiento y prueba de la Oferta.....	52
Gráfica 5. Impactos asociados a los factores en el proceso de entrenamiento y prueba de la demanda regular.	54
Gráfica 6. Resultados de pronósticos para demanda regular y oferta del escenario 1	57
Gráfica 7. Resultados de pronósticos para demanda regular y oferta del escenario 2.	58
Gráfica 8. Resultados de pronósticos para demanda regular y oferta del escenario 3.	60

LISTA DE FIGURAS

Figura 1. Neurona biológica.....	28
Figura 2. Estructura básica de una Red Neuronal Artificial.	30
Figura 3. Principales tipos de funciones de activación.	33
Figura 4. Esquema de un escenario en general de predicción.....	56

LISTA DE ANEXOS

ANEXO A. Comparación de demanda regular y oferta respecto al tipo de promoción: <i>Producto gratis</i>	70
ANEXO B. Comparación de demanda regular y oferta respecto al tipo de promoción: <i>Ahorre \$.</i>	71
ANEXO C. Comparación de demanda regular y promoción respecto a la época del año.	72
ANEXO D. Demanda en Punto de venta 1	73
ANEXO E. Demanda en Punto de venta 2	74
ANEXO F. Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 1.	75
ANEXO G. Conjunto de datos usados para predicción en el escenario 1.....	76
ANEXO H. Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 2.	77
ANEXO I. Conjunto de datos usados para predicción en el escenario 2.....	78
ANEXO J. Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 3.	79
ANEXO K. Conjunto de datos usados para predicción en el escenario 3.....	80
ANEXO L. Escenarios para probar los sistemas de pronósticos (Escenarios 1, 2 y 3).	81
ANEXO M. Modelo de pronósticos tradicional con Suavización Exponencial Doble con indicadores de error (MAD, ECM, PAME) (Escenarios 1, 2 y 3).	83
ANEXO N. Modelo de pronósticos basado en Lee et al. (2007) con Suavización Exponencial Doble e indicadores de error (MAD, ECM, PAME) (Escenarios 1, 2 y 3).	85

INTRODUCCIÓN

Actualmente, los consumidores están cada vez más enterados respecto a los precios, calidad y servicios que ofrecen las empresas de los productos que consumen y, a medida que los mercados se vuelven más exigentes, las organizaciones necesitan diseñar estrategias que les permitan obedecer a estos requerimientos para así expandir su mercado y reducir la competencia. De acuerdo a esto, las promociones de ventas pueden desempeñar un papel importante para alcanzar dichos objetivos organizacionales.

Kotler & Armstrong, (2012) definen las promociones de ventas como incentivos a corto plazo que fomentan la compra o venta de un producto o servicio. Este tipo de maniobras por parte de las empresas incentiva la demanda de forma positiva para generar un mayor volumen de ventas. De la misma forma, llevando este tipo de estrategias al resto de la cadena de abastecimiento, un aumento en el volumen de ventas se ve traducido en una mayor producción que a su vez genera costos asociados al almacenamiento y distribución de los bienes (además de otros que no se tratarán por el momento). Una manera en la cual algunas empresas han sobrellevado este problema de cambio en la demanda es a través de los pronósticos, pero los modelos tradicionales de pronósticos no tienen metodologías establecidas para prever del todo el efecto que generan las promociones en la demanda.

Los pronósticos cumplen un papel importante en los objetivos de las organizaciones dado que intervienen en la toma de decisiones, más profundamente tienen un aspecto fundamental e ineludible en el correcto control de los inventarios, dado que una mala utilización de éstos puede sesgar exageradamente la cantidad de inventario por encima o por debajo de la demanda real y llegar a incurrir en costos o incluso pérdida de clientes.

Los tipos de pronósticos más usados son: cualitativos, series de tiempo, causales por analogía, simulación y combinaciones de los anteriores (Vidal Holguín Holguín, 2010). Estos métodos de pronósticos, por lo general, tienen asociado un error que depende de diferentes atributos que tienen que ver directamente con el comportamiento de la demanda y es por esto que se vuelve

primordial el definir y comprender qué se desea pronosticar, en qué momento y para qué se van a utilizar. De esta forma se convierten los pronósticos en una parte esencial para lograr una buena gestión de inventarios.

Una buena gestión de inventarios conlleva a tener una buena gestión de costos. Dicho de otra manera, mejorar los pronósticos de demanda disminuye el costo de mantener inventario, que a su vez reduce el costo total de la producción, lo que contribuye a una mejor gestión en los costos, producto de una buena gestión de inventarios. Aunque deben tenerse en cuenta otros costos asociados a la fuerza de ventas y otras áreas de las empresas.

Para llevar una buena gestión de inventarios, es necesario tener en cuenta que intrínseco a éstos viene anidado un error típico en el pronóstico, el cual se presenta por la incertidumbre que tienen los datos hacia el futuro, es decir, la variación en el comportamiento que puedan tener respecto de su comportamiento habitual. Ahora bien, reducir el error de los pronósticos es una tarea que puede ser muy ardua y quizás en muchas situaciones difíciles de optimizar.

A lo largo del desarrollo del presente proyecto se argumenta como las redes neuronales han mostrado buenos resultados como sistemas de pronósticos para series temporales que presentan cambios en el comportamiento de la demanda o que son afectados por *intervenciones externas* que pueden o no ser conocidas. De esta forma, se presenta como una buena alternativa a utilizar para prever el comportamiento de la demanda de un producto que es susceptible a promociones.

El presente trabajo de grado es únicamente en función de la promoción. El sistema de pronósticos que se plantea es una propuesta de modelo para predecir el comportamiento de la demanda de un producto de botiquín al momento de una promoción de ventas. Para esto se proceden a describir y analizar factores que influyen en el comportamiento de compra de los clientes para el producto que ha sido objeto de estudio, los cuales serán el insumo principal para el modelo de RNA que se propone como alternativa de solución a la situación planteada.

1. PLANTEAMIENTO DEL PROBLEMA

Actualmente los mercados tienen un alto grado de dinamismo y las organizaciones deben ajustar sus estrategias frente a la dinámica competitiva del mercado. En este sentido las empresas ofrecen a los consumidores productos o servicios con características que satisfagan las necesidades y deseos de los clientes. Debido a esto, las empresas realizan estrategias con el propósito de capturar y retener a los clientes para generar rentabilidad que le permita mantenerse en el juego.

Un factor muy importante dentro los mercados es la competitividad, puesto que un consumidor puede elegir entre varios productos y/o servicios y su decisión depende de cuál se ajusta a sus requerimientos. Si el producto que se ofrece al cliente satisface todas o la mayoría de sus expectativas respecto del(los) que ofrece(n) la competencia, el producto será demandado por el mercado.

La demanda puede establecerse como la necesidad o deseo que tiene un consumidor por un producto o servicio, respaldado por su capacidad de compra (Kotler & Armstrong, 2012). En este sentido, ya que la demanda de un producto sólo se puede saber en el momento en que ocurre, es necesario conocer, para planear la producción, cuál será la demanda futura. En este punto es necesario pronosticar lo que sucederá con la demanda y es por esto que aparecen como alternativa diferentes tipos de sistemas para pronosticar a partir del comportamiento de la demanda.

La demanda, dependiendo del tipo de producto/servicio, la época del año, la demografía, entre otros factores, presenta diferentes comportamientos. Vidal Holguín Holguín,(2010) presenta un resumen de los patrones de la demanda:

- Demanda perpetua o uniforme: Su promedio se mantiene por largos períodos de tiempo y su fluctuación permanece dentro de rangos “pequeños”.
- Demanda con tendencia: Puede ser creciente o decreciente. Su promedio de demanda varía significativamente.

- Demanda periódica o estacional: La demanda de este tipo de productos se caracteriza por presentar picos en ciertos períodos de tiempo conocidos y demanda aproximadamente uniforme en los demás períodos.
- Demanda altamente correlacionada: Se presenta cuando la demanda de un ítem depende en gran medida de la demanda de otro ítem.
- Demanda errática: Presenta grandes variaciones a lo largo del tiempo, pasando de períodos de cero demanda a grandes picos. La diferencia entre éste patrón y el periódico o estacional, es que en el errático los picos no son predecibles.

Para cada patrón de demanda se utiliza un tipo de sistema de pronóstico propio de cada uno. En la siguiente tabla se muestra de forma sintetizada, el comportamiento y sistema de pronóstico a utilizar en cada caso:

Tabla 1. Los sistemas de pronósticos y el patrón de demanda observado

PATRÓN DE DEMANDA OBSERVADO	SISTEMA DE PRONÓSTICO RECOMENDADO
Perpetua, estable o uniforme	Promedio móvil o suavización exponencial simple
Con tendencia creciente o decreciente	Regresión lineal simple o suavización exponencial doble
Estacional o periódica	Modelos periódicos de Winters
Demandas altamente correlacionadas	Métodos integrados de promedios móviles auto-regresivos (ARIMA)
Errática (Por ejemplo, en ítems clase A de bajo movimiento)	Pronóstico combinado de tiempo entre la ocurrencia de demandas consecutivas y la magnitud de las transacciones individuales (Método de Croston y relacionados)

Fuente: Adaptada de Vidal Holguín (2010).

Además del comportamiento de la demanda, se debe tener en cuenta que esta no sucede por sí sola y que hay factores que desencadenan el comportamiento propiamente dicho.

Adicional a los patrones usuales de la demanda hay situaciones que obligan a que la serie de tiempo cambie su comportamiento habitual. Wei, (2006) expone que las series de tiempo se ven afectadas por eventos externos conocidos tales como días festivos o promociones de ventas, y desconocidos como los valores atípicos. A estos eventos los llama *Intervenciones externas*.

En este caso se estudiará el efecto que pueden tener las promociones de ventas como intervenciones externas y los factores que afectan a la demanda para

cambiar el comportamiento de la misma. A continuación se presenta una breve definición de lo que son las promociones.

Las promociones se pueden ver como incentivos a corto plazo para fomentar la compra o la venta de un producto o servicio. Según Kotler & Armstrong, (2012) existen tres factores que han contribuido al rápido crecimiento de la promoción de ventas, sobre todo en los mercados de consumo:

- Las empresas se enfrentan a una mayor competencia.
- Los gerentes de marketing deben enfrentarse a mayores presiones para aumentar las ventas.
- La ineficiencia de la publicidad, el desorden de los medios de comunicación y las restricciones legales.

Dado que con las promociones se busca maximizar las ganancias, Muñíz (2010) presenta objetivos específicos a cumplir por medio de estas, que entre otros pueden ser:

- Incrementar las ventas.
- Contrarrestar acciones de la competencia.
- Conseguir nuevos clientes.
- Potenciar la marca.
- Generar liquidez económica.
- Fidelizar.
- Introducir nuevos productos.
- Motivar equipos de venta.
- Reforzar la campaña publicitaria.

Puesto de esta forma, es claro ver que el objetivo general de las empresas es incrementar la demanda de sus productos. Ahora bien, para conseguir que éstos objetivos se lleven a cabo, es necesario implementar diferentes estrategias en cuanto a las promociones. Perreault & McCarthy, (2001) presentan una lista con diferentes clases de promociones que pueden llegar a presentarse en la mezcla de mercado: (i) Venta personal, (ii) Publicidad, (iii) concursos a sus clientes potenciales, (iv) concursos a la fuerza de ventas, (v) ferias comerciales, (vi)

correo directo, (vii) merchandising, (viii) muestras, (ix) cupones y (x) patrocinio en eventos.

Para poner en marcha una promoción primero se debe pronosticar la posible demanda que ha de suceder en ese lapso, esto principalmente para mantener un nivel de servicio que a su vez va ligado el nivel de inventario que se tenga para suplir la demanda venidera, el movimiento de los productos asociado a la demanda y toda la demás logística asociada como lo es la planeación de la producción y ventas, las compras de materia prima, el transporte y tratamiento de materia prima (MP), productos en proceso (WIP, por sus siglas en inglés) y producto terminado (PT).

Se debe tener especial cuidado con el esfuerzo extra por parte de los recursos, ya que en el mismo espacio de tiempo el área de producción debe producir una cantidad mayor de producto al que se acostumbra y de manera análoga, el área de compras y control de calidad deben controlar una mayor cantidad de unidades y se debe vender una mayor cantidad de productos. Es decir que los recursos de la cadena de suministro deben aumentar su productividad respecto a su trabajo habitual. O'Donnell et al, (2009), evidencian y proponen un algoritmo genético para reducir los efectos negativos que hay sobre la cadena de abastecimiento, el cual se valida primero siendo utilizado para determinar la política de ordenamiento óptima con una versión en línea del juego de la cerveza (Beer Game) por parte del MIT, y luego se aplica a una serie de experimentos con demanda y plazos de entrega deterministas, aleatorios combinados con las promociones en ventas.

Dado que las empresas también utilizan las promociones como estrategia para generar recordación de marca por parte de los consumidores en el mercado, es de gran importancia conocer previamente el comportamiento que la demanda pueda llegar a tener durante esta *intervención externa*.

Para identificar el comportamiento, se plantearán cuatro puntos clave en los datos de la serie de tiempo: (i) el punto inicial de la serie, (ii) el punto inicial de la promoción, (iii) el punto final de la promoción y (iv) el punto final de la serie.

El lapso inicial, contemplado entre el punto inicial de la serie y el punto inicial de la promoción, puede contener uno o una combinación de los patrones presentados en la tabla 1.

En el lapso secundario, que se encuentra entre el punto inicial de la promoción y el punto final de la promoción, generalmente la demanda presenta una tendencia positiva, pero al ser una intervención externa, el tipo de pronóstico utilizado en el primer lapso, no sigue siendo tan efectivo. La tendencia que se presenta puede deberse a factores tales como el tipo, momento, lugar, la marca, entre otros, de la promoción. Estos nuevos factores afectan los sistemas de información que se tienen respecto del patrón de demanda que ocurre antes de ésta situación en especial y es debido a esto que el sistema de pronósticos que se usa para el lapso inicial debe ser modificado. Para ésta situación en que existen eventos especiales, Lee, et al. (2007) presentan una serie de factores que afectan a la demanda y los toman en cuenta para el desarrollo de su modelo de pronósticos pero al mismo tiempo mencionan la importancia que el juicio de expertos o la gerencia tiene con el fin de reducir la variación de los pronósticos y estar alerta a cualquier eventualidad.

Por último, en el lapso final, entre el punto final de la promoción y el punto final de la serie, en el transcurso de la investigación del proyecto, hasta el momento pueden existir cuatro situaciones respecto al comportamiento de la demanda:

- a) Tendencia extendida: La tendencia de la demanda continúa aún después de terminada la promoción. Esto puede deberse a que, luego de que el período de promociones ha terminado, la demanda haya “reactivado” el ciclo de vida del producto o a que el producto se haya estancado antes de que ésta promoción apareciera en un momento previo a llegar a su punto de madurez.
- b) Promoción como evento desapercibido: Luego de terminadas las promociones, la demanda continúa con su comportamiento habitual, lo que da a pensar que la demanda se ve altamente influenciada por estas maniobras mercantiles, pero que luego de que éstas opciones de compra desaparecen, el producto se sigue consumiendo “como si nada hubiera pasado”. En este punto, el producto ya se encontraba maduro en el ciclo de vida.

- c) Resurgimiento de la demanda: Al momento en que las promociones llegan a su fin, la demanda no vuelve al punto alrededor del cual venía oscilando, sino que continúa su comportamiento en el punto en que la demanda ha terminado. Esta situación ocurre si el producto, luego de la promoción, ha alcanzado su punto de madurez en el ciclo de vida; de este modo el pronóstico de demanda debe actualizarse para evitar una mala gestión e incurrir en costos innecesarios.
- d) Caída de la demanda: Luego de que las promociones terminan, la demanda es menor de la que se presentaba antes de que éstas se realizaran. Esta situación puede presentarse debido a que (a) el producto ya está llegando al final de su ciclo de vida (Kotler & Armstrong, 2012), (b) a que los consumidores han obtenido una mayor cantidad del producto que generalmente consumen a un precio menor o a una mayor cantidad por el mismo precio (Ailawadi & Neslin, 1998) o (c) compran el producto por atributos que no tienen que ver con el producto en sí como un tipo de colección, un regalo, una rifa, entre otros.

Debido a estos posibles cambios en la elasticidad y el comportamiento de la demanda y a que estas intervenciones externas son conocidas, se debería hacer ahínco en los efectos externos que se conciben como producto de las promociones. De la misma forma, Ramanathan & Muyldermans, (2010) sostienen que las promociones de ventas pueden estar influenciadas por factores tales como el clima, los períodos de vacaciones y festividades que a veces se pasan por alto. Además de esto, presentan dentro de sus resultados que los factores de demanda que afectan a ciertos productos no necesariamente influyen en la misma medida sobre otros.

En situaciones como esta, en que el comportamiento de una variable en el tiempo es afectada (en este caso, demanda) por diferentes factores, se ha demostrado que las redes neuronales (en inglés, Artificial Neural Networks: ANN) como herramienta para el pronóstico obtienen buenos resultados. Aguirre & Martínez, (2012) utilizan las redes neuronales para pronosticar la demanda de alimentos en el comedor institucional de la Universidad del Valle. Concluyen que utilizar un modelo basado en redes neuronales es una mejor alternativa que los métodos clásicos para pronosticar la demanda, esto debido principalmente a la

velocidad de respuesta de cada uno. Ghiassi, et al. (2005) consideran que las Redes neuronales han mostrado ser un método efectivo para el pronóstico de las series de tiempo, y por su parte, desarrollan un modelo de red neuronal que utiliza diferentes arquitecturas de los modelos tradicionales (*feed-forward, back-propagation: FFBP*).

