UN MODELO PARA EL PRONÓSTICO DE DEMANDA DE PRODUCTOS ALIMENTICIOS EN UN RESTAURANTE INSTITUCIONAL

DANNY STEVEN MARTÍNEZ PAREDES, Ing.
ARMANDO ALIRIO AGUIRRE VALENCIA, Ing.



FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA INDUSTRIAL
MAESTRÍA EN INGENIERÍA ÉNFASIS EN INGENIERÍA INDUSTRIAL
SANTIAGO DE CALI
2012

UN MODELO PARA EL PRONÓSTICO DE DEMANDA DE PRODUCTOS ALIMENTICIOS EN UN RESTAURANTE INSTITUCIONAL

DANNY STEVEN MARTÍNEZ PAREDES, Ing.
ARMANDO ALIRIO AGUIRRE VALENCIA, Ing.

Trabajo de Grado para optar al título de Magister en Ingeniería

Director
JULIO CESAR LONDOÑO ORTEGA, M.Sc.



FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA INDUSTRIAL
MAESTRÍA EN INGENIERÍA ÉNFASIS EN INGENIERÍA INDUSTRIAL
SANTIAGO DE CALI
2012

NOTA DE ACEPTACIÓN

M.Sc. Julio César Londoño Ortega
Director

Ph.D. Carlos Julio Vidal Holguín
Jurado

M.Sc. Juan Pablo Orejuela Cabrera
Jurado

Santiago de Cali, septiembre 13 de 2012

A mi padre, mi madre y mi hermano por todo el apoyo brindado durante estos años. A Nana por su amor y comprensión.

Danny

Agradezco a mi familia por su apoyo, comprensión, paciencia y por el tiempo que me brindaron a lo largo de este proyecto.

Armando

AGRADECIMIENTOS

Los autores expresan sus agradecimientos a las siguientes personas:

- M.Sc. Julio César Londoño: Profesor de la Universidad del Valle y Director de esta investigación.
- Sra. Martha Lucia Cardona: Jefe de sección restaurante de la Universidad del Valle.
- Sra. Aida Elena Palacios: Profesional encargada de la producción del restaurante de la Universidad del Valle.
- M.Sc. Andrés Felipe Osorio: Director de la Maestría en Ingeniería Industrial de la Universidad ICESI.
- Sr. Jaime Mosquera: Profesor de la Universidad del Valle.
- M.Sc. Gloria Esperanza Portilla: Docente investigadora de la Pontificia Universidad Javeriana.
- Nuestras familias y amigos.

Su colaboración fue determinante en el desarrollo de este proyecto de investigación.

CONTENIDO

	Página
INTRODUCCIÓN	1
1. PLANTEAMIENTO DEL PROBLEMA	3
2. OBJETIVOS	5
2.1 OBJETIVO GENERAL	5
2.2 OBJETIVOS ESPECÍFICOS	5
3. ESTADO DEL ARTE	6
3.1 MÉTODOS CLÁSICOS DE PRONÓSTICOS	6
3.2 REDES NEURONALES ARTIFICIALES	8
4. MARCO TEÓRICO	10
4.1 ARQUITECTURA	12
4.2 FUNCIÓN DE ACTIVACIÓN O TRANSFERENCIA	16
4.3 PROCESO DE APRENDIZAJE	16
5. PROCESO METODOLÓGICO	21

5.1 CASO DE ESTUDIO 21

5.2 ANÁLISIS DE LOS FACTORES QUE AFECTAN LA DEMANDA DIARIA 23

5.3 MODELO DE PRONÓSTICO DE DEMANDA CON REDES NEURONALES ARTIFICIALES 39

5.3.1 Planteamiento del modelo de Redes Neuronales Artificiales para el pronóstico de la demanda diaria 40

5.3.2 Evaluación del modelo de Redes Neuronales Artificiales para el pronóstico de la demanda diaria 44

5.3.3 Pronósticos de demanda con Redes Neuronales Artificiales vs. Pronósticos de demanda con Métodos Clásicos 51

6. CONCLUSIONES Y TRABAJOS FUTUROS 66

6.1 CONCLUSIONES 66

6.2 TRABAJOS FUTUROS 67

BIBLIOGRAFÍA 69

LISTA DE TABLAS

Página

Tabla 1. Características de los métodos para pronosticar la demanda 6

Tabla 2. Cantidad de registros de demanda diaria por cada semestre 23

Tabla 3. Programación de menús para la semana del 20 al 24 de febrero del 2012 24

Tabla 4. Muestra del listado de preparaciones 25

Tabla 5. Muestra de los datos consolidados 26

Tabla 6. Estadísticos descriptivos de la demanda diaria por semestre 29

Tabla 7. Ejemplo de preparaciones para cada elemento de menú 40

Tabla 8. Grupos de preparaciones para cada elemento de menú 41

Tabla 9. Ejemplo de construcción de un patrón de menú 42

Tabla 10. Número de veces que fue utilizado cada patrón durante los períodos analizados 42

Tabla 11. Porcentaje de utilización de los patrones de menú 43

Tabla 12. Principales características de los software utilizados 44

Tabla 13. Indicadores de la evaluación de las Redes Neuronales Artificiales para el 47

pronóstico de la demanda del 16 de mayo al 15 de junio de 2012

Tabla 14. Inventario de seguridad para el pronóstico de la demanda del 16 de mayo al 15 de junio de 2012 50

Tabla 15. Indicadores de la evaluación del método del Promedio Móvil 52

Tabla 16. Indicadores de la evaluación del método de la Suavización Exponencial Simple 54

Tabla 17. Indicadores de la evaluación del método de la Suavización Exponencial Doble 55

Tabla 18. Indicadores de la evaluación del método Combinado 56

Tabla 19. Indicadores de la evaluación del método Multiplicativo de Winters 58

Tabla 20. Indicadores de la evaluación de los métodos clásicos de pronósticos 60

Tabla 21. Indicadores de la evaluación de las Redes Neuronales Artificiales 61

Tabla 22. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales 62

Tabla 23. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales para la demanda diaria de los estudiantes 63

Tabla 24. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales para la demanda diaria de los empleados 64

LISTA DE FIGURAS

Página

Figura 1. La neurona biológica 10

Figura 2. Estructura básica de una Red Neuronal Artificial 11

Figura 3. Red Neuronal Artificial unidireccional monocapa 13

Figura 4. Red Neuronal Artificial unidireccional multicapa 14

Figura 5. Perceptrón Multicapa para tres variables de entrada, con dos nodos en la primera capa oculta y tres en la segunda 14

Figura 6. Red de Regresión Generalizada para dos variables de entrada con tres casos de patrón en el entrenamiento 15

Figura 7. Principales tipos de funciones de activación 17

Figura 8. Esquema del algoritmo Backpropagation 19

Figura 9. Cantidad de almuerzos servidos por cada semestre 22

Figura 10. Comportamiento de la demanda diaria 28

Figura 11. Comportamiento de la demanda diaria de los empleados 30

Figura 12. Comportamiento de la demanda diaria de los estudiantes 30

Figuras 13. Boxplot de la demanda según el tipo de usuario 31

Figuras 14. Comportamiento de la demanda durante los días lunes 32

Figuras 15. Comportamiento de la demanda durante los días martes 32

Figuras 16. Comportamiento de la demanda durante los días miércoles 33

Figuras 17. Comportamiento de la demanda durante los días jueves 33

Figuras 18. Comportamiento de la demanda durante los días viernes 34

Figuras 19. Boxplot de la demanda según el día de la semana 34

Figura 20. Comportamiento de la demanda de los días en que se sirvieron frijoles 36

Figura 21. Comportamiento de la demanda de los días en que se sirvió pescado 36

Figuras 22. Boxplot de la demanda de los días en que se sirvieron frijoles y los días en que se sirvió pescado 37

Figura 23. Comportamiento de la demanda de los días en que se sirvió carne de cerdo 37

Figura 24. Comportamiento de la demanda de los días en que se sirvió pollo 38

Figura 25. Comportamiento de la demanda de los días en que se sirvió carne de res 38

Figura 26. Boxplot de la demanda según el tipo de carne servida 39

Figura 27. Modelo propuesto de Red Neuronal Artificial 43

Figura 28. Pronóstico de la demanda del 16 de mayo al 15 de junio del 2012 obtenido con las Redes Neuronales Artificiales. 48

Figura 29. Impacto de las variables independientes en cada tipo de red simulada para pronosticar la demanda del 16 de mayo al 15 de junio del 2012 49

Figura 30. Pronóstico de la demanda obtenido con el método del Promedio Móvil 53

Figura 31. Pronóstico de la demanda obtenido con el método de la Suavización Exponencial Simple 54

Figura 32. Pronóstico de la demanda obtenido con el método de la Suavización Exponencial Doble 55

Figura 33. Pronóstico de la demanda obtenido con el método Combinado 57

Figura 34. Pronóstico de la demanda obtenido con el método Multiplicativo de Winters 58

Figura 35. Pronóstico de la demanda obtenido con cada uno de los métodos clásicos evaluados 59

Figura 36. Pronóstico de la demanda obtenido con los métodos que presentaron mejor desempeño en la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales 62

Figura 37. Pronóstico obtenido con los métodos clásicos y las Redes Neuronales Artificiales para la demanda diaria de los estudiantes 63

Figura 38. Pronóstico obtenido con los métodos clásicos y las Redes Neuronales Artificiales para la demanda diaria de los empleados 65

INTRODUCCIÓN

Uno de los desafíos de una empresa que elabora alimentos para miles de clientes, es decidir la cantidad de productos que debe preparar cada día. Este valor es de gran importancia para la planeación diaria de la producción, porque la elaboración de más o menos alimentos respecto a la demanda diaria real, puede ser la diferencia entre no satisfacer las necesidades de los clientes o desperdiciar productos, y aprovechar de manera eficiente los recursos. Debido a estas condiciones, se hace necesario contar con una herramienta que le permita a los planeadores disponer de información precisa, para determinar la cantidad de productos que se deben preparar para satisfacer la demanda diaria.

Es aquí donde el pronóstico, aparece como un instrumento que permite calcular las proyecciones de la demanda diaria de forma rápida y confiable, utilizando como fuente de trabajo la información histórica de la serie. Existen varias técnicas aplicadas para la elaboración de pronósticos como el Promedio Móvil, los Modelos Autorregresivos Integrados de Medias Móviles (en inglés Autoregressive Integrated Moving Average, ARIMA), la Suavización Exponencial, el método Multiplicativo de Winters, etc. Sin embargo, las Redes Neuronales Artificiales permiten generarlos en situaciones donde la serie es no lineal, debido a que ésta puede ser afectada por diferentes factores tales como la diversidad y periodicidad del menú, el día de la semana o el mes, entre otros; y así, ofrecer un resultado confiable a los planeadores.

El objetivo principal de este proyecto de investigación es la construcción de un modelo para el pronóstico de la demanda de alimentos en un restaurante institucional, aplicando conceptos y tecnologías de Redes Neuronales Artificiales. Con este propósito se construyó un caso de estudio fundamentado en la operación del restaurante de la Universidad del Valle, en el municipio de Santiago de Cali, Colombia.