Es conveniente entonces plantear un sistema de pronóstico basado en redes neuronales para el comportamiento de la demanda de un producto que es susceptible de ser promocionado. Esto para tomar en cuenta al momento de pronosticar, todos o por lo menos una gran cantidad de factores y la incidencia que cada uno de ellos pueda tener sobre el producto.

A partir de este punto se plantean las redes neuronales como herramienta a desarrollar para generar un sistema de pronósticos en el que se puedan tomar en cuenta los factores externos que pueden o no ser controlables y que afectan al comportamiento de la demanda. Se cuenta con datos de demanda de una serie de productos de botiquín de cierta empresa nacional en Colombia y, por la facilidad de consecución de los mismos y al seguimiento que se les puede dar para relacionar los factores externos, se ha optado por utilizarlos en el ejercicio del presente proyecto de grado para demostrar la efectividad que puede llegar a tener un sistema de pronósticos basado en redes neuronales aplicado a productos que pueden ser promocionados.

A lo largo del documento (y de las referencias que se presentan en el estado del arte) se presentan diferentes tipos de arquitecturas de redes neuronales, las cuales han sido bien vistas de acuerdo al uso que se les ha dado en específico para cada investigación. Ahora bien, tomando en cuenta entonces que las diferentes arquitecturas de redes neuronales permiten prever el comportamiento de una serie de datos afectada por diferentes factores a partir de la historia y que pueden ser utilizadas como base para un sistema de pronósticos, se debe seleccionar el modelo de arquitectura apropiado para el tipo de producto del presente estudio. Queda entonces como pregunta de investigación ¿Cómo pronosticar la demanda de un producto bajo efectos de campañas promocionales, utilizando técnicas basadas en redes neuronales?

2. OBJETIVOS

2.1. OBJETIVO GENERAL

Establecer un sistema de pronósticos basado en redes neuronales para predecir la demanda de productos farmacéuticos que son afectados por campañas promocionales.

2.2. OBJETIVOS ESPECÍFICOS

- Identificar patrones de demanda que se presentan como consecuencia de las promociones de productos de botiquín mediante el análisis gráfico de datos.
- Identificar cuáles podrían ser los principales factores que afectan la decisión de compra del consumidor en productos de botiquín a partir de la caracterización de las diferentes tipos de promociones.
- Construir sistemas de pronósticos mediante diferentes arquitecturas de redes neuronales.
- Evaluar la efectividad de las diferentes arquitecturas utilizadas realizando comparaciones con base en el error cuadrático medio obtenido.

3. JUSTIFICACIÓN

El éxito de las organizaciones depende en gran medida de qué tan presente esté su marca en la consciencia de los consumidores. Una forma de estar en la mente de las personas, de manera positiva para la empresa, es a partir del nivel de servicio que éstas puedan brindar a sus compradores. Para cumplir con éste objetivo, la predicción de la demanda futura de sus productos tiende a convertirse en un gran eslabón de la cadena, siendo los sistemas de pronósticos un elemento clave para cumplir con los objetivos de la organización y para el mejoramiento de su competitividad, ya que de no tomar las decisiones correctas, se puede caer en extremos como el deficiente servicio al cliente, el exceso de inventarios o, peor aún, ambos factores en forma simultánea cuando se presenta el desbalanceo de los inventarios para ofrecer un buen servicio (Vidal Holguín, 2010). Es decir, lograr que el producto que requiera un consumidor esté disponible al momento y en la cantidad que necesita, sin que esto afecte de forma negativa a la gestión de costos de la empresa. En este sentido surge la necesidad de establecer sistemas de pronósticos que permitan dar cumplimiento a los objetivos tanto de producción como de toda la empresa. Dado que hay situaciones en las que el comportamiento normal de la demanda es afectado por intervenciones externas (como en el caso de las promociones), el pronóstico de la demanda se convierte en una tarea compleja de realizar debido a la variabilidad que se presenta a causa de este cambio inducido en la decisión de compra de los consumidores. No solucionar esta situación llevaría a que las empresas presenten pronósticos sesgados, ocasionando con esto incremento en costos de inventario y pérdida del nivel de servicio al cliente.

En los últimos años las promociones de ventas han experimentado un auge importante en nuestros mercados como consecuencia de una evolución en el consumidor, y por esta razón esta herramienta se ha convertido en una de las más poderosas armas de la estrategia de mercadeo. Ramanathan & Muyldermans, (2010) muestran cómo las promociones se han convertido en una práctica común en muchos puntos de venta al por menor. Este artículo identifica factores de demanda para la planeación y pronóstico de promociones para una compañía de refrescos en el Reino Unido.

Permitir incrementar la demanda de los productos y así mismo atraer y retener a los consumidores es un objetivo que buscan las empresas; y la promoción de ventas es lo que básicamente ofrece. Pero obtener de forma exitosa una campaña de promoción requiere de una alta capacidad de planeación, dado que existen elementos internos y externos que afectan los objetivos de la misma. Estos elementos pueden ser: recursos de producción, proveedores, publicidad, logística, presupuestos, pronósticos, entre otros. Los pronósticos desempeñan un papel muy importante dentro de las campañas de promoción, puesto que determinar las previsiones de demanda es complicado cuando el comportamiento de los datos no es normal, debido a que existirán datos atípicos (demanda con promoción) que aumentan la variabilidad de la serie y terminan convirtiendo la gestión de inventarios en una tarea costosa si se quiere mantener un nivel de servicio adecuado. De esta manera, establecer un buen sistema de pronóstico reflejará gran incidencia en el éxito de la campaña de promoción, dado que determinar con mayor grado de exactitud la demanda que tendrá la promoción, hará que se reduzcan los costos de inventario y de esta manera mayor ganancia para la empresa.

REVISIÓN BIBLIOGRÁFICA

De acuerdo a las búsquedas realizadas en diferentes bases de datos, hasta el 20 de diciembre de 2013 se encontraron, ente otros, los siguientes artículos respecto al tema de pronósticos de demanda, promoción de ventas y redes neuronales los cuales se presentan a continuación:

Theoretical models of sales promotions: Contributions, limitations, and a future research agenda (Raju, 1995).

El objetivo de este artículo es revisar modelos teóricos de promociones de ventas. Se destacan las contribuciones clave de esos modelos, se discuten sus limitantes y se perfila una agenda para una futura investigación. Las preguntas examinadas en los modelos incluyen asuntos fundamentales como por qué las empresas recurren a promociones de ventas en mercados maduros y por qué el uso de las promociones de ventas se han incrementado tanto durante las últimas décadas (años 80 y 90). Se incluye en este artículo una revisión de modelos

dirigidos a nivel estratégico de las empresas, tales como la asignación de dólares entre publicidad y promociones de ventas y el énfasis relativo entre las promociones comerciales y promociones para el consumidor. También se revisan modelos teóricos que explican cómo responden los consumidores a los precios de las promociones y qué tipo de herramientas de promociones de ventas deben ser superiores a otras en un tipo de mercado en particular.

Retailer promotion planning: Improving forecast accuracy and interpretability (Trusov, et al., 2006).

Este artículo considera el problema de pronosticar las ventas de productos teniendo en cuenta los atributos del mismo, los niveles históricos de ventas y las promociones de ventas. Reconoce que la implementación de un modelo de pronósticos es un problema estadístico muy difícil de solucionar. En el artículo se propone un motor analítico que combina técnicas de modelado estadístico, minería de datos, y la optimización combinatoria para producir un pequeño conjunto de reglas eficaces que pronostica los niveles de volumen de ventas.

La influencia de las promociones de ventas en la decisión de compra (Cavlovic, 2007).

El artículo tiene como objetivo revisar diferentes tipos de efectos causados por las promociones de ventas en la decisión de compra de los consumidores. De acuerdo al marco conceptual general de las promociones de ventas, se resaltan los principales hallazgos y limitaciones encontradas a través de diversos estudios. Los autores proponen que los efectos causados por las promociones en ventas deberían ser contrastados por medio de futuras investigaciones.

Providing support for the use of analogies in demand forecasting tasks (Lee et al., 2007).

El artículo menciona la importancia que tiene el juicio de la gerencia en el uso de los pronósticos estadísticos con el fin de tener en cuenta los eventos especiales, tales como las promociones de ventas. Hay evidencia de que se utiliza a menudo la información de eventos similares del pasado para ayudar a estimar las previsiones de los efectos de un evento especial. “*Hemos llevado a cabo un*

experimento para investigar si un sistema de apoyo pronóstico (FSS), que proporciona a los usuarios orientación sobre juicios de similitud y el apoyo a los juicios de adaptación, podría conducir a hacer previsiones más precisas de los efectos de las promociones de ventas". El experimento sugiere que una forma simple, fácil de implementar de apoyo a la adaptación podría mejorar significativamente la exactitud del pronóstico en ciertas condiciones.

Reducing the negative effects of sales promotions in supply chains using genetic algorithms (O'Donnell et al., 2009).

Este trabajo considera el efecto negativo que tienen las promociones de ventas en la cadena de suministro. Los autores proponen un algoritmo genético para reducir estos efectos. Con el fin de validar el algoritmo genético, se aplica el modelo a una línea de distribución de cerveza del MIT. Posteriormente, el algoritmo genético se aplica en una serie de experimentos en los que la demanda es determinística y aleatoria y combinando plazos de entrega con las promociones de ventas. También el artículo muestra cómo los algoritmos genéticos se pueden utilizar no sólo para amortiguar el impacto del efecto látigo sino también para ayudar a los gerentes encargados del abastecimiento en la predicción para reordenar cantidades a lo largo de la cadena de suministro.

Como se mencionó anteriormente las campañas promocionales no sólo van acompañadas de incrementos en las ventas de los productos, sino que también se ejerce un efecto sobre toda la cadena de suministro, es decir, la evidencia del denominado efecto látigo. Este artículo menciona esos efectos y por consiguiente surge la necesidad de precisar aún más sobre los pronósticos de demanda para tener como resultado campañas promocionales exitosas.

Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK (Ramanathan & Muijldermans, 2010).

El artículo muestra cómo las promociones se han convertido en una práctica común en muchos puntos de venta al por menor. Por lo general, estas promociones se planifican conjuntamente por los fabricantes y los minoristas, haciendo acuerdos sobre los productos de la promoción y tipos de promociones,

como por ejemplo: la reducción de precios y el calendario de las promociones. Sin embargo, las ventas también pueden estar influidas por otros factores como el clima, los períodos de vacaciones y festivales, que a veces se pasan por alto. En esta investigación, se identifica un conjunto de factores que influyen en la demanda de las ventas de una empresa líder de refrescos en el Reino Unido. El autor relaciona los factores de la demanda con las ventas reales de la empresa para obtener una visión más clara de la estructura de la demanda subyacente. Para lograr esto, se utilizan modelos de ecuaciones estructurales. Los resultados obtenidos confirman el papel de los factores de promoción en el incremento de las ventas para todos los productos. Sin embargo, algunos factores de la demanda influyen sólo en unos productos. Esto sugiere que existen diferentes estructuras de la demanda para diferentes familias de productos, y confirman la importancia de recopilar e intercambiar la información adecuada de la cadena de suministro. En general el enfoque también puede ayudar a los gerentes a planificar, prever y promover los diferentes productos en colaboración con otros socios de la cadena de suministro.

El autor dentro de su investigación identifica factores asociados a la demanda normal y con promociones, por esta razón es muy importante este artículo para el presente proyecto, dado que uno de los objetivos es identificar factores asociados a las demanda con promociones.

Un modelo para el pronóstico de demanda de productos alimenticios en un restaurante institucional (Aguirre & Martínez, 2012).

Los autores proponen la utilización de redes neuronales como alternativa para pronosticar el comportamiento de la demanda de productos alimenticios en el comedor de la Universidad del Valle. Para éste caso, se identifican factores como el día de la semana y semestre, menú ofrecido, entre otros que afectan la decisión de los usuarios. Se concluye que para pronosticar la demanda cuando existen factores externos que afectan el comportamiento, las redes neuronales presentan mejores resultados que con los métodos tradicionales.

Supply chain collaboration for improved forecast accuracy of promotional sales (Rammanathan, 2012).

El autor de este artículo muestra las promociones de ventas como un vínculo entre los minoristas con los fabricantes. Esto para mejorar las ventas bajo elementos como planificación, previsión y reabastecimiento. El propósito de este trabajo es plantear la hipótesis de que los pronósticos en colaboración mejorarán la precisión de los mismos involucrando los factores subyacentes de la demanda. Se implementa un enfoque de estudio de caso para estudiar diversos factores de la demanda de productos de gaseosas de una empresa con sede en Reino Unido, que ofrece promociones frecuentes en los puntos de venta. Los resultados del estudio de caso se validan empíricamente por medio de análisis de regresión lineal múltiple a partir de datos reales de ventas de la empresa. Entre los hallazgos se encuentra que algunos de los factores de demanda especificados como muy importantes por la empresa no se encuentran como altamente significativos para las ventas reales. En resumen lo que busca el autor es comprender la importancia de los factores de demanda de productos específicos a través de modelos de regresión y la incorporación de los mismos en la toma de decisiones de gestión, dado que esto ayudará a los administradores a identificar la información necesaria para hacer pronósticos de demanda más precisas.

Price promotions, operations cost, and profit in a two-stage supply chain (Su & Geunes, 2012).

Este artículo menciona cómo la variabilidad de la demanda aumenta a medida que uno se desplaza aguas arriba en la cadena de suministro. Este llamado "efecto látigo" (Bullwhip effect) a menudo aumenta los costos de las operaciones, incluyendo el inventario y los costos de transporte. Las variaciones de precios son consideradas como una de las causas principales del efecto látigo, y por lo tanto se recomienda comúnmente estrategias de precios bajos para contrarrestar los efectos del mismo.

Se demuestra que a pesar de que el uso de las promociones puede en realidad incrementar los costos de los minoristas y proveedores, esos costos pueden ser más que compensados con ganancias mayores, inclusive en ausencia de coordinación explícita. Es decir, si el proveedor aplica juiciosamente una

estrategia de promoción y el minorista traspasa algo de ese descuento a sus consumidores, entonces bajo ciertas condiciones, el beneficio resultante de la cadena de abastecimiento puede exceder el de una estrategia constante con base en un bajo precio.

Analysis of judgmental adjustments in the presence of promotions (Trapero et al., 2013).

El artículo menciona que los pronósticos de ventas son cada vez más complejos debido a una serie de factores, como el corto de los ciclos de vida de los productos, mercados cada vez más competitivos, y el marketing agresivo. A menudo, los pronósticos se elaboran utilizando un sistema de apoyo que integra pronósticos estadísticos univariados con el juicio de los expertos en la organización. También dice que los gerentes añaden información a los pronósticos para futuras promociones y así se mejora la exactitud. A pesar de la importancia del análisis de juicio en las promociones, son escasos los documentos dedicados a estudiar su relación con el rendimiento del pronóstico. Los autores analizan la exactitud de los ajustes de gestión en periodos de promociones, con base en datos semanales de una empresa manufacturera.

El análisis se utiliza para establecer si los ajustes realizados a partir del juicio de expertos pueden ser sustituidos por los modelos estadísticos multivariados que respondan a la información promocional. Se demuestra que los ajustes de juicio pueden mejorar los pronósticos iniciales durante las promociones, pero no de manera sistemática. Finalmente, construyen un modelo híbrido e ilustran el hecho de que los expertos humanos todavía dan valor añadido a los modelos de función de transferencia.

En los diferentes artículos citados se llega a la conclusión de que es necesario utilizar modelos de pronósticos que tengan un mayor alcance para prever el comportamiento de la demanda, es decir, que presenten menor diferencia entre el pronóstico y el dato real. Para esto, diferentes autores presentan el hecho de que es necesario tomar en cuenta no sólo el comportamiento de la demanda, sino también el por qué se presenta dicho comportamiento: Hacer seguimiento a los datos para saber cómo es que se afectan e incluir el peso que éstos puedan

llegar a tener y cómo afectan al comportamiento de compra para un producto en especial.

Las redes neuronales por el hecho de incluir entre sus atributos un peso para la diferente cantidad de factores que puedan hacer parte de las decisiones de compra por parte de los consumidores, se presenta como una buena alternativa a evaluar.

4. PROCESO METODOLÓGICO

Existe un supuesto fundamental de que la demanda es independiente. Un ejemplo de esto es lo planteado por Vidal Holguín (2010), quien considera que un aspecto muy importante de la demanda es precisamente su carácter de independiente es decir, que es causada por entes externos a la empresa como el hecho de que los clientes compren los productos finales que la empresa manufactura. Al mismo tiempo, la demanda dependiente, como su nombre lo indica, depende de otras demandas, como lo son las materias primas y los componentes que se utilizan para realizar un determinado producto.

Sostiene además que no existe una metodología clara y unificada para definir el control de la demanda dependiente de una manera integral con la demanda independiente. A pesar de que la modelación de la demanda independiente ha tenido un buen desarrollo, y que a su vez, la programación de los requerimientos de materiales en distintos ambientes productivos cuenta con una serie de técnicas para definir el control de la demanda dependiente, especialmente mediante métodos determinísticos, no hay un desarrollo que permita definir claramente cómo pasar de la demanda independiente a la demanda dependiente.