A partir de sus datos históricos, se analizó qué factores tienen influencia en el comportamiento de la demanda diaria, los cuales son: la fecha, el día de la semana, la época del semestre y el menú preparado. Basado en esta información se propuso un

modelo de Redes Neuronales Artificiales para predecir la demanda en el restaurante universitario.

Este modelo se simuló mediante el uso de software especializados para dos tipos de redes diferentes: Perceptrón Multicapa y Red de Regresión Generalizada. Los resultados de esta evaluación se compararon con los obtenidos a través de la aplicación de los métodos clásicos de pronósticos.

Con base en lo anterior, este estudio concluyó que utilizar un modelo basado en Redes Neuronales Artificiales es mejor alternativa que los métodos clásicos para pronosticar la demanda en sistemas productivos donde la serie es discontinua, como la que se presenta en el restaurante de la Universidad del Valle; esto debido a la capacidad que tiene de ajustarse rápidamente a los cambios producidos en el comportamiento de la demanda, a causa de los diferentes factores que puedan afectarla. Así mismo, en sistemas donde el comportamiento de la demanda no es muy variable y se convierte en perpetua, se sugiere usar mejor los métodos clásicos, ya que el desarrollo de un modelo de Redes Neuronales Artificiales requiere un gran esfuerzo y los resultados obtenidos respecto a los clásicos no presentan una mayor mejora.

Para finalizar, se plantean algunas propuestas de investigación futuras que podrían llevarse a cabo tomando como base los resultados obtenidos en este trabajo.

1. PLANTEAMIENTO DEL PROBLEMA

La incertidumbre y variabilidad en la demanda diaria de usuarios en el sistema de producción de alimentos de un restaurante institucional, puede ocasionar principalmente dos situaciones: por una parte sobrecostos productivos debido a la elaboración de más productos de los necesarios, y por otra parte, pérdidas a causa del malestar de los clientes por demandas no satisfechas e imagen negativa en el servicio cuando se produzcan menos alimentos que los demandados.

Esta variabilidad puede darse por diversos factores que a su vez pueden tener mayor o menor influencia en la demanda. Factores como el día de la semana o del mes (inicio o fin de mes, quincena), tipo de carne del menú (pescado, carne de res o de cerdo, pollo), fechas especiales (día de la secretaria, día de amor y amistad, día del estudiante), entre otros, afectan la cantidad de usuarios que se acercan a diario a comprar los productos ofrecidos por el restaurante institucional.

Lo planteado anteriormente, ocasiona excesos o faltantes de alimentos que afectan las finanzas de la empresa, debido a que los primeros aumentan el costo promedio del plato, sobrepasando el rango del costo presupuestado, mientras que los segundos incrementan la tasa de rumor negativo de la empresa causada por la no satisfacción de los clientes. Esta situación se convierte en crítica si se considera que estos factores negativos podrían presentarse diariamente.

Bajo este escenario, es necesario establecer los siguientes supuestos:

- Existe suficiente inventario durante la planeación de la producción.
- No hay problemas de almacenamiento y conservación de los productos perecederos con los que se elabora el menú diario.
- En el restaurante se elabora diariamente sólo un tipo de menú.
- El pronóstico se calculará para cada día de acuerdo a la información de la demanda, con relación a las causas que se definan.

Dado que se desconoce el comportamiento de la demanda, se requiere explorar las técnicas tradicionales para pronosticar y comparar sus resultados con los obtenidos con otros métodos. En situaciones en donde no se han podido elaborar modelos matemáticos que representen el comportamiento de la demanda, las Redes Neuronales Artificiales han mostrado su potencial para predecir o pronosticar la demanda futura; algunas aplicaciones exitosas se han dado en sectores como el de la aviación (Tang et al, 1991) para calcular el tráfico de pasajeros, o el de los servicios públicos para pronosticar la cantidad de energía eléctrica (Park y Sandberg, 1991; Bacha y Meyer 1992) o de agua (Lubero, 1991) que puede requerir una población.

Considerando lo expuesto anteriormente, ¿se podrá obtener un mejor pronóstico de la demanda de alimentos a producir en un restaurante institucional utilizando Redes Neuronales Artificiales, teniendo en cuenta los factores que la afectan?

2. OBJETIVOS

2.1 OBJETIVO GENERAL

Construir un modelo basado en Redes Neuronales Artificiales para el pronóstico diario de la demanda de alimentos en un restaurante institucional colombiano.

2.2 OBJETIVOS ESPECÍFICOS

- Determinar los factores que afectan el comportamiento de la demanda diaria de alimentos en un restaurante.
- Diseñar y simular un modelo basado en Redes Neuronales Artificiales para realizar el pronóstico de la demanda diaria en un restaurante institucional colombiano a partir de la información histórica de la demanda.
- Establecer el desempeño de la técnica propuesta en comparación a otros métodos tradicionales como solución para este tipo de problema.

3. ESTADO DEL ARTE

Al estar este proyecto de investigación enfocado en el desarrollo de un modelo para pronosticar la demanda, es conveniente hacer una breve revisión de los métodos clásicos de pronósticos, y los principales autores que han propuesto modelos o herramientas para predecir la demanda utilizando Redes Neuronales Artificiales.

3.1 MÉTODOS CLÁSICOS DE PRONÓSTICOS

En la tabla 1, Fitzsimmons (2006) presenta las principales características de los métodos más utilizados para pronosticar la demanda.

Tabla 1. Características de los métodos para pronosticar la demanda.

Método	Datos requeridos	Costo relativo	Horizonte del pronóstico
Regresión	Todos los datos del pasado de todas las variables	Moderado	Medio
Promedio Móvil	Las *n* más recientes observaciones	Muy bajo	Corto
Suavización Exponencial	El valor previo suavizado y la más reciente observación	Muy bajo	Corto

Fuente: Fitzsimmons (2006).