Además de presentar un modelo para la predicción de la demanda de productos susceptibles a ser promocionados utilizando redes neuronales, en el desarrollo del proyecto se realiza un ejercicio para demostrar que el supuesto de que la demanda es independiente, no es del todo cierto. Esto es debido a la cantidad de factores (medibles o no) que hacen que un consumidor cambie de opinión en su decisión por comprar una cantidad determinada de cierto producto. Ejemplo de esto es la *mezcla de mercado*, en la que la fuerza de ventas está asociada al producto, precio, plaza y promoción, en la cual se supone que cada una de estas fuerzas genera un impacto en la decisión de compra del consumidor. Kotler & Armstrong, (2012) definen la mezcla de mercado como “*el conjunto de herramientas tácticas controlables de mercadotecnia que la empresa combina para producir una respuesta deseada en el mercado meta. La mezcla de mercado incluye todo lo que la empresa puede hacer para influir en la demanda*

de su producto”.

En los capítulos siguientes se plantean una definición de las redes neuronales y su estructura, luego se procede a describir el caso de estudio abordado, después se muestra cómo se desarrolla el modelo de pronósticos y por último se concluye acerca de los resultados del mismo.


5. MARCO TEÓRICO

Como primera medida, se presenta un resumen acerca de qué son y cómo se utilizan las redes neuronales, las cuales son la base para el pronóstico propuesto en este trabajo de grado.

Las Redes Neuronales Artificiales (RNA) son recursos que realizan cálculos multifactoriales para encontrar un resultado a partir de ciertos valores o entradas. Las RNA tienen su origen en el concepto de neurona artificial introducido por McCulloch & Pitts, (1943), el cual se basa en supuestos acerca de la forma en que trabajan las neuronas biológicas (Ver figura 1).

Las RNA contienen capas de nodos de computación que operan como dispositivos adicionadores. Estos nodos están interconectados por líneas de conexión ponderadas y los pesos se ajustan cuando se introducen los datos iniciales a la red para el proceso de entrenamiento.

Figura 1. Neurona biológica



Fuente: Tomado de Bustamante, (2007)

Matich, (2001) presenta algunas ventajas que incluyen las redes neuronales:

- Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante la etapa de aprendizaje.
- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener,

incluso sufriendo un gran daño.


- Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

Las neuronas se distribuyen dentro de una red formando niveles o capas, las cuales pueden ser de *entrada* (realizan función(es) de entrada), *ocultas* (se distribuyen dentro de otras capas superiores) o de *salida* (realizan función(es) de salida), que a su vez se encuentran conectadas entre sí. Una red puede estar compuesta de una sola capa (monocapa, la cual cumple las funciones de entrada y salida simultáneamente) o de varias capas (multicapa). Dicha distribución es conocida como topología y es la base para definir la estructura que tiene una red neuronal.

De la misma forma, la estructura que determina el funcionamiento de las redes está definida básicamente por la arquitectura (el número de capas ocultas y el número de nodos de esas capas), los pesos sinápticos (parámetro asignado a cada conexión de neuronas), los términos de tendencia o Bias (parámetro asignado a cada neurona) y la función de activación (encargada de convertir los valores de entrada de cada neurona en su valor de salida) (Flórez & Fernández, 2008); (Caicedo & López, 2009); (Bazán, 2012). La figura 2 representa la estructura básica de una RNA, donde:

$x_1, \dots, x_n$	→ Valores de entrada de la neurona j
$w_{j1}, \dots, w_{jn}$	→ Valores de los pesos sinápticos de la neurona j
θ_j o Bias $_j$	→ Valor propio de tendencia de la neurona j
$f(\Sigma)$ o Net $_j$	→ Función de entrada junto con el <i>Bias</i> asociado en la neurona j
$\varphi(\cdot)_j$	→ Función de activación en la neurona j
$f(o)$	→ Función de salida de la neurona j
y_j	→ Valor de salida de la neurona j

Figura 2. Estructura básica de una Red Neuronal Artificial.



Fuente: Autores

De manera general, las neuronas artificiales pueden clasificarse en binarias (solo toman valores dentro del intervalo $\{0,1\}$ o $\{-1,1\}$) o reales (toman valores dentro del rango $[0,1]$ o $[-1,1]$). Aunque los pesos no están restringidos a cierto intervalo, puede que esto sea necesario para ciertas aplicaciones específicas.

La tabla 2 presenta algunas de las redes neuronales más conocidas junto con sus aplicaciones principales, limitaciones y algunos comentarios presentados por Gómez, et al (1994).

5.1. ARQUITECTURA DE LAS RNA

La arquitectura de una Red Neuronal Artificial (RNA) se define por la cantidad de neuronas que van en cada capa, las capas que la constituyen (monocapa o multicapa) y la forma en que la información fluye a través de ellas (unidireccionales o recurrentes).

En las redes unidireccionales la información va en una única dirección y todas las neuronas están interconectadas entre sí, mientras que en las recurrentes no siempre sucede lo mismo con respecto de la información, debido a que éstas pueden retroalimentarse de capas anteriores a través de conexiones sinápticas.

Tabla 2. Descripción de RNA más conocidas.

Nombre de la red	Inventores y Desarrolladores	Año	Aplicaciones principales	Limitaciones	Comentarios
ART	Gail Carpenter, Univ. Northeastern; Stephen Grossberg, Univ. Boston.	1978-1986	Reconocimiento patrones, especialmente cuando el patrón es complicado o poco familiar para los humanos (sonidos, lecturas de radar o sonar)	Sensible a distorsiones y cambios en la escala	Muy sofisticado, no aplicado todavía a demasiados problemas
Madaline	Bernard Widrow, Univ. Stanford	1960-1962	Módems adaptativos; ecualizadores adaptativos (canceladores de eco) en líneas telefónicas	Supone una relación lineal entre entrada y salida	Cuenta con aplicaciones comerciales desde hace más de 20 años
Necognitron	Kunihilo Fukushima, Laboratorios NHK	1978-1984	Reconocimiento de caracteres manuscritos	Necesita de un número muy grande de elemento de proceso y conexión	Una de las redes más complicadas que se han desarrollado; insensible a las diferencias de escala, traslación o rotación
Perceptrón	Franj Rosenblatt, Univ. Cornell	1957	Reconocimiento de caracteres	No puede reconocer caracteres complejos (como los chinos)	Es la red neuronal más antigua; poco utilizada hoy en día
Retropropagación	Paul Werbos, Univ. Harvard; David Rumelhart, Univ. Stanford	1974-1985	Síntesis fonética de textos; control adaptativo de brazos de robots	Sólo entrenamiento supervisado, los ejemplos de entrada-salida deben ser abundantes	Es la red neuronal más popular hoy en día
Hopfield	John Hopfield, California, Laboratorio AT&T Bell	1982	Recuperación de datos o imágenes completos de fragmentos	No aprende, los pesos deben estar compuestos de fragmentos	Puede ser implementada en gran escala
Memoria, asociativa bidireccional	Bark Kosko, Univ. Southern California	1985	Memoria asociativa direccionable por contenidos	Baja densidad de almacenamiento; los datos deben estar convencionalmente codificados	La red que más fácilmente aprende

Fuente: Adaptado de Gómez, et al (1994).

5.1.1. Neuronas de entrada

El número de neuronas de entrada se selecciona una vez que las variables independientes se ha pre-procesado, ya que cada variable independiente es representada por su neurona de entrada propia (Benedetti, et al., 2011).

5.1.2. Número de capas ocultas

Las capas ocultas son las encargadas del procesamiento y transmiten la

información desde las capas de entrada hasta las capas de salida. De esta forma, todas las neuronas de una capa cualquiera están interconectadas con todas las neuronas de la capa previa y la siguiente. No está de más decir que una red monocapa no posee capas ocultas debido a que la capa de entrada es la misma capa de salida.

Una red muy conocida de tipo multicapa es el MLP o *Multilayer Perceptron* (Perceptrón Multicapa), el cual es una adaptación del Perceptrón original presentado por Rosenblatt (1958). La diferencia radica en que se realiza con una estructura en la cual se plantean capas ocultas.


Las MLP permiten hacer predicciones más rápidamente y presentan una mayor fiabilidad cuando el valor de alguna variable de entrada se encuentra por fuera del rango de valores de esa variable en los datos de entrenamiento. Además, tienen la capacidad de generalizar a partir de conjuntos de entrenamiento muy pequeños (Bazán, 2012).

Otro tipo de red unidireccional multicapa conocido son las GRN o *Generalized Regression Network* (Redes de Regresión Generalizadas), las cuales se utilizan para realizar aproximaciones de predicciones y funciones numéricas. Su diferencia con las MLP radica principalmente en que las GRN cuentan con dos capas de procesamiento definidas: capa de patrón y capa de suma. La primera contiene una neurona por cada caso de entrenamiento (Bishop, C.M. (1995); Masters, T. (1995).), que calcula su distancia con el caso presentando utilizando funciones de suavización. Los valores que calcula la capa patrón se transfieren a los nodos de la capa de suma. Estos nodos suman los valores de entrada y activan la función de salida para generar la predicción.

Las ventajas que ofrecen las GRN son el realizar un proceso de entrenamiento más rápido y el no requerir la especificación de su topología (número de capas ocultas y cantidad de nodos por capa). Sin embargo, las GRN solo trabajan con salidas numéricas (Bazán, 2012).

5.2. FUNCIÓN DE ACTIVACIÓN

Figura 3. Principales tipos de funciones de activación.



Fuente: Adaptado de Flórez y Fernández (2008) y Matich (2001).

Se utiliza para convertir los valores de entrada de cada neurona en un valor de salida Flórez & Fernández (2008); Lahoz-Beltrá, (2004). Para esto, cada neurona de la(s) capa(s) de procesamiento calcula una suma ponderada de sus valores de entrada:

$$Net_j = x_0 * w_0 + x_1 * w_1 + \dots + x_n * w_n + Bias_j;$$

Donde:

$f(\Sigma)$ o Net_j → Función de entrada junto asociado en la neurona j

$x_1, \dots, x_n$ → Valores de entrada de la neurona j

$w_1, \dots, w_n$ → Valores de los pesos sinápticos de la neurona j

θ_j o $Bias_j$ → Valor propio de tendencia de la neurona j

Al resultado obtenido se aplica luego la función de activación para generar el valor de salida de la neurona. En la figura 3 se presentan las funciones de activación más utilizadas en las RNA.

5.3. APRENDIZAJE

Las redes neuronales en la fase de aprendizaje tienen varias etapas hasta llegar al resultado final para la cual son construidas: entrenamiento, ejecución y prueba.

5.3.1. Fase de entrenamiento

El entrenamiento de las redes neuronales se puede dar a través del tipo de aprendizaje de que estas dependan. Gómez et al (1994) dividen los tipos de aprendizaje de las RNA en Aprendizaje Supervisado y No supervisado:

El *aprendizaje supervisado* presenta dos vectores (entrada y salida deseada). La salida computada por la red se compara con una “salida deseada” y los pesos de la red se modifican en el sentido de reducir el error cometido. Se repite esta operación iterativamente hasta que la diferencia entre la salida computada y la deseada sea aceptablemente pequeña. Con “n” parejas de este tipo se forma un Conjunto de Entrenamiento.

El aprendizaje supervisado se divide a su vez en dos subcategorías:

- *Aprendizaje Estructural*, que se refiere a la búsqueda de la mejor conexión o afinidad posible entrada/salida para cada pareja de patrones individuales. En este tipo de aprendizaje no existe una dependencia entre las entradas y las respuestas previas.
- *Aprendizaje Temporal*, que hace referencia a la captura de una serie de patrones necesarios para conseguir algún resultado final. La respuesta de la red depende de las entradas y respuestas previas.

El *aprendizaje no supervisado* solamente utiliza información local durante todo el proceso de aprendizaje. Es el modelo más cercano al sistema biológico, no se utiliza el vector salida esperada y sólo hay vectores de entrada en el conjunto de entrenamiento. El algoritmo interno modifica los pesos de tal forma que a entradas muy parecidas, la red compute la misma salida. Las salidas se asocian a las entradas de acuerdo con el proceso de entrenamiento. El proceso abstrae propiedades colectivas subyacentes del conjunto de entrenamiento y las agrupa por clases de similitudes.

Tabla 3. Características de los algoritmos de entrenamiento más conocidos.

Algoritmo de entrenamiento	Tiempo de entrenamiento	Supervisado / No Supervisado	Lineal / No Lineal	Estructural / Temporal	Capacidad de Almacenamiento
Hebbiano	Rápido	Supervisado	Lineal	Estructural	Pobre
Competitivo	Lento	No supervisado	Lineal	Estructural	Buena
Min-Max	Rápido	No supervisado	No lineal	Estructural	Buena
Corrección Error Dos Niveles	Lento	Supervisado	Lineal	Ambos	Buena
Corrección Error Multinivel	Muy lento	Supervisado	No lineal	Ambos	Muy buena
Reforzamiento	Súper lento	Supervisado	No lineal	Ambos	Buena
Estocástico	Súper lento	Supervisado	No lineal	Estructural	Buena

Fuente: Adaptado de Gómez, et al (1994).

En la Tabla 3 se presenta un resumen con las características de algunos de los tipos de algoritmos de entrenamiento más conocidos.

5.3.2. Fase de ejecución y prueba

Luego de la fase de aprendizaje, la RNA aplica lo desarrollado en la fase de

ejecución y prueba. En esta parte, la red prueba la eficacia que hay respecto a lo *aprendido* en la fase de entrenamiento. Se mide la cantidad de veces que el pronóstico acertó respecto al nivel de tolerancia que el modelo ofrezca.

5.3.3. Topología de las redes neuronales

La topología hace referencia a la organización y disposición de las neuronas en la red, formando capas de neuronas más o menos alejadas de la entrada y salida de dicha red. En este sentido, 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.

5.4. CASO DE ESTUDIO

El objeto de estudio de esta investigación está asociado a la demanda de diferentes productos de botiquín que son susceptibles a promociones de diferente clase y que a su vez son afectados por diferentes factores.

Los productos de botiquín son ítems que presentan un ciclo de vida relativamente extenso (Bayer, por ejemplo, ha analizado aspirinas luego de 4 años de su producción y éstas aún continúan teniendo el 100% de potencia (Debesa et al., 2004)), debido a esto, no es raro el hecho de que hayan promociones que se mantengan por más de un semestre en el mercado.

A partir de una base de datos suministrada por una empresa farmacéutica, en la cual se recopila la demanda obtenida de varios productos en diferentes puntos de ventas, a los que luego se le asociaron diferentes tipos de promociones, entre otros factores, se obtiene la información necesaria para la presente investigación.

Los productos cuentan con dos series de tiempo (regular y oferta¹). En la serie regular se presenta la demanda del producto en su estado normal de comportamiento; la serie oferta presenta el comportamiento de la demanda

¹ Cabe anotar que la palabra *oferta* en el proyecto hace referencia a la siguiente definición por parte de la empresa farmacéutica que proveyó los datos: “Oferta se refiere a lo que se ofrece para la promoción” y no a la definición Económica que presenta la RAE: “Conjunto de bienes o mercancías que se presentan en el mercado con un precio concreto y en un momento determinado” (<http://buscon.rae.es/drae/srv/search?id=KrH7WQTG7DXX2jwGyzmB>)

únicamente cuando existe la promoción y se toma como una referencia independiente del producto regular.

Durante el lapso suministrado de datos para la investigación se encontraron cuatro familias de promociones diferentes con las cuales se pretende analizar el impacto que éstas y los diferentes factores tienen sobre la decisión de compra de los consumidores. Es precisamente este impacto o influencia lo que llega a demostrar, en cierta forma, que la demanda de los productos terminados en realidad depende de factores o fuerzas de mercado, tal como se mencionó en el capítulo 4.

El modelo que se propone se emplea tanto para analizar la influencia que tienen los factores que influyen en la demanda, como para pronosticar y tomar decisiones acerca de qué tanto se debe producir o qué factores deben tomarse en cuenta al momento de realizar una promoción para así tomar decisiones más acertadas al momento de realizarlas: qué tipo de promoción realizar dependiendo del producto, el punto de venta, la época del año y de la cantidad esperada de ventas que se pretenda.

Ahora bien, a partir de los factores definidos en la siguiente sección, y teniendo en cuenta los conceptos teóricos explicados hasta este punto, se planteó un modelo de RNA para pronosticar la demanda de un producto de botiquín, el cual se ve afectado por campañas promocionales (ofertas).

5.5. SELECCIÓN DE FACTORES DE ENTRADA A LAS RNA.

A partir de datos recolectados se han propuesto algunos factores de demanda, y, a partir del análisis gráfico, se determina a priori, según un juicio de expertos, su impacto dentro de las promociones (sin dar un valor específico para el peso de cada uno en la decisión de compra del consumidor). Para todos los casos, con el objetivo de hacer notar la diferencia que existe entre el producto sin efectos de promoción (*regular*) y con la promoción (*oferta*), se ha decidido presentar las series de datos de forma independiente y agregadas, además que esto permite evaluar la influencia de la promoción de manera aislada al comportamiento de compra habitual por el producto.

Al presentar el modelo, el software en la fase de entrenamiento identificará el impacto (peso sináptico) que el mismo identifique para cada uno de los factores seleccionados.


Factor 1: Tipo de promoción

Oferta real

Un factor que afecta al comportamiento de la demanda es el tipo de promoción que se presente para determinado producto, es decir, qué se ofrece además del producto ofertado para capturar la atención del consumidor y convencerlo de comprar el producto.