Se inicia con los modelos causales, los cuales cuando son utilizados para pronosticar la demanda, presentan la causa de ésta y su relación con otras variables (Shah, 2009). De este grupo sobresale el análisis de regresión lineal.

Esta es una técnica utilizada para realizar pronósticos en situaciones donde no se dispone de datos de la serie de tiempo (Anderson et al, 2004). El análisis de regresión lineal permite elaborar una ecuación matemática que muestre como se relaciona una variable dependiente, en este caso la demanda, con las variables independientes.

Otro tipo de modelos utilizados para el pronóstico de la demanda son las series de tiempo. De este grupo se destacan para el pronóstico de la demanda el uso del Promedio Móvil, el ARIMA, la Suavización Exponencial y el método Multiplicativo de Winters.

El Promedio Móvil se usa para estimar el promedio de una serie de tiempo de demanda, y por lo tanto, para suprimir los efectos de las fluctuaciones al azar (Krajewski y Ritzman, 2000). Esta técnica usa el promedio de los valores de *n* datos más recientes en la serie de tiempo como el pronóstico del siguiente período. El Promedio Móvil es muy útil cuando la demanda no tiene tendencias pronunciadas ni influencias estacionales, es decir, supone que las tendencias del mercado mantendrán cierta estabilidad a lo largo del tiempo (Render et al, 2006).

El ARIMA, desarrollado por Box y Jenkins (1976), es un método que tiene como principio básico asumir la linealidad entre las variables (Chen y Ou, 2009). Los coeficientes de autocorrelación identifican la asociación entre una variable en un período de tiempo con la misma variable en cualquier otro período de tiempo (Chase, 2009); a pesar de su éxito en la generación de pronósticos, esta técnica es la menos utilizada del grupo de las series de tiempo.

Por otra parte, Hirschey (2008) afirma que la Suavización Exponencial es un método que identifica patrones históricos de tendencia o estacionalidad en los datos y extrapola estos patrones hacia adelante en el período de pronóstico. Su precisión depende del grado en el que los patrones de cambio establecidos son evidentes y consistentes en el tiempo; este es el método más utilizado en la elaboración de pronósticos en los negocios.

El método Multiplicativo de Winters (1960) se aplica cuando una serie temporal muestra tendencia lineal y patrón estacional multiplicativo para el cual el nivel, la tasa de

crecimiento y el patrón estacional podrían ser cambiantes y no fijos (Bowerman et al, 2007). Este método es el más comúnmente utilizado en demanda estacional (Vidal, 2010).

Estas técnicas tradicionales han sido aplicadas por varios autores para pronosticar la demanda en restaurantes. Ryu et al (2003) compararon varios métodos como el Promedio Móvil, la Suavización Exponencial, el método Multiplicativo de Winters y la Regresión Lineal, para identificar cuál de éstos era más preciso al elaborar el pronóstico de la demanda en un restaurante universitario. Otros autores como Blecher (2004) y Zhan et al (2008), realizaron estudios comparativos similares en restaurantes con el fin de establecer la mejor técnica para pronosticar la demanda, obteniendo como resultado que la Suavización Exponencial fue la que presentó el mejor rendimiento.

3.2 REDES NEURONALES ARTIFICIALES

Adicional a los métodos descritos, existen otras técnicas consideradas no tradicionales (Nojek et al, 2003), entre los cuales se encuentran las Redes Neuronales Artificiales (RNA) (en inglés Artificial Neural Networks, ANN). Una RNA es una estructura computacional modelada en base a procesos biológicos (Adya y Collopy, 1998), que busca reproducir el esquema neuronal, tanto en sus unidades de proceso, las neuronas, como en sus conexiones y modos de establecerlas (Pino et al, 2001).

Una de las mayores aplicaciones de las RNA es la elaboración de pronósticos (Sharda, 1994), debido a que proveen a los investigadores y pronosticadores una herramienta que, contrario a los modelos basados en métodos tradicionales, utiliza métodos auto-adaptativos basados en datos en los que se establecen algunas suposiciones a priori acerca del problema (Zhang et al, 1998).

Algunos autores han utilizado las RNA para realizar pronósticos en diferentes sectores como el energético para el cálculo de la carga por hora de un sistema eléctrico (Srinivasan et al, 1994; Beccali et al, 2004) y el precio de la energía eléctrica (Villada et al, 2008), el financiero para predecir la tasa de cambio semanal y mensual (Hann y Steurer 1996), o inclusive el educativo para pronosticar la calificación promedio de un estudiante (Gorr et al, 1994).

Otros autores han planteado modelos basados en RNA para el pronóstico de la demanda y comparado sus resultados en relación a las predicciones obtenidas mediante el uso de algunos métodos clásicos (Nojek et al, 2003; Zhang et al, 2005; Mena et al, 2006; Hamzaçebi, 2008; Castaño et al, 2009). Por otra parte, autores como Salazar et al (2006), así como Khashei y Bijari (2010), han planteado modelos donde integran las RNA con métodos clásicos para la elaboración del pronóstico de la demanda. De igual manera, Ghiassi et al (2005), así como Vera y Bustamante (2007), propusieron modelos dinámicos de RNA para predecir la demanda.

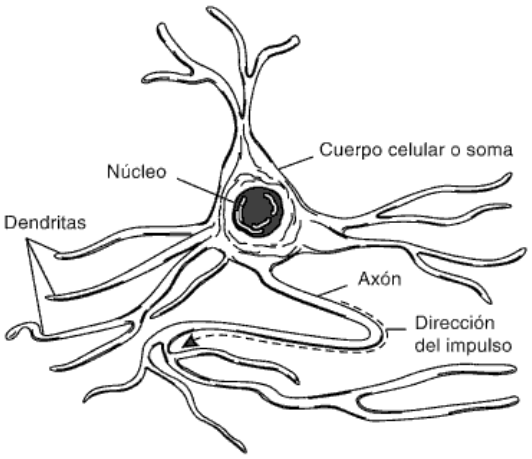
Respecto al uso de las RNA para pronosticar la demanda en restaurantes, algunos autores han propuesto la utilización de sistemas expertos basados en RNA y Lógica Difusa. Sánchez et al (1995) desarrollaron un sistema experto para predecir la demanda en un restaurante universitario y compararon su desempeño respecto al obtenido con el uso de las técnicas tradicionales. Por su parte, autores como Doganis et al (2006), así como Chen y Ou (2009), han propuesto modelos para el pronóstico de artículos perecederos utilizando RNA, y en algunos casos combinándolos con otras técnicas como los Algoritmos Genéticos. Estos estudios obtuvieron como resultado que los modelos basados en RNA presentaron un mejor rendimiento que los métodos clásicos de pronósticos.

4. MARCO TEÓRICO

No se justifica hacer una discusión de las teorías que ya han sido ampliamente tratadas por otros autores respecto a los métodos clásicos de pronósticos. El enfoque teórico de este estudio son las Redes Neuronales Artificiales (RNA), las cuales son importantes para esta investigación, ya que su uso permite desarrollar aplicaciones para la solución de problemas complejos.

Las RNA son metodologías computacionales que realizan cálculos multifactoriales (Dayhoff y DeLeo, 2001). Estas redes tienen su origen en el concepto de neurona artificial introducido por McCulloch y Pitts (1943), basado en supuestos acerca de la forma de trabajar de la neurona biológica y cuya estructura se observa en la figura 1.

Figura 1. La neurona biológica.



Fuente: Bustamante (2007).

Los modelos de RNA contienen capas de nodos (neuronas) de computación simple que operan como dispositivos adicionadores. Estos nodos están ricamente interconectados por líneas de conexión ponderadas y los pesos se ajustan cuando se presentan los datos a la red durante el proceso de entrenamiento.

La estructura que determina el funcionamiento de estas 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 y Fernández, 2008; Caicedo y 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

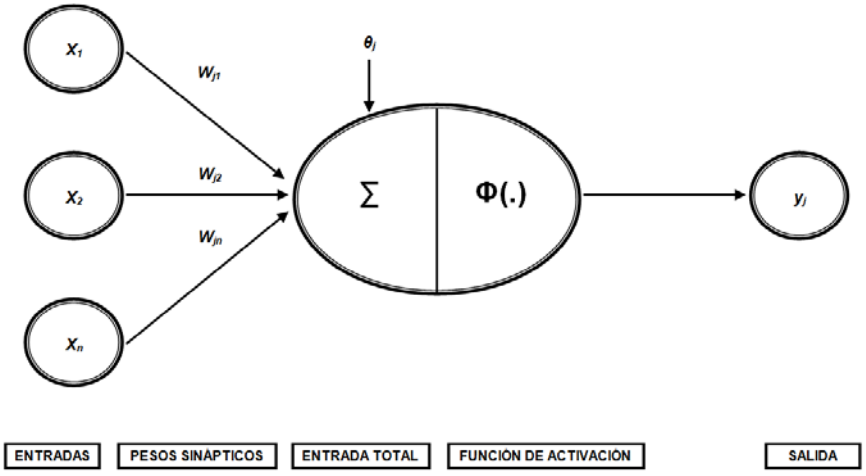
$\theta_j \; o \; Bias_j$ → valor propio de tendencia de la neurona j

$\sum o \; Net_j$ → sumatoria del producto de los valores de entrada y los pesos sinápticos, más el $Bias$ en la neurona j

$\phi(.)_j$ → función de activación en la neurona j

y_j → valor de salida de la neurona j

Figura 2. Estructura básica de una Red Neuronal Artificial.



Fuente: Adaptado de Caicedo y López (2009).

En los últimas seis décadas, las RNA han evolucionado desde el desarrollo preliminar de la neurona artificial, a través del redescubrimiento y la popularización del algoritmo de

entrenamiento Backpropagation, hasta la aplicación de RNA utilizando hardware dedicado (Yang, 2009).

A continuación se describen en detalle los principales conceptos en los que se basa el funcionamiento de las RNA.

4.1 ARQUITECTURA

La arquitectura de una RNA es la forma como se organizan las neuronas en su interior, la cual se define con base al número de capas que posea la red (monocapa y multicapa) o a la forma como fluye la información a través de ésta (unidireccionales y recurrentes).

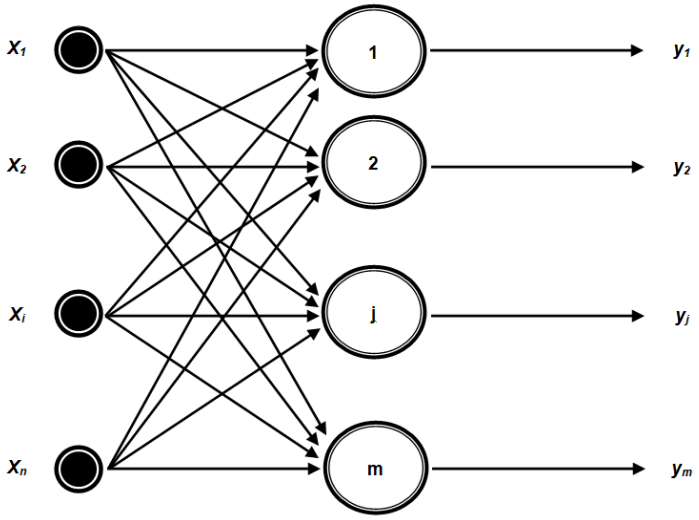
En las redes unidireccionales (en inglés Feedforward) la información fluye en una única dirección a través de las conexiones de la red; desde las neuronas de la capa de entrada, pasando por la(s) capa(s) de procesamiento hasta la capa de salida, sin ciclos de retroalimentación (Caicedo y López, 2009).