A continuación se presentan dos escenarios ocurridos en distintos períodos de tiempo para un mismo producto en un mismo punto de venta con diferentes tipos de promociones. Estas son **Gratis otro producto** y luego el mismo producto por un valor menor al habitual, es decir, **Ahorre \$**.

Gráfica 1. Comparación de demanda regular y oferta respecto al tipo de promoción



Fuente: Autores

En la gráfica 1.a. al momento de ocurrencia de la promoción, la demanda del producto regular baja y la promoción como tal sube. Este tipo de promoción queda en duda acerca de qué tan exitosa pudo haber sido debido al cambio de la demanda en el lapso en que duró. En el caso de “Ahorre \$” (figura 1.b.) ocurren dos promociones, una al inicio y otra al final de la serie. Mientras que la primera impulsa la demanda del producto regular, la segunda parece disminuir la demanda mientras dura, aunque, de nuevo, impulsa la demanda regular del producto. Concluyendo este caso, se puede decir que el tipo de la promoción

afecta al comportamiento y la efectividad de la misma para un mismo punto de venta en dos momentos distintos.

En el anexo A se puede observar una tabla con los datos utilizados para el tipo de promoción Producto gratis y en el Anexo B, para Ahorre \$. Se propone este factor para analizar separadamente el tipo de oferta específico que se utiliza para cada promoción. Los tipos de oferta que se presentan en los productos utilizados para el proyecto de investigación y la familia de promociones que se incluye en cada una de ellas se pueden apreciar en la tabla 4.

Tabla 4. Tipos de promoción y Ofertas

TIPO DE PROMOCIÓN	OFERTA REAL
AHORRE \$	AH\$800
AHORRE \$	ESPECIAL \$
AHORRE \$	AH \$700
AHORRE \$	AHORRE \$1000
AHORRE \$	AHORRE \$1200
AHORRE %	AHOR 25%
AHORRE %	AH 15%
AHORRE %	AH 20%
AHORRE %	AHORRE 1000 B.I
AHORRE %	AHORRE 25%
GRATIS OTRO PRODUCTO	GT.LLAVERO
GRATIS OTRO PRODUCTO	8 GTS 2 SBS NIÑO
GRATIS OTRO PRODUCTO	GTS CREMATARRO
GRATIS OTRO PRODUCTO	GTS CHICOS 90GRFCO PLAST 330GR
GRATIS OTRO PRODUCTO	ISODINE ESPUMA GRATIS CURITAS
Pague M Lleve N	PAGUE 1 LLEVE 2
Pague M Lleve N	8 GTS 2
Pague M Lleve N	X 8 GTS 3 SOB
Pague M Lleve N	2X1
Pague M Lleve N	2X3
Pague M Lleve N	2X3
Pague M Lleve N	PAGUE 2 LLEVE 3
PAGUE M LLEVE N	2X1
PAGUE M LLEVE N	PAGUE 100 LLEVE 130
PAGUE M LLEVE N	PAGUE 2 LLEVE 3
PAGUE M LLEVE N	2X1
PAGUE M LLEVE N	PAGUE 5 LLEVE 6
PAGUE M LLEVE N	24 GTS 10

Fuente: Autores

Tipo de promoción general

Se presenta la promoción como una generalización del tipo de oferta real mencionada anteriormente. Esto para ubicar un tipo de promoción y analizar su efecto en una familia de promociones. Las familias (tipos de promoción) y la oferta real para cada tipo se presentan en la tabla 4.

Factor 2: Temporada (Mes)

Se toma este factor para analizar el impacto que tiene una promoción en el comportamiento dependiendo del momento del año en que ésta se realice. Los meses en que aparecen las ofertas son independientes entre las promociones. En la tabla 5 se presenta información de la cantidad de veces en que ha habido una promoción en un mes en especial (Cuenta de MES), su frecuencia (Frecuencia de MES) y las unidades de producto demandadas para lo ofertado por mes (Suma de OFERTA).

Tabla 5. Cantidad de promociones por mes y frecuencia de ocurrencia


Etiquetas de fila	Cuenta de MES	Frecuencia de MES	Suma de OFERTA
Enero	17	5,56%	2634
Febrero	22	7,19%	2754
Marzo	23	7,52%	4972
Abril	23	7,52%	4394
Mayo	18	5,88%	3043
Junio	24	7,84%	4292
Julio	29	9,48%	6084
Agosto	30	9,80%	4551
Septiembre	31	10,13%	4448
Octubre	30	9,80%	3117
Noviembre	31	10,13%	2956
Diciembre	28	9,15%	3552
Total general	306	100,00%	46797

Fuente: Autores

En la gráfica 2 se presenta el comportamiento de la demanda para el Producto A y Producto A + PROM, es decir, con demanda regular y con oferta respectivamente, además se muestra la suma de las dos demandas anteriores.

Del análisis del comportamiento de las demandas, se puede apreciar estacionalidad cada 12 periodos, periodos en los cuales su demanda se incrementa aproximadamente en un 150%. Esto demuestra que el factor temporada juega un papel importante en la demanda del producto.

Gráfica 2. Comparación de demanda regular y promoción respecto a la época del año.




Fuente: Autores

En el anexo C se puede observar la tabla con los datos utilizados para generar la anterior gráfica.


Factor 3: Punto de Venta.

Gráfica 3. Comparación de demandas en Punto de venta

a) Punto de Venta 1



b) Punto de Venta 2.



Fuente: Autores

En el anexo D se puede observar la tabla con los datos utilizados para la demanda en el Punto de venta 1 y en el Anexo B, para el punto de venta 2. Dependiendo del lugar en que una promoción se realice, tendrá un impacto diferente. Esto, siguiendo los parámetros establecidos por la mezcla de mercado (Kotler & Armstrong, 2012). En el análisis previo del punto de venta, en el cual se ofrece el mismo producto, el mismo tipo de promoción (gratis otro producto),

iniciando en el mismo momento pero en diferentes puntos de venta (punto de venta 7 y punto de venta 2). En la gráfica 3 (a y b) se presenta una comparación de un mismo producto.

De acuerdo al análisis gráfico, la demanda del producto en general, varía más en el punto de venta 2 que en el punto de venta 1. De la misma forma, la oferta generó un impacto mayor y se sostuvo por más tiempo en el punto de venta 2 que en el punto de venta 1. Además, las unidades de venta del producto en el punto de venta 1 son alrededor del 7% de lo que se demanda en el punto de venta 2.

Factor 4: Duración de la promoción

Se propone la cantidad de meses que dura la promoción como factor a considerar, lo cual se supone se establece al inicio de la misma a menos que se haya definido que iba a ser una promoción de tipo “hasta agotar existencias”.

Factor 5: Período de duración

Tabla 6. Período de duración de promociones y mes en que inician

	PERÍODO DE DURACIÓN (meses)						
MES	2	3	4	5	6	7	Total
Enero			1				1
Febrero		1	1	1	2	2	7
Marzo				3		1	4
Abril	1					1	2
Junio		1	3	5	1	2	12
Julio			1	1	2	3	7
Agosto		1		4	1		6
Septiembre		1	2	1		1	5
Octubre		1		1		1	3
Noviembre			2	1	2	4	9
Total general	1	5	10	17	8	15	56

Fuente: Autores

Este factor se toma en cuenta para tomar en cuenta el momento en que se inicia una promoción, el impacto que va teniendo a medida en que la promoción avanza o termina y el tiempo que dura cada una. En la Tabla 6 se presentan los meses de inicio y la duración que han tenido los diferentes productos que fueron

tomados en cuenta para el estudio.

Según lo presentado en esta sección, se han definido los siguientes factores que afectan al comportamiento de la demanda de los diferentes productos y que alimentarán al modelo basado en redes neuronales:

- Tipo de promoción
- Temporada (Mes)
- Punto de venta
- Duración de la promoción
- Período de duración

Aunque el tipo de producto puede llegar a afectar en gran medida el comportamiento de la demanda en este tipo de ítems, éste no se toma en consideración en principio, debido a la cantidad de datos que se tiene de cada uno de ellos para compararlos. En la tabla 8, en la cual se presentan codificados los 16 tipos de productos que se utilizarán en el modelo, se observa que el máximo de series que se llega a presentar de un producto es de 6 (316 datos históricos). Se plantea como un trabajo futuro de investigación.

El modelo arroja el peso que tiene cada uno de los factores al momento del entrenamiento. De este modo se sabrá el efecto que cada uno de ellos tiene al momento de realizar un tipo de promoción, para iniciar en cierto mes, en un punto de venta específico, durante un tiempo esperado de ocurrencia.

6. MODELO DE PRONÓSTICOS BASADO EN REDES NEURONALES ARTIFICIALES

A continuación se presenta el desarrollo del modelo de pronósticos basado en redes neuronales para un producto de botiquín susceptible a promociones. Primero se presentan definiciones acerca del software utilizado, a continuación se describen los tipos de red que se utilizan, luego se explica en qué consisten el entrenamiento y prueba de los datos y finalmente se hace una predicción con los resultados de la fase de entrenamiento y prueba.

6.1. DEFINICIONES

Para continuar con la descripción del funcionamiento del modelo, se debe describir algunos términos usados en las siguientes secciones.

Caso: La definición hace referencia a un registro o evento en cierto periodo de tiempo, este tiene asociado una variable dependiente y una o más variables independientes, es decir contiene los factores que afectan el comportamiento de la variable dependiente.

Serie: Una serie representa los 36 meses o periodos de demanda regular u oferta. Dentro del conjunto de datos existen al menos una serie para un tipo de producto, al igual que al menos una oferta para cada serie.

Tipos de Variables: El Software emplea las siguientes opciones:

- *Etiqueta:* Una variable cuyos posibles valores son “entrenar”, “probar” o “predecir”. Este tipo de variable se usa para identificar casos de un conjunto de datos que se usarán para entrenamiento, prueba o predicción.
- *Categoría dependiente:* Variable dependiente o de predicción, cuyos valores posibles se toman de un conjunto de posibles categorías; por ejemplo Sí o No, o Rojo o Azul.
- *Categoría independiente:* Variable independiente cuyos valores posibles se toman del conjunto de posibles categorías; por ejemplo Sí o No, o Rojo o Azul.

- Numérica dependiente: Variable dependiente o de predicción, cuyos posibles valores son numéricos.
- Numérica independiente: Variable independiente cuyos posibles valores son numéricos.
- Sin usar: Variable de un conjunto de datos que no se usará en la red neuronal.

Estos tipos de variables se emplean en el modelo RNA, excepto el tipo de variable etiqueta; en la sección 6.3 se explica por qué no se usó este tipo de variable. En las siguientes secciones se describe el uso de estas variables para las configuraciones de red empleadas con el fin de determinar la mejor red.

Tabla 7. Principales características del software.

Tipo de Red	GRN	MLP
Tipos de variables	Numéricas y cadenas	Numéricas y cadenas
Configuración de la red	• Selección automática de la mejor arquitectura y topología. • Selección del porcentaje de casos utilizados para los procesos de entrenamiento y pruebas. • Selección manual de los Casos que son utilizados para los procesos de entrenamiento y pruebas. • Selección automática o manual de la función de activación y del algoritmo de entrenamiento, según el tipo de la variable de salida.	• Selección automática de la mejor arquitectura y topología. • Selección del porcentaje de casos utilizados para los procesos de entrenamiento y pruebas. • Selección manual de los casos que son utilizados para los procesos de entrenamiento y pruebas. • Selección automática o manual de la función de activación y del algoritmo de entrenamiento, según el tipo de la variable de salida. • Selección manual del número de nodos por cada capa.
Condiciones de parada en el entrenamiento	• Configuración del tiempo máximo de entrenamiento. • Número máximo de ensayos en el proceso de entrenamiento. • Porcentaje de cambio del error en el entrenamiento.	• Configuración del tiempo máximo de entrenamiento. • Número máximo de ensayos en el proceso de entrenamiento. • Porcentaje de cambio del error en el entrenamiento.
Reportes	• Progreso del entrenamiento de la red y la reducción de los errores generados. • Valores de los pesos sinápticos. • Impacto de las variables independientes. • Errores de los procesos de entrenamiento y pruebas (MAD, ECM y MAPE).	• Progreso del entrenamiento de la red y la reducción de los errores generados. • Valores de los pesos sinápticos. • Impacto de las variables independientes. • Errores de los procesos de entrenamiento y pruebas (MAD, ECM y MAPE).

	• Diagrama de dispersión. • Histograma de los residuales	• Diagrama de dispersión. • Histograma de los residuales
--	---	---

Fuente: Autores

6.2. DESCRIPCIÓN DE LA RED NEURONAL UTILIZADA

Para la simulación del modelo RNA se utilizó un software comercial, cuyas principales características se presentan en la tabla 7. Se identifican estas características para mostrar las diferencias que puede haber entre uno y otro tipo de red (GRN y MLP).

La principal diferencia que se presenta en las características de las RNA se da precisamente en la configuración, en la cual las de tipo MLP presentan la posibilidad de seleccionar manualmente tanto el número de capas como el número de nodos por capa, contrario a las de tipo GRN, en las que sólo se ofrece una selección automática.

6.3. ENTRENAMIENTO Y PRUEBA

El Software desarrolla y utiliza las redes neuronales para el entrenamiento y prueba en 3 pasos: Primero se capturan los datos que se van a utilizar para el desarrollo de la simulación, luego se realiza el proceso de entrenamiento y por último se hace una prueba para evaluar el resultado del entrenamiento.

6.3.1. Captura de datos

Luego de haber identificado los factores que afectan el comportamiento de la variable dependiente (lo cual se describió en la sección 6.1), se inicia con el proceso de captura de datos. En este proceso se asigna a cada factor el tipo de variable a la que pertenece. Para esto, es necesario codificar y clasificar cada uno de los datos que se van a incluir en el desarrollo del entrenamiento y prueba del modelo.

Los datos se ingresan al software como una matriz, la cual va ordenada con cada una de las variables que utiliza como factores de entrada a la red. A continuación se presenta cómo se codificaron y clasificaron los factores que se utilizan en el modelo.

6.3.1.1. Codificación de los productos

Es necesario codificar y/o clasificar los datos para poder ingresar los datos al software. Debido a esto, en la tabla 8 se presentan los productos asignándole un código (letra) a cada uno. Se identificó la frecuencia en que se implementan las promociones para ese producto en todos los puntos de venta registrados en la base de datos.

Tabla 8. Codificación de los productos y número de veces que fue implementada una promoción.

Código del Producto	Frecuencia de Casos	Frecuencia de series (36 meses/serie)
A	144	4
B	36	1
C	108	3
D	180	5
E	216	6
F	216	6
G	180	5
H	72	2
I	36	1
J	72	2
K	108	3
L	72	2
M	180	5
N	144	4
O	144	4
P	36	1

Fuente: Autores

Para ver de una forma más clara la codificación presentada, se puede tomar como ejemplo la serie de datos presentada en la Gráfica 2 de la sección 5.5: (*Comparación de demanda regular y promoción respecto a la época del año*), la cual pertenece al tipo de producto F, y cuyos valores pueden verse en el ANEXO C.

La frecuencia de las series se tomó en cuenta para realizar los modelos de pronósticos y analizar la incidencia de los datos históricos en los mismos. La discusión acerca de esta característica se realizará en la sección 6.7.

6.3.1.2. Codificación de los puntos de venta

De la misma manera que con los productos, se realizó una codificación con los puntos de venta. Para este factor se utiliza una configuración alfanumérica: una letra y un número. La letra identifica la zona en que se encuentra el punto de

venta y el número identifica a la cadena comercializadora del producto. En la tabla 9 se presenta la codificación de la zona geográfica:

Tabla 9. Código de zona geográfica

ZONA	CÓDIGO ZONA
Antioquia	A
Atlántico	B
Cundinamarca	C
Centro Pacífico	D
Oriente	E

Fuente: Autores

Luego, para dar una codificación general a los puntos de venta, a la zona geográfica se agregó el código de los puntos de venta para, de esta forma, obtener el código completo para el factor Punto de venta. En la tabla 10 se presenta dicha codificación:

Tabla 10. Codificación del Punto de Venta y número de veces que fue implementada la promoción.

Código	Frecuencia de Casos	Frecuencia de series (36 meses/serie)
A2	36	1
A5	108	3
A9	36	1
B5	108	3
B7	180	5
B8	72	2
B9	144	4
C1	72	2
C2	180	5
C3	72	2
C5	36	1
C7	36	1
C8	36	1
C9	144	4
D2	72	2
D4	252	7
D6	144	4
D7	72	2
D9	36	1
E2	36	1
E5	36	1

E9	36	1
----	----	---

Fuente: Autores

En la serie de datos presentada en la Gráfica 3 de la sección 5.5: (*Comparación de demandas en a) Punto de Venta 1 y b) Punto de Venta 2.*), pueden observarse dos series de datos diferentes, las cuales pertenecen, cada una, a un punto de venta diferente. La serie del Punto de venta 1 se encuentra en la Región Centro Pacífico (Código D) y pertenece a la cadena de distribución 7, mientras que el Punto de venta 2, se encuentra en la región Cundinamarca (Código C) y pertenece a la cadena de distribución 2. Los valores de cada una de las series de datos se pueden encontrar en el Anexo D y Anexo E, respectivamente.

6.3.1.3. Clasificación de los tipos de promociones

Como se mencionó en la sección 5 y dado que se registraron diferentes tipos de promociones, éstas se clasificaron a partir de características similares, por ejemplo, la promoción Ahorre \$800 y la promoción Ahorre \$700 se clasificó en un tipo de promoción general Ahorre \$. En la tabla 11 se muestran las familias de los tipos de promociones utilizadas para alimentar el modelo RNA.

Tabla 11. *Tipos de promociones*

Tipo de Promoción
Ahorre \$
Ahorre %
Pague M Lleve N
Gratis otro Producto

Fuente: Autores

6.3.2. Entrenamiento

El propósito de la red es generar valores de salida que sean aproximadamente correctos para una serie de valores de entrada, es decir, minimización del error entre el valor de entrada y el valor de salida. Con esto el proceso de entrenamiento básicamente genera una red neuronal entrenada a partir de un conjunto de datos compuesto de casos con valores de salida conocidos. Estos frecuentemente son datos históricos de los cuales se conocen los valores de salida, es decir, una variable dependiente.

En el modelo se presentan dos variables dependientes, OFERTA y DEMANDA REGULAR, cada una de estas se manejó dentro de la simulación del modelo por separado y se explica más detalladamente en la sección 6.4. Existe un porcentaje del conjunto de datos que es utilizado para entrenamiento de la red, este porcentaje se puede configurar, lo que permite encontrar el óptimo porcentaje en conjunto de otras combinaciones de variables, permitiendo obtener la mejor configuración de red.

Si la variable *etiqueta* se asigna directamente sobre alguno de los conjuntos de datos, esta variable quedará permanentemente con ese tipo de etiqueta (entrenar, probar, predecir), lo que restringe el tipo de valor que puede llegar a tomar esa variable.

Si no se asigna la variable *etiqueta* a algún conjunto de datos, el modelo escoge aleatoriamente bajo un criterio interno del software las variables que utiliza.

Dentro de los procesos de entrenamiento no se asignó la variable tipo *etiqueta* a ningún dato, puesto que se buscaba entrenar el modelo bajo diferentes configuraciones de red para identificar la mejor configuración.

6.3.3. Prueba

En este proceso se evalúa la red neuronal con el objetivo de ver cómo realiza la predicción de los valores de salida conocidos. Los datos usados para las pruebas son normalmente un subconjunto de los datos históricos, representando un porcentaje menor en comparación al proceso de entrenamiento, este subconjunto no se utiliza para el entrenamiento de la red.

En la siguiente subsección se presentan los resultados del entrenamiento y prueba para los dos tipos de redes utilizadas para predecir la demanda.

6.3.4. Experimentos de entrenamiento y prueba

El entrenamiento y las pruebas son un proceso que consume gran cantidad de tiempo, dado que se deben realizar varias veces con diferentes configuraciones para generar una red neuronal que obtenga los resultados esperados (mínimos valores de los indicadores de error) y con esto pueda generar una buena

predicción. A partir de esto se desarrollaron deferentes configuraciones de red neuronal.

Después de definir el conjunto de datos que contiene los casos con valores históricos conocidos, se puede entrenar la red neuronal usando esos datos. El Software permite alternar entre distintas configuraciones de red neuronal. Los elementos que pueden generar las posibles combinaciones son los siguientes: Tipología de la Red Neuronal utilizada (GRN o MLP), número de nodos (para la red tipo MLP), cantidad de datos para entrenamiento, cantidad de datos para prueba, porcentaje de error, tiempo de entrenamiento y número de iteraciones. Los indicadores evaluados para determinar la mejor red fueron el MAPE, ECM y la MAD

Entrenamiento y prueba para la Oferta

En la tabla 12 se describen las configuraciones de redes usadas en el proceso de entrenamiento y prueba, y se presentan los indicadores que dieron como resultado cada una de ellas.

Tabla 12. Configuraciones y resultados de redes neuronales.

Elementos de Configuración de la Red	Configuración 1	Configuración 2	Configuración 3	Configuración 4
Red Neuronal utilizada	GRN	MLP	Buscar mejor red	MLP
Número de nodos en la 1ra capa	Automático	3	Automático	2
Número de nodos en la 2da capa	Automático	2	Automático	2
Cantidad de datos para entrenamiento	1555	1555	1555	1555
Cantidad de datos para prueba	389	389	389	389
Cantidad total de datos	1944	1944	1944	1944
Porcentaje de error	1%	1%	1%	1%
Tiempo de entrenamiento (minutos)	1	120	600	120
INDICADORES				
MAD	2,48	48,2	2,54	2,54
ECM	7,77	93,73	8,03	8,03
MAPE	2,62%	59,66%	3,93%	57,64%


Fuente: Autores

Los resultados obtenidos a partir de las distintas configuraciones muestran que la red GRN es la mejor. Los indicadores muestran una gran diferencia entre la red MLP y la red GRN. Además, el entrenamiento arrojó los impactos o pesos sinápticos que tiene cada factor o variable independiente. En la gráfica 4 se muestran dos tipos de impacto, cada uno dependiendo del tipo de RNA (GRN y

MLP).

Para la red tipo MLP el factor con mayor peso es el Tipo de Promoción con valor de 27%, mientras que para la red GRN su valor es de 11%. Para el caso de estudio los resultados muestran que el factor Tipo de Producto es el que tiene mayor peso en la decisión de compra del consumidor. La red GRN es la que presentó un error mínimo respecto de la red MLP y para ella el factor de mayor peso es el Tipo de Producto con un valor de 45,9%.

Gráfica 4. Impactos asociados a los factores en el proceso de entrenamiento y prueba de la Oferta.



Fuente: Autores

Entrenamiento y prueba para la demanda regular

En la tabla 13 se describen las configuraciones de redes usadas en el proceso de entrenamiento y prueba para la predicción de la demanda regular, y se

presentan los indicadores que dieron como resultado cada una de ellas.

Tabla 13. Configuraciones y resultados de redes neuronales.


Elementos de Configuración de la Red	Configuración 1	Configuración 2	Configuración 3	Configuración 4
Red Neuronal utilizada	GRN	MLP	Buscar mejor red	MLP
Número de nodos en la 1ra capa	Automático	3	Automático	2
Número de nodos en la 2da capa	Automático	2	Automático	2
Cantidad de datos para entrenamiento	1555	1555	1555	1555
Cantidad de datos para prueba	389	389	389	389
Cantidad total de datos	1944	1944	1944	1944
Porcentaje de error	1%	1%	1%	1%
Tiempo de entrenamiento (minutos)	1	120	600	120
INDICADORES				
MAD	4,89	176,16	3,55	86,44
ECM	13,63	361,9	11,22	176,23
MAPE	10,54%	69,49%	6,35%	65,89%

Fuente: Autores

Al igual que para el entrenamiento de la etapa 1 los resultados muestran que la red GRN es la mejor, esto dado por los resultados de la configuración 1 (red GRN) y la configuración 3, esta última arrojó como resultado de búsqueda de mejor red, la red GRN, obteniendo estas dos configuraciones los mejores valores en los indicadores evaluados. En la gráfica 5 se muestran los resultados obtenidos para los impactos o pesos (sinápticos) que tiene cada factor o variable independiente.

Los resultados del entrenamiento y prueba de la etapa 2 muestran que la red GRN es la mejor, y el factor con mayor peso para esta red es Tipo de Producto con un valor de 37,6%, mientras que para la red el factor con mayor peso es los valores de la demanda de la Oferta. Para la red GRN los factores con menor incidencia en la decisión de compra del consumidor según los resultados son el Punto de venta y los valores de demanda de la oferta, 4,2% y 3,4% respectivamente.

Gráfica 5. Impactos asociados a los factores en el proceso de entrenamiento y prueba de la demanda regular.



Fuente: Autores

6.4. PREDICCIÓN PARA LA OFERTA Y LA DEMANDA REGULAR

En este proceso se usó la red neuronal entrenada y para predecir valores de salida desconocidos. Estos son sencillamente los valores de la variable dependiente que se configuró en la captura de datos.

Para pronosticar tanto la demanda regular y la oferta es necesario hacerlo en dos etapas, puesto que el software solo permite incluir una variable dependiente, es decir, la variable que se desea pronosticar. A continuación se detalla cada etapa:

6.4.1. Etapa 1

Dado que la demanda regular se ve afectada por la promoción, primero se pronostica la OFERTA, y luego la DEMANDA REGULAR con los datos generados. Al modelo RNA se ingresaron seis factores y la variable dependiente

OFERTA, sin incluir la DEMANDA REGULAR, puesto que esta última se usa para la etapa 2. En la tabla 14 se presentan tanto los factores (variables) que incluye el modelo RNA de la etapa 1, como la forma en que se incluyeron en el software:

Tabla 14. Factores (variables) para el proceso de predicción de la etapa 1.

OFERTA	TIPO DE PROMOCIÓN	TEMPORADA (MES)	PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Variable Numérica dependiente	Variable Categoría independiente	Variable Categoría independiente	Variable categoría independiente	Variable categoría independiente	Variable categoría independiente	Variable categoría independiente

Fuente: Autores

6.4.2. Etapa 2

En esta etapa se incluye la DEMANDA REGULAR, siendo esta la variable de predicción o variable dependiente, mientras que la variable OFERTA o PROMOCIÓN se convierte en este punto en una variable independiente. En la tabla 15 se muestran los factores (variables) que se incluyen en el modelo RNA de la etapa 2 y la forma como se incluyeron en el software:

Tabla 15. Factores (variables) para el proceso de predicción de la etapa 2.

DEMANDA REGULAR	OFERTA	TIPO DE PROMOCIÓN	TEMPORADA (MES)	PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Variable Numérica dependiente	Variable Numérica independiente	Variable Categoría independiente	Variable Categoría independiente	Variable categoría independiente	Variable categoría independiente	Variable categoría independiente	Variable categoría independiente

Fuente: Autores

6.5. PREDICCIÓN

Como objeto de estudio es muy importante evaluar los datos de salida o predicciones de los pronósticos. Para ampliar este análisis se presentan varios escenarios de simulación, cada uno con un producto distinto y las series asociadas a dicho producto. A continuación se describe cada escenario. Para cada uno de los casos se pronostica la demanda de la variable OFERTA y demanda REGULAR de un producto. Para la OFERTA solamente se pronostica

sobre los periodos en los cuales se tiene programada la duración de la misma; distinto a la REGULAR, la cual se supone que sigue siendo demandada durante todos los periodos.


Escenario 1: Este escenario se caracteriza por tener una serie que hizo parte del conjunto de datos de entrenamiento de la red neuronal y se presenta una sola serie como valor de frecuencia, es decir, 36 casos (Ver tabla 8, Código del Producto: B).

Escenario 2: Se caracteriza por tener una serie que no se incluyó en el entrenamiento de la red neuronal y se presenta una serie con una oferta promocional. (Ver tabla 8, Código del Producto: B)

Escenario 3: Se caracteriza por tener factores similares incluidos en diferentes series en la fase de entrenamiento de la red neuronal, pero a diferencia de los otros dos escenarios esta tiene 6 frecuencias de series, es decir, 216 casos. (Ver tabla 8, Código del Producto: E)

Las series usadas en los escenarios tienen valores reales de demanda REGULAR y de OFERTA como información histórica, también tienen asociados los factores Punto de venta, Tipo de promoción, Temporada (Mes), Periodo de duración de la promoción y Duración de la promoción. Esta información se muestra en las tablas de conjunto de datos de cada escenario.

Figura 4. Esquema de un escenario en general de predicción.



Fuente: Autores

En la figura 4 se visualiza el esquema de un escenario en general en el cual primero se determina la demanda a pronosticar siendo la demanda con OFERTA o DEMANDA REGULAR, posteriormente la red a utilizar y finalmente el resultado de la predicción.

6.5.1. ESCENARIO 1.

Pronóstico para la demanda de la oferta a partir de una serie de datos que se incluyó en el entrenamiento de la RNA


Este escenario contiene al producto B y posee una serie de 36 meses, solo se realizó una campaña promocional, en el punto de venta D6, con el tipo de promoción “Ahorre \$” y duró 7 meses. En el anexo F se presenta la información de este escenario.

6.5.2. RESULTADOS ESCENARIO 1.


Como se mencionó en la sección 6.4, primero se pronosticó la OFERTA y posteriormente la demanda REGULAR. En el anexo G1 y anexo G2 se presenta la información de los resultados de predicción, y en las gráficas 6a y 6b y en la tabla 16, se presentan los resultados obtenidos mediante las dos tipologías de red que presentaron mejores resultados en el proceso de entrenamiento.

Gráfica 6. Resultados de pronósticos para demanda regular y oferta del escenario 1

a) Pronóstico de la oferta.



b) Pronóstico de la demanda regular.



Fuente: Autores

Tabla 16. Resultados de Indicadores del escenario 1.

	Demanda Oferta		Demanda Regular	
	GRN	MLP	GRN	MLP
MAD	0,13	46,73	53,88	39,46
ECM	0	2.184	2.903	1.557
MAPE	0,09%	48,13%	179,26%	204,21%

Fuente: Autores

Análisis de los resultados

De acuerdo a la tabla anterior, para la predicción de la OFERTA, la red GRN presenta mejores resultados respecto a los indicadores evaluados. Con esto se puede concluir que para una serie que se incluyó en procesos de entrenamiento los resultados son relativamente buenos.


6.5.3. ESCENARIO 2.

Pronóstico para la demanda de la oferta a partir de una serie de datos que no se incluyó en el entrenamiento de la RNA

Este escenario contiene al producto E y solo posee una serie de 36 meses, solo se realizó una campaña promocional, en el punto de venta C2, con el tipo de promoción “PAGUE M LLEVE N” y duró 5 meses. En el anexo H se presenta la información de este escenario.

6.5.4. RESULTADOS ESCENARIO 2.

Gráfica 7. Resultados de pronósticos para demanda regular y oferta del escenario 2.



Fuente: Autores

En el anexo I1 y I2 se presentan los datos de predicción, y en los gráficos 7a y 7b se presentan los resultados de predicción, y en la tabla 17 los resultados de los indicadores obtenidos mediante las dos tipologías de red que presentaron mejores resultados en el proceso de entrenamiento.

Tabla 17. Resultados de Indicadores del escenario 2.

	Demanda Oferta		Demanda Regular	
	GRN	MLP	GRN	MLP
MAD	322,41	162,03	458,05	526,89
ECM	103.950	26.253	209.806	277.610
MAPE	66,78%	14,86%	74,40%	87,69%

Fuente: Autores

Análisis de los resultados

Predicción de la Demanda de la Oferta

De acuerdo a lo anterior se puede decir que, para una serie de datos que no se incluyó en el proceso de entrenamiento y que los datos o casos tienen valores por fuera del rango con los que se entrenó la red, la tipología de red MLP tiene mejores resultados. Los indicadores de la red MLP son mejores a los de la red GRN. Haciendo énfasis en el indicador MAPE, para la red MLP este tiene un valor de 14,86%, mientras que para la red GRN su valor es 66,78%. Con esto se concluye que la tipología MLP es más fiable al predecir valores que están por fuera del rango de datos de entrenamiento.

Predicción de la Demanda Regular

Dado los resultados del escenario 2, se puede evidenciar que el resultado no fue el mismo como sucedió al predecir la oferta. El indicador MAPE de la red GRN tuvo un mejor resultado con un valor de 74%, mientras que la red MLP un valor de 87,69%, esto permite analizar que cuando se presentan estos escenarios realmente las redes no son del todo fiables, puesto que los rangos están por fuera de los rangos con los que se entrenó la red.

6.5.5. ESCENARIO 3.


Pronóstico para la demanda de la oferta a partir de una serie de datos con seis frecuencias que se incluyó en el entrenamiento de la RNA

Este escenario contiene al producto E y tiene 6 series de 36 meses cada una, es decir, 216 casos, se realizaron 6 campañas promocionales en distintos puntos de venta, con el tipo de “PAGUE M LLEVE N” y “GRATIS OTRO PRODUCTO”. En el anexo J se presenta la información de este escenario.

6.5.6. RESULTADOS ESCENARIO 3.

En los anexos K1 y K2, y en las gráficas 8a y 8b se presentan los resultados de predicción de la oferta y la demanda regular, y en tabla 18 se presentan los resultados obtenidos de los indicadores mediante las dos tipologías de red que presentaron mejores resultados en el proceso de entrenamiento.

Gráfica 8. Resultados de pronósticos para demanda regular y oferta del escenario 3.



Fuente: Autores

Tabla 18. Resultados de Indicadores del escenario 3.

	Demanda Oferta		Demanda Regular	
	GRN	MLP	GRN	MLP
MAD	106,85	132,31	169,51	202,82
ECM	11.417	17.506	28.732	41.137
MAPE	82,32%	107,14%	71,93%	72,91%

Fuente: Autores

Análisis de los resultados

Predicción de la Demanda de la Oferta

De acuerdo a las gráficas 7a y 7b, y la tabla 18 se puede decir que, para la predicción de una serie de datos que se incluyó en el proceso de entrenamiento y además se entrenó con 6 series de datos para el mismo producto como se expone en la descripción del escenario 3, la tipología o red GRN presenta mejores resultados frente a la MLP. Lo mismo sucede para la predicción de la oferta, aunque la diferencia se acorta respecto al indicador MAPE, esto se debe a que este indicador tiene mayor precisión cuando existe mayor variación entre el rango de datos, puesto que existe 6 series en distintos puntos de venta y rango de demanda más altos. En la sección 6.7 se discute con mayor detalle estos resultados.