De otra forma, en las redes recurrentes la información no siempre fluye en la misma dirección, debido a que ésta puede retroalimentarse en capas anteriores a través de conexiones sinápticas. La presencia de bucles de retroalimentación en esta arquitectura, generan incremento en la capacidad de aprendizaje y el rendimiento de la RNA.

Según lo planteado por Haykin (2005), se pueden identificar tres clases fundamentales de arquitecturas de RNA: las redes unidireccionales monocapa, las redes unidireccionales multicapa y las redes recurrentes.

Las redes unidireccionales monocapa solo disponen de una capa de procesamiento encargada de recibir la información de las neuronas de la capa de entrada, y transfiere los datos procesados a la capa de salida; tal como se muestra en la figura 3. En este tipo de arquitectura no se realizan procesos de computación en la capa de entrada, ya que esta únicamente sirve de interfaz entre los datos de entrada y las siguientes capas de neuronas.

Figura 3. Red Neuronal Artificial unidireccional monocapa.

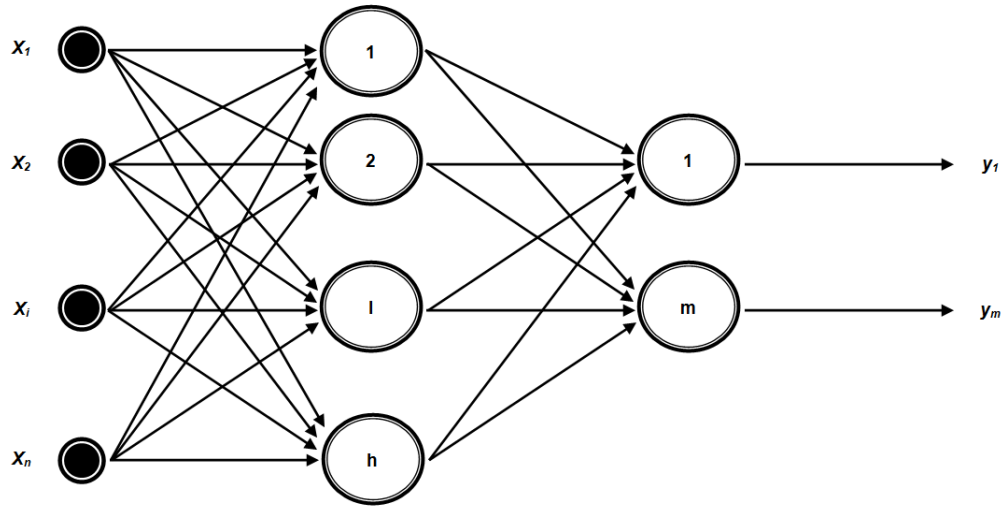


Fuente: Adaptado de Caicedo y López (2009).

Por otra parte, las redes unidireccionales multicapa incluyen una o varias capas intermedias llamadas capas ocultas que se encargan del procesamiento y transmisión de la información entre las capas de entrada y la salida de la red, con las cuales no tiene una relación directa pero sí total conectividad; esto significa, que todas las neuronas de una capa cualquiera están interconectadas con todas las neuronas de la capa previa y la siguiente, tal como se observa en la figura 4. Las redes multicapa son las más utilizadas en pronósticos debido a su capacidad inherente de asignar de forma arbitraria entradas a una salida.

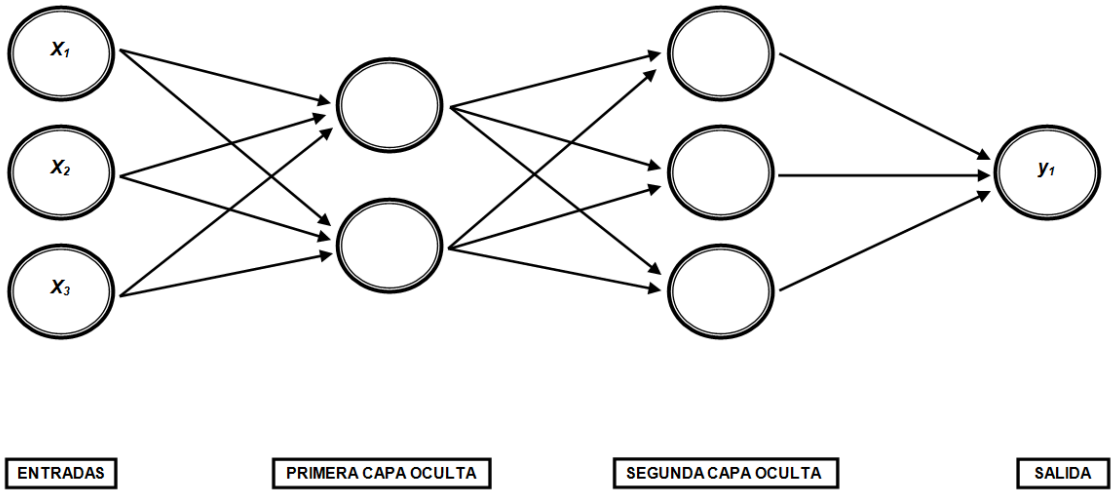
Dentro de este tipo de arquitectura se encuentra el Perceptrón Multicapa (en inglés Multilayer Perceptron, MLP). Esta red combina el modelo propuesto por Rosenblatt (1958), con la estructura de las redes multicapa que plantean la implementación de capas ocultas; su estructura básica se presenta en la figura 5. Rosenblatt diseñó y desarrolló el modelo de red neuronal que denominó Perceptrón, el cual tiene un nivel de entrada encargado de recibir la información del exterior y un nivel de salida que realiza el procesamiento de los datos entregados por el nivel inicial, con el fin de generar la salida de la red neuronal; este sistema es capaz de asociar unas entradas dadas a una salida determinada.

Figura 4. Red Neuronal Artificial unidireccional multicapa.



Fuente: Adaptado de Caicedo y López (2009).

Figura 5. Perceptrón Multicapa para tres variables de entrada, con dos nodos en la primera capa oculta y tres en la segunda.



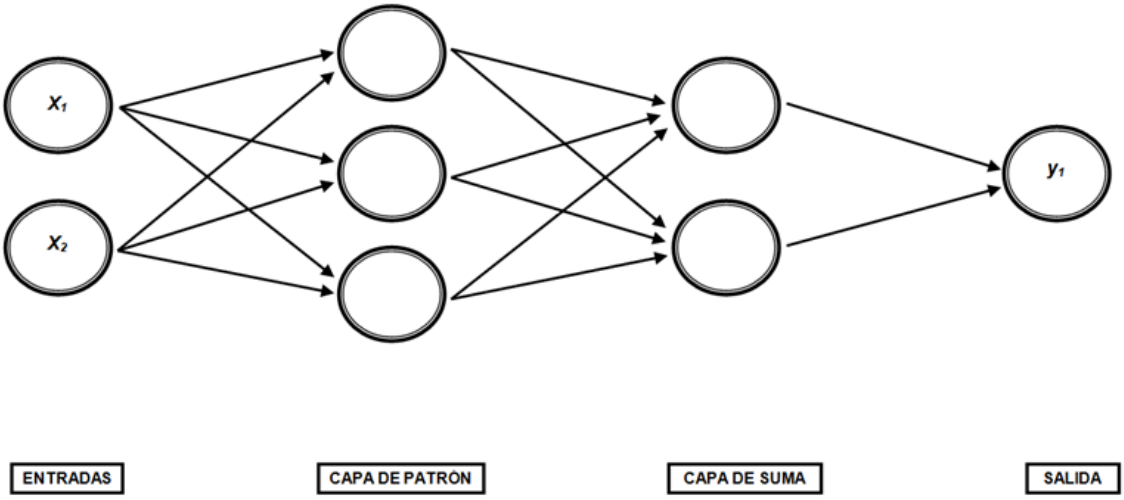
Fuente: Adaptado de Flórez y Fernández (2008).

Algunas de las ventajas que ofrecen las MLP son el permitir hacer predicciones más rápidamente, presentar 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 y tener la capacidad de generalizar a partir de conjuntos de entrenamiento muy pequeños (Bazán, 2012).

Así mismo, en el grupo de las redes unidireccionales multicapa se destacan las Redes de Regresión Generalizada (en inglés Generalized Regression Network, GRN), las cuales se usan para aproximación de predicciones y funciones numéricas. Este tipo de redes fueron presentadas por Specht (1991), y posteriormente estudiadas por Masters (1995). La estructura básica de las GRN se representa en la figura 6.

Figura 6. Red de Regresión Generalizada para dos variables de entrada con tres casos de patrón en el entrenamiento.



Fuente: Adaptado de Specht (1991).

Las GRN cuentan con dos capas de procesamiento definidas: la capa de patrón y la capa de suma. La primera contiene una neurona por cada caso de entrenamiento (Bishop, 1995; Masters, 1995), que calcula su distancia con el caso presentado utilizando “factores de suavización”. Los valores calculados en la capa de patrón se transfieren a los dos nodos de la capa suma, el numerador y denominador, que son funciones de la distancia y del valor dependiente. Estos nodos suman sus valores de entrada, y al ser pasados al nodo de salida este los divide para generar la predicción.

Las ventajas que ofrecen este tipo de redes 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 sólo trabajan con salidas numéricas (Bazán, 2012).

4.2 FUNCIÓN DE ACTIVACIÓN O TRANSFERENCIA

La función de activación es usada para convertir los valores de entrada de cada neurona en su valor de salida (Flórez y Fernández, 2008; Lahoz-Beltrá, 2004). Para esto, primero cada neurona de la(s) capa(s) de procesamiento calcula una suma clasificada de sus valores de entrada:

$$Net = in_0 * w_0 + in_1 * w_1 + \cdots + in_n * w_n + Bias$$

donde, $in_0, \dots, in_n$ → valores de salida de las neuronas de la capa anterior

$w_0, \dots, w_n$ → valores de los pesos sinápticos

$Bias$ → valor propio de tendencia de cada neurona

Finalmente, a este resultado obtenido se aplica la función de activación con el fin de generar el valor de salida de la neurona. La figura 7 presenta las funciones de activación más utilizadas en la implementación de las RNA.