6.6. PRUEBA DE PRONÓSTICOS CON MODELOS TRADICIONALES

Para probar la efectividad del modelo de pronósticos desarrollado a lo largo de la investigación, se ha decidido evaluar los indicadores de error que éste presenta respecto al error que resulta de pronosticar las mismas series con modelos de pronósticos tradicionales. A continuación se presentan dos tipos de pronósticos con Suavización Exponencial Doble (SED), la cual se utiliza para predecir la demanda cuando los datos manifiestan una tendencia en el comportamiento (positiva o negativa). Primero se realiza un pronóstico solamente tomando como base el factor Producto y el factor Punto de venta, ya que éste último es necesario cuando la toma de decisiones es descentralizada. El segundo modelo de pronósticos que se toma para evaluar es el presentado por Lee et al. (2007), en donde utiliza un sistema de pronósticos (SED) en el cual toma ciertos factores y los filtra de la demanda ocurrida en promociones pasadas para pronosticar la demanda en la siguiente promoción.

Cabe anotar que los modelos de pronósticos tradicionales que se presentan a continuación solamente se utilizaron para pronosticar la demanda en el momento en que ocurren las promociones, lo cual es el objeto de estudio de la presente investigación.

Para obtener los resultados presentados en las tablas contiguas a cada uno de los pronósticos se utilizó el software *Excel*™ y, para optimizar el valor de α , se

utiliza el complemento *Solver*. En ambos casos, el valor de α se evaluó dentro del rango [0,01; 0,3].

En el Anexo L se pueden revisar los datos que se utilizaron para llevar a cabo cada uno de los pronósticos, los datos de entrenamiento y los resultados de los indicadores de error.

6.6.1. Modelo de pronósticos tradicionales: Suavización Exponencial Doble (SED)

Para utilizar este tipo de pronóstico se toman en cuenta solamente los factores *Tipo de producto* y *Punto de venta*, puesto que se supone son cadenas de supermercados independientes. A modo de resumen, se presentan los resultados de los indicadores de error (MAD, ECM y PAME) y el valor de alfa (α) óptimo para cada uno de los escenarios (los mismos que los utilizados en la prueba de las RNA) para analizar directamente la diferencia.

Tabla 19. Indicadores de error para la SED

SED			
Indicadores	Escenario (1)	Escenario (2)	Escenario (3)
MAD	46,10	185,02	90,57
ECM	4402,27	54497,98	8692,34
PAME (%)	101	90	96
α	0,01	0,01	0,01

Fuente: Autores

En el anexo M se encuentran los datos utilizados y sus resultados al aplicar el modelo de pronósticos tradicional (SED).

En la sección 6.7 se discutirá acerca de los diferentes resultados suministrados por los diferentes modelos de pronósticos, en donde se analizará la diferencia entre ellos.

6.6.2. Método de Lee et al. (2007)

La diferencia entre los modelos de pronósticos utilizados con la SED, es que Lee et al. (2007) proponen pronosticar con datos similares, es decir, que compartan características similares y así poder generar una predicción. Luego estos datos similares se utilizan mediante un modelo de pronósticos tradicional, en este caso,

la SED. Los datos que se toman como similares para este modelo son los mismos factores de entrada que se utilizaron para las RNA.

En la tabla 20 se presentan los resultados de los indicadores de error para cada uno de los escenarios presentados anteriormente:

Tabla 20. Indicadores de error para el método de Lee et al. (2007)

Lee et al. (2007)			
	Escenario (1)	Escenario (2)	Escenario (3)
MAD	46,10	185,02	144,79
ECM	4402,27	54497,98	23282,67
PAME (%)	101	90	124
α	0,01	0,01	0,10

Fuente: Autores

En el anexo N se presentan tanto los datos utilizados como sus resultados al aplicar el método de Lee et al. (2007).

En la siguiente sección se procederá a discutir acerca de los resultados respecto a aquéllos obtenidos con las RNA y SED como método de pronósticos tradicionales.

6.7. DISCUSIÓN ACERCA DE LOS RESULTADOS

Respecto a la cantidad de tipo de promociones que se encontraron en la investigación (de los datos suministrados por la empresa farmacéutica), se debe tener en cuenta que los encargados de las promociones utilizan gran variedad de estas para hacer notar, entre los consumidores, el producto y que un solo tipo de promoción no se vuelva una costumbre, lo cual haría, en cierto modo al tener las promociones las mismas características, que el cambio en el comportamiento de la demanda se presente como una serie de tipo estacional, para lo cual ya hay métodos para predecir la demanda (Ver tabla 1).

Cuando los sistemas de pronósticos cuentan no cuentan con suficientes datos, éstos en general presentan un nivel de error alto, ya que al haber, por ejemplo, un solo tipo de promoción entre las series de entrenamiento, el comportamiento de una variable no alcanza a ser del todo estudiada, entrenada y puesta a prueba por los modelos de manera eficiente. En el caso en que se pronostica una serie

que estaba incluida en el entrenamiento, el software detecta que todas las condiciones de la misma ya se habían presentado y, debido a esto, el pronóstico que genera es prácticamente una copia del comportamiento que se obtuvo con los datos de entrenamiento.

Ahora bien, el hecho de que no hayan suficientes datos, no quiere decir que sean necesarios más años de historia para cada producto en los que probablemente haya existido una misma promoción. Esto debido al mercado y su velocidad de cambio respecto a décadas anteriores. El ritmo de cambio y la globalización han hecho que los mercados de antes no presenten en gran medida el mismo comportamiento que el que puede llegar a presentar la demanda ahora. Ejemplo de este caso es el ocurrido en el escenario 3, en el que se tenían varias características similares, pero la demanda que se iba a pronosticar fue, en realidad, significativamente mayor que la de años anteriores. En este caso una posible solución sería tener lapsos menores en las series, por ejemplo semanas en lugar de meses para la misma cantidad de años.

Tomando como referencia los datos suministrados por la empresa farmacéutica, para cualquiera de los escenarios, las RNA presentan por mucho mejores resultados que con los otros métodos. Ahora bien, a pesar de que el método de Lee et al. (2007) toman en cuenta factores o características similares para tomar valores y pronosticar, la falta de datos históricos hace como en el escenario 3, que es en donde se presenta un producto con la mayor cantidad de series posibles de las suministradas (6), obtenga no tan buenos resultados respecto al método tradicional de pronósticos con SED. Mientras que con el método tradicional de SED se utilizaron tres series (como se explicó anteriormente, se toman las series bajo el supuesto de que la toma de decisiones es descentralizada respecto a los puntos de venta), el método de Lee et al. solamente puede tomar dos series, las cuales no son suficientes para predecir el comportamiento futuro de los datos.

Ahora bien, cabe anotar que el los datos en el Método de Lee et al. antes de pronosticar se venían comportando de manera similar, pero los datos que se presentan para analizar los indicadores de error son significativamente mayores.

El modelo respondió con un nivel de la variable alfa (α) mayor que el método tradicional, pero no fue suficiente para minimizar el error entre ambos.

7. CONCLUSIONES

- A lo largo del proyecto de investigación se puede observar cómo la demanda es afectada por diferentes factores independiente de si es en estado regular o si la demanda hace parte de una promoción. Esto cambia el concepto de independencia de la demanda externa, la cual en realidad puede ser afectada por factores manipulables como lo son la mezcla de mercado (producto, precio, plaza y promoción).
- Al identificar los factores de demanda y luego al entrenar el modelo, los resultados de los pesos sinápticos presentan que el factor “Punto de venta” tiene un impacto significativo al momento de planear una promoción y en el comportamiento de compra de los consumidores en general.
- Las redes que se modelan para una situación en especial no necesariamente se pueden utilizar para otra. Aunque los datos y factores que se presenten sean los mismos, esto no quiere decir que los pesos sinápticos que vayan a tomar sean iguales.
- Al pronosticar la demanda de un producto que se ajuste a los criterios de selección que se hayan incluido en la red, se encontró que de los dos tipos de redes simuladas, el Perceptrón Multicapa (MLP) y la Red de Regresión Generalizada (GRN), la primera presenta mejores resultados cuando el rango de datos utilizados está por fuera de los datos con que se entrenó la red, mientras que la GRN se ajusta mejor al comportamiento en el caso contrario.

- Los modelos de pronósticos basados en redes neuronales artificiales, al igual que los tradicionales, necesitan de la historia para poder realizar un pronóstico. Es decir, mientras que una red neuronal no tenga más que una ocurrencia para cierto comportamiento debido a factores específicos, lo máximo que podrá hacer la red será pronosticar el comportamiento, pero no necesariamente pronosticará con exactitud (o al mismo nivel) la cantidad de unidades que se esperaría.
- La rapidez con que los mercados cambian, hace que los datos históricos, hasta cierto rango hacia atrás, pierdan validez respecto al comportamiento actual, es decir, no es lo mismo el comportamiento de compra de hace diez o más años al de hace dos años, o al actual.

BILIOGRAFÍA

- Aguirre, A., & Martínez, D. (2012). *UN MODELO PARA EL PRONÓSTICO DE DEMANDA DE PRODUCTOS ALIMENTICIOS EN UN RESTAURANTE INSTITUCIONAL*. Trabajo de Investigación de Maestría. Universidad del Valle.
- Ailawadi, K. L., & Neslin, S. A. (1998). The Effect of Promotion on Consumption : Buying More and Consuming It Faster. *Journal of Marketing Research*, XXXV(August), 390–398.
- Bazán, N. (2012). NUEVAS HERRAMIENTAS DE INVESTIGACIÓN: LAS REDES NEURONALES. *ReCAD – Revista Electrónica de Ciencias Aplicadas Al Deporte*, 5.
- Benedetti, F., Baigún, A.& Yanguas, M. L. (2011). Predicciones de series de tiempo con redes neuronales: Trading usando el índice de Merval, Technical report, Argentina, Universidad de San Andrés.
- Bishop, C.M. (1995) *Neural Networks for Pattern Recognition*: Estados Unidos: Oxford University Press, primera edición
- Bustamante, E. (2007). *El sistema nervioso desde las neuronas hasta el cerebro humano* (1st ed.). Medellín, Colombia: Universidad de Antioquia.

- Caicedo, E. F., & López, J. . (2009). *Una aproximación práctica a las redes neuronales artificiales* (1st ed.). Cali: Universidad del Valle © Copyright 2010.
- Cavlovic, B. D. (2007). La influencia de las promociones de ventas en la decisión de compra, 1–13.
- Debesa, F., Fernández, R. & Pérez J. (2004). Caducidad de los medicamentos: justificación de una duda. *Revista cubana de farmacia*, 38(3), Cuba, Ciudad de la Habana.
- Flórez, R., & Fernández, J. . (2008). *Redes Neuronales Artificiales fundamentos teóricos y aplicaciones prácticas* (1st ed.). España: NetBiblo S.L.
- Ghiassi, M., Saidane, H., & Zimbra, D. K. (2005). A dynamic artificial neural network model for forecasting time series events. *International Journal of Forecasting*, 21(2), 341–362. doi:10.1016/j.ijforecast.2004.10.008
- Gómez, F. J., Fernández, M. A., López, M. T. Díaz-Marta, M. A. (1994) Aprendizaje con Redes Neuronales Artificiales. *Revista Ensayos*, nº 9 - UCLM., páginas 169-180. Diciembre 1994. ISSN 0214-4824
- Kotler, P., & Armstrong, G. (2012). *Principles of Marketing* (p. 611). Library of Congress Cataloging-in-Publication Data.
- Lahoz-Beltrá, R. (2004). Bioinformática: Simulación, vida artificial e inteligencia artificial. España: Ediciones Díaz de Santos.
- Lee, W. Y., Goodwin, P., Fildes, R., Nikolopoulos, K., & Lawrence, M. (2007). Providing support for the use of analogies in demand forecasting tasks. *International Journal of Forecasting*, 23(3), 377–390. doi:10.1016/j.ijforecast.2007.02.006
- Masters, T. (1995). *Advanced Algorithms for Neural Networks*. Estados Unidos: Wiley, primera edición
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario.

- McCulloch, W. S., & Pitts, W. H. (2008). A LOGICAL CALCULUS OF THE IDEAS IMMAMENT IN NERVOUS ACTIVITY, 5, 115–133.
- Muñíz, R. G. (2010). *MARKETING EN EL SIGLO XXI* (3rd ed., p. 422). Madrid, España: Centro de Estudios Financieros.
- O'Donnell, T., Humphreys, P., McIvor, R., & Maguire, L. (2009). Reducing the negative effects of sales promotions in supply chains using genetic algorithms. *Expert Systems with Applications*, 36(4), 7827–7837. doi:10.1016/j.eswa.2008.11.034
- Perreault, W. D., & McCarthy, E. J. (2001). *MARKETING: UN ENFOQUE GLOBAL* (13th ed., p. 797). Ciudad de México, México: Mc Graw-Hill, Interamericana de México.
- Raju, J. S. (1995). Theoretical models of sales promotions: Contributions, limitations, and a future research agenda. *European Journal of Operational Research*, (1), 1–17. doi:10.1016/0377-2217(94)00275-H
- Ramanathan, U., & Muijldermans, L. (2010). Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK. *International Journal of Production Economics*, 128(2), 538–545. doi:10.1016/j.ijpe.2010.07.007
- Rammanathan, U. (2012). Supply chain collaboration for improved forecast accuracy of promotional sales. *International Journal of Operations and Production Management*, 32(6), 676–695.
- Rosenblatt, F. (1958) The perceptron: A probabilistic model for information storage & organization in the brain. *Psychological review*, 65, 386-408.
- Su, Y., & Geunes, J. (2012). Price promotions, operations cost, and profit in a two-stage supply chain. *Omega*, 40(6), 891–905. doi:10.1016/j.omega.2012.01.010
- Trapero, J. R., Pedregal, D. J., Fildes, R., & Kourentzes, N. (2013). Analysis of judgmental adjustments in the presence of promotions. *International*

Journal of Forecasting, 29(2), 234–243.

doi:10.1016/j.ijforecast.2012.10.002

Trusov, M., Bodapati, A. V., & Cooper, L. G. (2006). Retailer promotion planning: Improving forecast accuracy and interpretability. *Journal of Interactive Marketing*, 20(3-4), 71–81. doi:10.1002/dir.20068

Vidal Holguín, C. J. (2010). *PLANEACIÓN, OPTIMIZACIÓN Y ADMINISTRACIÓN DE CADENAS DE ABASTECIMIENTO*. (E. de I. I. y E. – U. del Valle & © Copyright 2010, Eds.) (p. 610). Santiago de Cali: Universidad del Valle © Copyright 2010.

Wei, W. W. S. (2006). Time series analysis Univariate and multivariate methods (p. Cap. 10).

ANEXOS

ANEXO A. Comparación de demanda regular y oferta respecto al tipo de promoción: Producto gratis

MES	PROMOCIÓN GRATIS OTRO PRODUCTO	REGULAR	TIPO DE PROMOCIÓN	OFERTA REAL	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	781			7	D	C2			E
Febrero	0	726			7	D	C2			E
Marzo	0	523			7	D	C2			E
Abril	0	677			7	D	C2			E
Mayo	0	655			7	D	C2			E
Junio	0	719			7	D	C2			E
Julio	0	849			7	D	C2			E
Agosto	0	853			7	D	C2			E
Septiembre	0	701			7	D	C2			E
Octubre	0	817			7	D	C2			E
Noviembre	0	813			7	D	C2			E
Diciembre	0	1171			7	D	C2			E
Enero	0	1063			7	D	C2			E
Febrero	91	623	Gratis otro producto	Gratis 2 sobres	7	D	C2	5 Meses	1	E
Marzo	499	294	Gratis otro producto	Gratis 2 sobres	7	D	C2	5 Meses	2	E
Abril	444	333	Gratis otro producto	Gratis 2 sobres	7	D	C2	5 Meses	3	E
Mayo	169	628	Gratis otro producto	Gratis 2 sobres	7	D	C2	5 Meses	4	E
Junio	24	748	Gratis otro producto	Gratis 2 sobres	7	D	C2	5 Meses	5	E
Julio	0	797			7	D	C2			E
Agosto	0	696			7	D	C2			E
Septiembre	0	464			7	D	C2			E
Octubre	0	662			7	D	C2			E
Noviembre	0	591			7	D	C2			E
Diciembre	0	512			7	D	C2			E
Enero	0	410			7	D	C2			E
Febrero	0	247			7	D	C2			E
Marzo	0	294			7	D	C2			E
Abril	0	574			7	D	C2			E
Mayo	0	796			7	D	C2			E
Junio	0	759			7	D	C2			E
Julio	0	773			7	D	C2			E
Agosto	0	980			7	D	C2			E
Septiembre	0	838			7	D	C2			E
Octubre	0	661			7	D	C2			E
Noviembre	0	137			7	D	C2			E
Diciembre	0	39			7	D	C2			E

ANEXO B. Comparación de demanda regular y oferta respecto al tipo de promoción:
Ahorre \$.

MES	OFERTA AHORRE \$	REGULAR	TIPO DE PROMOCIÓN	OFERTA REAL	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	781			2	C	C2			E
Febrero	293	726	Ahorre \$	Oferta especial	2	C	C2	8 Meses	1	E
Marzo	524	523	Ahorre \$	Oferta especial	2	C	C2	8 Meses	2	E
Abril	171	677	Ahorre \$	Oferta especial	2	C	C2	8 Meses	3	E
Mayo	330	655	Ahorre \$	Oferta especial	2	C	C2	8 Meses	4	E
Junio	164	719	Ahorre \$	Oferta especial	2	C	C2	8 Meses	5	E
Julio	16	849	Ahorre \$	Oferta especial	2	C	C2	8 Meses	6	E
Agosto	3	853	Ahorre \$	Oferta especial	2	C	C2	8 Meses	7	E
Septiembre	1	701	Ahorre \$	Oferta especial	2	C	C2	8 Meses	8	E
Octubre	0	817			2	C	C2			E
Noviembre	0	813			2	C	C2			E
Diciembre	0	1171			2	C	C2			E
Enero	0	1063			2	C	C2			E
Febrero	0	623			2	C	C2			E
Marzo	0	294			2	C	C2			E
Abril	0	333			2	C	C2			E
Mayo	0	628			2	C	C2			E
Junio	0	748			2	C	C2			E
Julio	0	797			2	C	C2			E
Agosto	0	696			2	C	C2			E
Septiembre	189	464	Ahorre \$	Oferta especial	2	C	C2	10 Meses	1	E
Octubre	82	662	Ahorre \$	Oferta especial	2	C	C2	10 Meses	2	E
Noviembre	20	591	Ahorre \$	Oferta especial	2	C	C2	10 Meses	3	E
Diciembre	427	512	Ahorre \$	Oferta especial	2	C	C2	10 Meses	4	E
Enero	532	410	Ahorre \$	Oferta especial	2	C	C2	10 Meses	5	E
Febrero	476	247	Ahorre \$	Oferta especial	2	C	C2	10 Meses	6	E
Marzo	419	294	Ahorre \$	Oferta especial	2	C	C2	10 Meses	7	E
Abril	89	574	Ahorre \$	Oferta especial	2	C	C2	10 Meses	8	E
Mayo	29	796	Ahorre \$	Oferta especial	2	C	C2	10 Meses	9	E
Junio	3	759	Ahorre \$	Oferta especial	2	C	C2	10 Meses	10	E
Julio	0	773			2	C	C2			E
Agosto	0	980			2	C	C2			E
Septiembre	9	838			2	C	C2			E
Octubre	1	661			2	C	C2			E
Noviembre	8	137			2	C	C2			E
Diciembre	2	39			2	C	C2			E

ANEXO C. Comparación de demanda regular y promoción respecto a la época del año.

MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	173	173				2	D	D2			F
Febrero	0	218	218				2	D	D2			F
Marzo	0	255	255				2	D	D2			F
Abril	75	164	239	tis otro produ	Gratis 2 sobre		2	D	D2	3 Meses	1	F
Mayo	51	222	273	tis otro produ	Gratis 2 sobre		2	D	D2	3 Meses	2	F
Junio	21	280	301	tis otro produ	Gratis 2 sobre		2	D	D2	3 Meses	3	F
Julio	0	241	241				2	D	D2			F
Agosto	0	204	204				2	D	D2			F
Septiembre	0	270	270				2	D	D2			F
Octubre	0	216	216				2	D	D2			F
Noviembre	0	526	526				2	D	D2			F
Diciembre	0	259	259				2	D	D2			F
Enero	0	182	182				2	D	D2			F
Febrero	0	181	181				2	D	D2			F
Marzo	0	273	273				2	D	D2			F
Abril	0	161	161				2	D	D2			F
Mayo	0	237	237				2	D	D2			F
Junio	0	219	219				2	D	D2			F
Julio	0	162	162				2	D	D2			F
Agosto	69	118	187	tis otro produ	Gratis 2 sobres		2	D	D2	16 Meses	1	F
Septiembre	44	141	185	tis otro produ	Gratis 2 sobres		2	D	D2	16 Meses	2	F
Octubre	5	144	149	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	3	F
Noviembre	370	333	703	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	4	F
Diciembre	175	98	273	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	5	F
Enero	110	77	187	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	6	F
Febrero	92	93	185	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	7	F
Marzo	90	108	198	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	8	F
Abril	68	121	189	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	9	F
Mayo	135	125	260	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	10	F
Junio	60	125	185	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	11	F
Julio	37	128	165	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	12	F
Agosto	13	118	131	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	13	F
Septiembre	4	90	94	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	14	F
Octubre	7	81	88	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	15	F
Noviembre	33	302	335	tis otro produ	Gratis 2 sobre		2	D	D2	16 Meses	16	F
Diciembre	0	581	581				2	D	D2			F

ANEXO D. Demanda en Punto de venta 1

MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	1308	1308				6	D	D6			D
Febrero	0	897	897				6	D	D6			D
Marzo	0	914	914				6	D	D6			D
Abril	0	259	259				6	D	D6			D
Mayo	0	260	260				6	D	D6			D
Junio	0	168	168				6	D	D6			D
Julio	0	237	237				6	D	D6			D
Agosto	0	858	858				6	D	D6			D
Septiembre	601	429	1030	tis otro produ	Gratis otro		6	D	D6	9 Meses	1	D
Octubre	866	217	1083	tis otro produ	Gratis otro		6	D	D6	9 Meses	2	D
Noviembre	886	139	1025	tis otro produ	Gratis otro		6	D	D6	9 Meses	3	D
Diciembre	1211	118	1329	tis otro produ	Gratis otro		6	D	D6	9 Meses	4	D
Enero	1222	65	1287	tis otro produ	Gratis otro		6	D	D6	9 Meses	5	D
Febrero	704	226	930	tis otro produ	Gratis otro		6	D	D6	9 Meses	6	D
Marzo	384	348	732	tis otro produ	Gratis otro		6	D	D6	9 Meses	7	D
Abril	80	362	442	tis otro produ	Gratis otro		6	D	D6	9 Meses	8	D
Mayo	7	185	192	tis otro produ	Gratis otro		6	D	D6	9 Meses	9	D
Junio	0	636	636				6	D	D6			D
Julio	0	1175	1175				6	D	D6			D
Agosto	0	1133	1133				6	D	D6			D
Septiembre	0	839	839				6	D	D6			D
Octubre	0	393	393				6	D	D6			D
Noviembre	0	350	350				6	D	D6			D
Diciembre	0	861	861				6	D	D6			D
Enero	0	793	793				6	D	D6			D
Febrero	0	736	736				6	D	D6			D
Marzo	0	504	504				6	D	D6			D
Abril	0	556	556				6	D	D6			D
Mayo	0	700	700				6	D	D6			D
Junio	0	520	520				6	D	D6			D
Julio	0	339	339				6	D	D6			D
Agosto	0	404	404				6	D	D6			D
Septiembre	0	466	466				6	D	D6			D
Octubre	0	932	932				6	D	D6			D
Noviembre	0	1159	1159				6	D	D6			D
Diciembre	0	1606	1606				6	D	D6			D

ANEXO E. Demanda en Punto de venta 2

MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	85	85				7	D	D7			F
Febrero	0	45	45				7	D	D7			F
Marzo	0	65	65				7	D	D7			F
Abril	0	85	85				7	D	D7			F
Mayo	0	86	86				7	D	D7			F
Junio	0	60	60				7	D	D7			F
Julio	0	87	87				7	D	D7			F
Agosto	0	78	78				7	D	D7			F
Septiembre	4	42	46	Ahorre %	15% of		7	D	D7	5 Meses	1	F
Octubre	10	42	52	Ahorre %	15% of		7	D	D7	5 Meses	2	F
Noviembre	30	35	65	Ahorre %	15% of		7	D	D7	5 Meses	3	F
Diciembre	29	26	55	Ahorre %	15% of		7	D	D7	5 Meses	4	F
Enero	5	53	58	Ahorre %	15% of		7	D	D7	5 Meses	5	F
Febrero	0	70	70				7	D	D7			F
Marzo	0	78	78				7	D	D7			F
Abril	0	84	84				7	D	D7			F
Mayo	0	61	61				7	D	D7			F
Junio	0	78	78				7	D	D7			F
Julio	0	65	65				7	D	D7			F
Agosto	0	60	60				7	D	D7			F
Septiembre	0	49	49				7	D	D7			F
Octubre	0	52	52				7	D	D7			F
Noviembre	0	55	55				7	D	D7			F
Diciembre	0	72	72				7	D	D7			F
Enero	0	54	54				7	D	D7			F
Febrero	0	53	53				7	D	D7			F
Marzo	0	67	67				7	D	D7			F
Abril	0	81	81				7	D	D7			F
Mayo	0	77	77				7	D	D7			F
Junio	0	71	71				7	D	D7			F
Julio	0	64	64				7	D	D7			F
Agosto	0	70	70				7	D	D7			F
Septiembre	0	61	61				7	D	D7			F
Octubre	0	59	59				7	D	D7			F
Noviembre	0	58	58				7	D	D7			F
Diciembre	0	88	88				7	D	D7			F

ANEXO F. *Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 1.*

OFERTA	REGULAR	TIPO DE PROMOCIÓN	TEMPORADA (MES)	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
76	85	AHORRE \$	Octubre	D6	7 Meses	1	B
149	59	AHORRE \$	Noviembre	D6	7 Meses	2	B
250	123	AHORRE \$	Diciembre	D6	7 Meses	3	B
74	100	AHORRE \$	Enero	D6	7 Meses	4	B
13	85	AHORRE \$	Febrero	D6	7 Meses	5	B
15	185	AHORRE \$	Marzo	D6	7 Meses	6	B
13	135	AHORRE \$	Abril	D6	7 Meses	7	B

ANEXO G. Conjunto de datos usados para predicción en el escenario 1.

Anexo G1.

Mes	Periodo	Demanda Oferta Real	Pronóstico Oferta GRN	Pronóstico Oferta LMP	ERROR GRN	ERROR LMP
Enero	1	0				
Febrero	2	0				
Marzo	3	0				
Abril	4	0				
Mayo	5	0				
Junio	6	0				
Julio	7	0				
Agosto	8	0				
Septiembre	9	0	0	0		
Octubre	10	76	223	91	147	15
Noviembre	11	149	223	88	74	61
Diciembre	12	250	245	249	5	1
Enero	13	74	74	88	0	14
Febrero	14	13	13	40	0	27
Marzo	15	15	165	88	150	73
Abril	16	13	15	98	2	85
Mayo	17	0	0	0		

Anexo G2.

Mes	Periodo	Demanda Oferta Real	Pronóstico Oferta Red GRN	Pronóstico Oferta Red LMP	ERROR GRN	ERROR LMP
Enero	1	0				
Febrero	2	0				
Marzo	3	0				
Abril	4	0				
Mayo	5	0				
Junio	6	0				
Julio	7	0				
Agosto	8	0				
Septiembre	9	0	0	0		
Octubre	10	76	223	91	147	15
Noviembre	11	149	223	88	74	61
Diciembre	12	250	245	249	5	1
Enero	13	74	74	88	0	14
Febrero	14	13	13	40	0	27
Marzo	15	15	15	88	0	73
Abril	16	13	15	98	2	85

ANEXO H. Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 2.

OFERTA	REGULAR	TIPO DE PROMOCIÓN	TEMPORADA (MES)	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
0	1.047		Enero	C2			E
0	801		Febrero	C2			E
0	616		Marzo	C2			E
0	758		Abril	C2			E
0	668		Mayo	C2			E
0	729		Junio	C2			E
0	841		Julio	C2			E
0	863		Agosto	C2			E
0	842		Septiembre	C2			E
0	954		Octubre	C2			E
0	939		Noviembre	C2			E
0	1.249		Diciembre	C2			E
0	1.195		Enero	C2			E
70	650	Pague M Lleve N	Febrero	C2	7 Meses	1	E
568	314	Pague M Lleve N	Marzo	C2	7 Meses	2	E
344	428	Pague M Lleve N	Abril	C2	7 Meses	3	E
212	707	Pague M Lleve N	Mayo	C2	7 Meses	4	E
32	856	Pague M Lleve N	Junio	C2	7 Meses	5	E
0	898		Julio	C2			E
0	849		Agosto	C2			E
0	562		Septiembre	C2			E
0	741		Octubre	C2			E
0	699		Noviembre	C2			E
0	743		Diciembre	C2			E
0	607		Enero	C2			E
0	370		Febrero	C2			E
0	331		Marzo	C2			E
0	348		Abril	C2			E
0	234		Mayo	C2			E
0	700		Junio	C2			E
0	720		Julio	C2			E
0	819		Agosto	C2			E
0	767		Septiembre	C2			E
0	545		Octubre	C2			E

ANEXO I. Conjunto de datos usados para predicción en el escenario 2.

Anexo I1.

Mes	Periodo	Demanda Regular Real	Pronóstico o Red GRN	Pronóstico Red LMP	ERROR GRN	ERROR LMP
Enero	1	1.047				
Febrero	2	801				
Marzo	3	616				
Abril	4	758				
Mayo	5	668				
Junio	6	729				
Julio	7	841				
Agosto	8	863				
Septiembre	9	842				
Octubre	10	954				
Noviembre	11	939				
Diciembre	12	1.249				
Enero	13	1.195				
Febrero	14	650	119	70	531	580
Marzo	15	314	160	63	154	251
Abril	16	428	97	62	331	366
Mayo	17	707	95	63	612	644
Junio	18	856	193	62	663	794

Anexo I2.

Mes	Periodo	Oferta Real	Pronóstico o GRN	Pronóstico o LMP	ERROR GRN	ERROR LMP
Enero	1	0				
Febrero	2	0				
Marzo	3	0				
Abril	4	0				
Mayo	5	0				
Junio	6	0				
Julio	7	0				
Agosto	8	0				
Septiembre	9	0				
Octubre	10	0				
Noviembre	11	0				
Diciembre	12	0				
Enero	13	0			0	0
Febrero	14	70	64	68	6	2
Marzo	15	568	148	719	420	151
Abril	16	344	974	724	630	380
Mayo	17	212	209	454	3	242
Junio	18	32	586	66	554	34

ANEXO J. Conjunto de datos de una serie asociado a sus respectivos factores en el escenario 3.

OFERTA	REGULAR	TIPO DE PROMOCIÓN	TEMPORADA (MES)	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
122	60	Pague M Lleve N	Febrero	C2	7 Meses	1	E
900	33	Pague M Lleve N	Marzo	C2	7 Meses	2	E
1.003	51	Pague M Lleve N	Abril	C2	7 Meses	3	E
770	31	Pague M Lleve N	Mayo	C2	7 Meses	4	E
603	22	Pague M Lleve N	Junio	C2	7 Meses	5	E
251	6	Pague M Lleve N	Julio	C2	7 Meses	6	E
103	8	Pague M Lleve N	Agosto	C2	7 Meses	7	E
12	108	Pague M Lleve N	Febrero	C2	4 Meses	1	E
95	147	Pague M Lleve N	Marzo	C2	4 Meses	2	E
57	129	Pague M Lleve N	Abril	C2	4 Meses	3	E
35	153	Pague M Lleve N	Mayo	C2	4 Meses	4	E
91	623	GRATIS OTRO PRODUCTO	Febrero	C2	4 Meses	1	E
499	294	GRATIS OTRO PRODUCTO	Marzo	C2	4 Meses	2	E
444	333	GRATIS OTRO PRODUCTO	Abril	C2	4 Meses	3	E
169	628	GRATIS OTRO PRODUCTO	Mayo	C2	4 Meses	4	E
128	43	GRATIS OTRO PRODUCTO	Agosto	C9	5 Meses	1	E
245	140	GRATIS OTRO PRODUCTO	Septiembre	C9	5 Meses	2	E
269	238	GRATIS OTRO PRODUCTO	Octubre	C9	5 Meses	3	E
248	228	GRATIS OTRO PRODUCTO	Noviembre	C9	5 Meses	4	E
32	722	GRATIS OTRO PRODUCTO	Diciembre	C9	5 Meses	5	E
37	114	Pague M Lleve N	Agosto	C9	5 Meses	1	E
57	162	Pague M Lleve N	Septiembre	C9	5 Meses	2	E
76	126	Pague M Lleve N	Octubre	C9	5 Meses	3	E
57	92	Pague M Lleve N	Noviembre	C9	5 Meses	4	E
45	236	Pague M Lleve N	Diciembre	C9	5 Meses	5	E
37	114	Pague M Lleve N	Agosto	C9	5 Meses	1	E
57	162	Pague M Lleve N	Septiembre	C9	5 Meses	2	E
76	126	Pague M Lleve N	Octubre	C9	5 Meses	3	E
57	92	Pague M Lleve N	Noviembre	C9	5 Meses	4	E
45	236	Pague M Lleve N	Diciembre	C9	5 Meses	5	E
37	92	Pague M Lleve N	Agosto	C9	5 Meses	1	E
79	104	Pague M Lleve N	Septiembre	C9	5 Meses	2	E
102	80	Pague M Lleve N	Octubre	C9	5 Meses	3	E
62	94	Pague M Lleve N	Noviembre	C9	5 Meses	4	E
35	197	Pague M Lleve N	Diciembre	C9	5 Meses	5	E

ANEXO K. Conjunto de datos usados para predicción en el escenario 3

Anexo K1

Mes	Periodo	Demand a Oferta Real	Pronóstic o Oferta GRN	Pronóstic o Oferta LMP	ERROR GRN	ERROR LMP
Enero	1	0				
Febrero	2	0				
Marzo	3	0				
Abril	4	0				
Mayo	5	0				
Junio	6	0				
Julio	7	0				
Agosto	8	0				
Septiembre	9	0				
Octubre	10	0				
Noviembre	11	0				
Diciembre	12	0				
Enero	13	0				
Febrero	14	0				
Marzo	15	0				
Abril	16	0				
Mayo	17	0				
Junio	18	0				
Julio	19	0				
Agosto	20	128	9	81	119,34	47
Septiembre	21	245	245	81	0,00	164
Octubre	22	269	32	81	236,91	188
Noviembre	23	248	128	81	119,77	167
Diciembre	24	32	90	126	58,24	94

Anexo K2

Mes	Periodo	Demanda Oferta Real	Pronóstico o Oferta GRN	Pronóstico o Oferta LMP	ERROR GRN	ERROR LMP
Enero	1	470				
Febrero	2	557				
Marzo	3	683				
Abril	4	622				
Mayo	5	722				
Junio	6	755				
Julio	7	763				
Agosto	8	567				
Septiembre	9	152				
Octubre	10	25				
Noviembre	11	6				
Diciembre	12	9				
Enero	13	9				
Febrero	14	2				
Marzo	15	0				
Abril	16	1				
Mayo	17	0				
Junio	18	2				
Julio	19	1				
Agosto	20	43	118	93	74,69	50
Septiembre	21	140	135	198	4,59	58
Octubre	22	238	108	93	130,36	145
Noviembre	23	228	96	93	131,78	135
Diciembre	24	722	216	96	506,10	626

ANEXO L. Escenarios para probar los sistemas de pronósticos (Escenarios 1, 2 y 3).

ESCENARIO 1												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	244	244				6	D	D6			8
Febrero	0	130	130				6	D	D6			8
Marzo	0	155	155				6	D	D6			8
Abril	0	169	169				6	D	D6			8
Mayo	0	143	143				6	D	D6			8
Junio	0	166	166				6	D	D6			8
Julio	0	170	170				6	D	D6			8
Agosto	0	144	144				6	D	D6			8
Septiembre	0	140	140				6	D	D6			8
Octubre	76	85	161	Ahorre \$	Ahorre \$800	Octubre	6	D	D6	7 meses	1	8
Noviembre	149	59	208	Ahorre \$	Ahorre \$800	Noviembre	6	D	D6	7 meses	2	8
Diciembre	250	123	373	Ahorre \$	Ahorre \$800	Diciembre	6	D	D6	7 meses	3	8
Enero	74	100	174	Ahorre \$	Ahorre \$800	Enero	6	D	D6	7 meses	4	8
Febrero	13	85	98	Ahorre \$	Ahorre \$800	Febrero	6	D	D6	7 meses	5	8
Marzo	15	185	200	Ahorre \$	Ahorre \$800	Marzo	6	D	D6	7 meses	6	8
Abril	13	135	148	Ahorre \$	Ahorre \$800	Abril	6	D	D6	7 meses	7	8
Mayo	0	149	149				6	D	D6			8
Junio	0	168	168				6	D	D6			8
Julio	0	170	170				6	D	D6			8
Agosto	0	153	153				6	D	D6			8
Septiembre	0	142	142				6	D	D6			8
Octubre	0	116	116				6	D	D6			8
Noviembre	0	140	140				6	D	D6			8
Diciembre	0	258	258				6	D	D6			8
Enero	0	296	296				6	D	D6			8
Febrero	0	194	194				6	D	D6			8
Marzo	0	192	192				6	D	D6			8
Abril	0	141	141				6	D	D6			8
Mayo	0	162	162				6	D	D6			8
Junio	0	147	147				6	D	D6			8
Julio	0	159	159				6	D	D6			8
Agosto	0	136	136				6	D	D6			8
Septiembre	0	134	134				6	D	D6			8
Octubre	0	118	118				6	D	D6			8
Noviembre	0	183	183				6	D	D6			8
Diciembre	0	245	245				6	D	D6			8

ESCENARIO 2												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	1047	1047				2	C	C2			8
Febrero	0	801	801				2	C	C2			8
Marzo	0	616	616				2	C	C2			8
Abril	0	758	758				2	C	C2			8
Mayo	0	668	668				2	C	C2			8
Junio	0	729	729				2	C	C2			8
Julio	0	841	841				2	C	C2			8
Agosto	0	863	863				2	C	C2			8
Septiembre	0	842	842				2	C	C2			8
Octubre	0	954	954				2	C	C2			8
Noviembre	0	939	939				2	C	C2			8
Diciembre	0	1249	1249				2	C	C2			8
Enero	0	1195	1195				2	C	C2			8
Febrero	70	650	720	ague M Lleve	Pague 8 Llev	Febrero	2	C	C2	5 Meses	1	8
Marzo	568	314	882	ague M Lleve	Pague 8 Llev	Marzo	2	C	C2	5 Meses	2	8
Abril	344	428	772	ague M Lleve	Pague 8 Llev	Abril	2	C	C2	5 Meses	3	8
Mayo	212	707	919	ague M Lleve	Pague 8 Llev	Mayo	2	C	C2	5 Meses	4	8
Junio	32	856	888	ague M Lleve	Pague 8 Llev	Junio	2	C	C2	5 Meses	5	8
Julio	0	898	898				2	C	C2			8
Agosto	0	849	849				2	C	C2			8
Septiembre	0	562	562				2	C	C2			8
Octubre	0	741	741				2	C	C2			8
Noviembre	0	699	699				2	C	C2			8
Diciembre	0	743	743				2	C	C2			8
Enero	0	607	607				2	C	C2			8
Febrero	0	370	370				2	C	C2			8
Marzo	0	331	331				2	C	C2			8
Abril	0	348	348				2	C	C2			8
Mayo	0	234	234				2	C	C2			8
Junio	0	700	700				2	C	C2			8
Julio	0	720	720				2	C	C2			8
Agosto	0	819	819				2	C	C2			8
Septiembre	0	767	767				2	C	C2			8
Octubre	0	545	545				2	C	C2			8
Noviembre	0	456	456				2	C	C2			8
Diciembre	0	934	934				2	C	C2			8

ESCENARIO 3												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Enero	0	470	470				9	C	C9			E
Febrero	0	557	557				9	C	C9			E
Marzo	0	683	683				9	C	C9			E
Abril	0	622	622				9	C	C9			E
Mayo	0	722	722				9	C	C9			E
Junio	0	755	755				9	C	C9			E
Julio	0	763	763				9	C	C9			E
Agosto	0	567	567				9	C	C9			E
Septiembre	0	152	152				9	C	C9			E
Octubre	0	25	25				9	C	C9			E
Noviembre	0	6	6				9	C	C9			E
Diciembre	0	9	9				9	C	C9			E
Enero	0	9	9				9	C	C9			E
Febrero	0	2	2				9	C	C9			E
Marzo	0	0	0				9	C	C9			E
Abril	0	1	1				9	C	C9			E
Mayo	0	0	0				9	C	C9			E
Junio	0	2	2				9	C	C9			E
Julio	0	1	1				9	C	C9			E
Agosto	128	43	171	tis otro Produ	gratis 2 sobre	Agosto	9	C	C9	5 meses	1	E
Septiembre	245	140	385	tis otro Produ	gratis 2 sobre	Septiembre	9	C	C9	5 meses	2	E
Octubre	269	238	507	tis otro Produ	gratis 2 sobre	Octubre	9	C	C9	5 meses	3	E
Noviembre	248	228	476	tis otro Produ	gratis 2 sobre	Noviembre	9	C	C9	5 meses	4	E
Diciembre	32	722	754	tis otro Produ	gratis 2 sobre	Diciembre	9	C	C9	5 meses	5	E
Enero	0	639	639				9	C	C9			E
Febrero	0	557	557				9	C	C9			E
Marzo	0	545	545				9	C	C9			E
Abril	0	545	545				9	C	C9			E
Mayo	0	493	493				9	C	C9			E
Junio	0	351	351				9	C	C9			E
Julio	0	366	366				9	C	C9			E
Agosto	0	444	444				9	C	C9			E
Septiembre	0	735	735				9	C	C9			E
Octubre	0	671	671				9	C	C9			E
Noviembre	0	578	578				9	C	C9			E
Diciembre	0	219	219				9	C	C9			E

ANEXO M. Modelo de pronósticos tradicional con Suavización Exponencial Doble con indicadores de error (MAD, ECM, PAME) (Escenarios 1, 2 y 3).

ESCENARIO 1												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Octubre	76	85	161	AHORRE \$	AHS800	Octubre	6	D	D6	7 Meses	1	B
Noviembre	149	59	208	AHORRE \$	AHS800	Noviembre	6	D	D6	7 Meses	2	B
Diciembre	250	123	373	AHORRE \$	AHS800	Diciembre	6	D	D6	7 Meses	3	B
Enero	74	100	174	AHORRE \$	AHS800	Enero	6	D	D6	7 Meses	4	B
Febrero	13	85	98	AHORRE \$	AHS800	Febrero	6	D	D6	7 Meses	5	B
Marzo	15	185	200	AHORRE \$	AHS800	Marzo	6	D	D6	7 Meses	6	B
Abril	13	135	148	AHORRE \$	AHS800	Abril	6	D	D6	7 Meses	7	B

SUAVIZACIÓN EXPONENCIAL DOBLE								
Mes	Demanda	S	S [2]	Pronóstico	error	error	error ²	error /d
1	76							
2	149							
3	250							
4	74							
5	13							
6	15							
7	13	2637,21429	5091					
8	76	2610,97214	5066,19972	159	-83	83	6830	1,09
9	149	2585,62242	5041,39395	131	18	18	326	0,12
10	250	2561,2562	5016,59257	105	145	145	21012	0,58
11	74	2538,14364	4991,80808	81	-7	7	51	0,10
12	13	2513,5022	4967,02502	60	-47	47	2180	3,59
13	15	2488,49718	4942,23974	35	-20	20	408	1,35
14	13	2463,76221	4917,45497	10	3	3	9	0,23

m	-24,785714
b	183,428571
b1	183,428571
MAD	46,099083
ECM	4402,27298
PAME	1,00800707
α	0,01

ESCENARIO 2												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Octubre	76	85	161	AHORRE \$	AHS800	Octubre	6	D	D6	7 Meses	1	B
Noviembre	149	59	208	AHORRE \$	AHS800	Noviembre	6	D	D6	7 Meses	2	B
Diciembre	250	123	373	AHORRE \$	AHS800	Diciembre	6	D	D6	7 Meses	3	B
Enero	74	100	174	AHORRE \$	AHS800	Enero	6	D	D6	7 Meses	4	B
Febrero	13	85	98	AHORRE \$	AHS800	Febrero	6	D	D6	7 Meses	5	B
Marzo	15	185	200	AHORRE \$	AHS800	Marzo	6	D	D6	7 Meses	6	B
Abril	13	135	148	AHORRE \$	AHS800	Abril	6	D	D6	7 Meses	7	B

SUAVIZACIÓN EXPONENCIAL DOBLE								
Mes	Demanda	S	S [2]	Pronóstico	error	error	error ²	error /d
1	76							
2	149							
3	250							
4	74							
5	13							
6	15							
7	13	2637,2143	5091					
8	70	2610,9721	5066,1997	159	-89	89	7858	1,27
9	568	2585,5624	5041,3933	131	437	437	191018	0,77
10	344	2565,3868	5016,6333	105	239	239	57157	0,69
11	212	2543,1729	4991,8987	89	123	123	15036	0,58
12	32	2519,8612	4967,1783	70	-38	38	1422	1,18

m	-24,78571
b	183,42857
b1	183,42857
MAD	185,02116
ECM	54497,979
PAME	0,8975378
α	0,01

ANEXO N. Modelo de pronósticos basado en Lee et al. (2007) con Suavización Exponencial Doble e indicadores de error (MAD, ECM, PAME) (Escenarios 1, 2 y 3).

ESCENARIO 1														
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORAD A (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO		
Octubre	76	85	161	AHORRE \$	AH\$800	Octubre	6	D	D6	7 Meses	1	B		
Noviembre	149	59	208	AHORRE \$	AH\$800	Noviembre	6	D	D6	7 Meses	2	B		
Diciembre	250	123	373	AHORRE \$	AH\$800	Diciembre	6	D	D6	7 Meses	3	B		
Enero	74	100	174	AHORRE \$	AH\$800	Enero	6	D	D6	7 Meses	4	B		
Febrero	13	85	98	AHORRE \$	AH\$800	Febrero	6	D	D6	7 Meses	5	B		
Marzo	15	185	200	AHORRE \$	AH\$800	Marzo	6	D	D6	7 Meses	6	B		
Abril	13	135	148	AHORRE \$	AH\$800	Abril	6	D	D6	7 Meses	7	B		
SUAVIZACIÓN EXPONENCIAL DOBLE														
Mes	Demanda	S	S [2]	Pronóstico	error	error	error'	error /d						
1	76								m	-24,7857143				
2	149								b	183,428571				
3	250								b1	183,428571				
4	74								MAD	46,099083				
5	13								ECM	4402,27298				
6	15								PAME	1,00800707				
7	13	2637,21429	5091						α	0,01				
8	76	2610,97214	5066,19972	159	-83	83	6830	1,09						
9	149	2585,62242	5041,39395	131	18	18	326	0,12						
10	250	2561,2562	5016,59257	105	145	145	21012	0,58						
11	74	2538,14364	4991,80808	81	-7	7	51	0,10						
12	13	2513,5022	4967,02502	60	-47	47	2180	3,59						
13	15	2488,49718	4942,23974	35	-20	20	408	1,35						
14	13	2463,76221	4917,45497	10	3	3	9	0,23						

ESCENARIO 2														
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORAD A (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO		
Octubre	76	85	161	AHORRE \$	AH\$800	Octubre	6	D	D6	7 Meses	1	B		
Noviembre	149	59	208	AHORRE \$	AH\$800	Noviembre	6	D	D6	7 Meses	2	B		
Diciembre	250	123	373	AHORRE \$	AH\$800	Diciembre	6	D	D6	7 Meses	3	B		
Enero	74	100	174	AHORRE \$	AH\$800	Enero	6	D	D6	7 Meses	4	B		
Febrero	13	85	98	AHORRE \$	AH\$800	Febrero	6	D	D6	7 Meses	5	B		
Marzo	15	185	200	AHORRE \$	AH\$800	Marzo	6	D	D6	7 Meses	6	B		
Abril	13	135	148	AHORRE \$	AH\$800	Abril	6	D	D6	7 Meses	7	B		
SUAVIZACIÓN EXPONENCIAL DOBLE														
Mes	Demanda	S	S [2]	Pronóstico	error	error	error'	error /d						
1	76								m	-24,7857143				
2	149								b	183,428571				
3	250								b1	183,428571				
4	74								MAD	185,021156				
5	13								ECM	54497,9787				
6	15								PAME	0,8975378				
7	13	2637,21429	5091						α	0,01				
8	70	2610,97214	5066,19972	159	-89	89	7858	1,27						
9	568	2585,56242	5041,39335	131	437	437	191018	0,77						
10	344	2565,3868	5016,63328	105	239	239	57157	0,69						
11	212	2543,17293	4991,89868	89	123	123	15036	0,58						
12	32	2519,8612	4967,1783	70	-38	38	1422	1,18						

ESCENARIO 3												
MES	OFERTA	REGULAR	SUMA	TIPO DE PROMOCIÓN	OFERTA REAL	TEMPORADA (MES)	CÓDIGO PUNTO DE VENTA	CÓDIGO ZONA	CÓDIGO GENERAL PUNTO DE VENTA	DURACIÓN PROMOCIÓN	PERIODO DURACIÓN	PRODUCTO
Agosto	37	114	151	ague M Lleve	X 8 GTS 3 SOB	Agosto	9	C	C9	5 Meses	1	E
Septiembre	57	162	219	ague M Lleve	X 8 GTS 3 SOB	Septiembre	9	C	C9	5 Meses	2	E
Octubre	76	126	202	ague M Lleve	X 8 GTS 3 SOB	Octubre	9	C	C9	5 Meses	3	E
Noviembre	57	92	149	ague M Lleve	X 8 GTS 3 SOB	Noviembre	9	C	C9	5 Meses	4	E
Diciembre	45	236	281	ague M Lleve	X 8 GTS 3 SOB	Diciembre	9	C	C9	5 Meses	5	E
Agosto	37	92	129	ague M Lleve	X 8 GTS 3 SOB	Agosto	9	C	C9	5 Meses	1	E
Septiembre	79	104	183	ague M Lleve	X 8 GTS 3 SOB	Septiembre	9	C	C9	5 Meses	2	E
Octubre	102	80	182	ague M Lleve	X 8 GTS 3 SOB	Octubre	9	C	C9	5 Meses	3	E
Noviembre	62	94	156	ague M Lleve	X 8 GTS 3 SOB	Noviembre	9	C	C9	5 Meses	4	E
Diciembre	35	197	232	ague M Lleve	X 8 GTS 3 SOB	Diciembre	9	C	C9	5 Meses	5	E

SUAVIZACIÓN EXPONENCIAL DOBLE												
Mes	Demanda	S	S[2]	Pronóstico	error	error	error	error /d				
1	37											
2	57											
3	76											
4	57											
5	45											
6	37											
7	79											
8	102											
9	62											
10	35	40,3795229	28,8923792									
11	128	39,8544737	30,013541	53	75	75	5609	0,59				
12	245	48,4576045	30,9740303	51	194	194	37729	0,79				
13	269	67,6404265	32,6804524	68	201	201	40468	0,75				
14	248	87,293412	36,0925964	106	142	142	20056	0,57				
15	32	102,978607	41,08987	144	-112	112	12551	3,50				

m	1,24242424
b	51,8666667
b1	51,8666667
MAD	144,789873
ECM	23282,6701
PAME	1,23955602
α	0,09760145