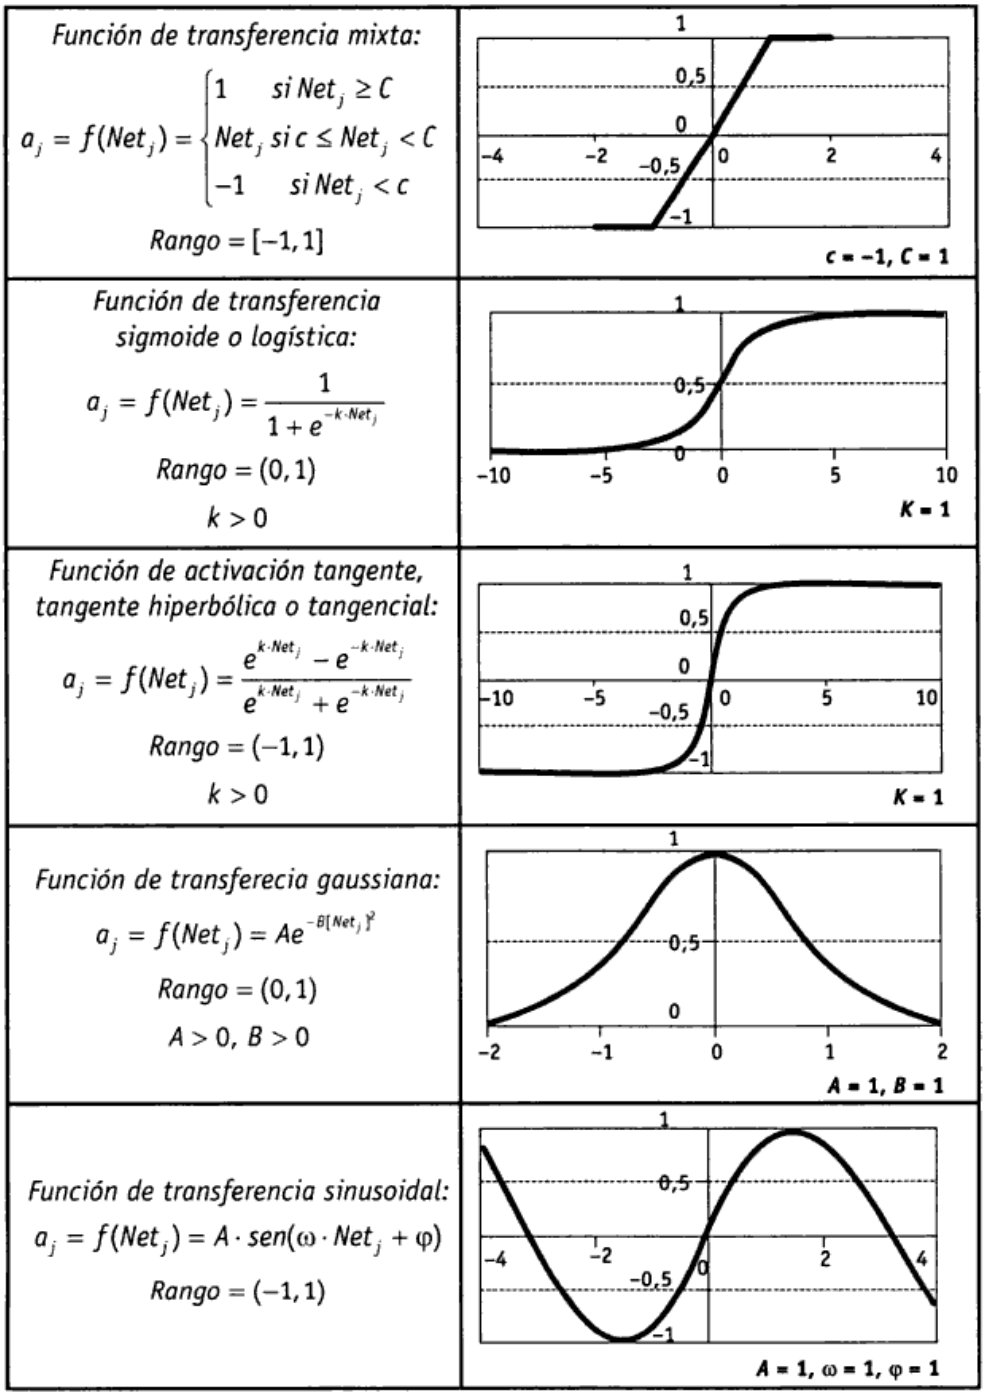
4.3 PROCESO DE APRENDIZAJE

Las RNA tienen la habilidad de aprender del entorno y mejorar su desempeño a través del ajuste de sus pesos sinápticos, y es aquí donde el entrenamiento de la red toma gran importancia. El proceso de aprendizaje o entrenamiento de las RNA puede ser de dos tipos: supervisado y no supervisado.

El aprendizaje supervisado consiste en ir ajustando los pesos gradualmente hasta que la diferencia entre el vector de salida resultante y el vector de salida esperado sea mínima. En este tipo de aprendizaje se parte de un vector de entrada, del cual se tiene

conocimiento de su vector de salida o al menos una aproximación de él, conocido como par de entrenamiento (Caicedo y López, 2009).

Figura 7. Principales tipos de funciones de activación.



Fuente: Flórez y Fernández (2008).

Por otra parte, en el aprendizaje no supervisado se desconoce el vector de salida y se dispone únicamente de un vector de entrada. En este tipo de aprendizaje se buscan por medio de diferentes vectores de entradas, salidas consistentes; es decir, que entradas similares producirán el mismo tipo de salida. Los pesos se van ajustando poco a poco a través del reconocimiento de patrones, regularidades, propiedades estáticas, entre otros.

Dentro de los algoritmos utilizados para el entrenamiento de las RNA se encuentran el Backpropagation y el Gradiente Conjugado. Ambos métodos están basados en el Gradiente Descendente, propuesto originalmente por Cauchy en 1847 y constituye uno de los métodos de optimización de funciones multivariantes más antiguos y conocidos (Flórez y Fernández, 2008). Este método busca obtener una aproximación lineal de la función de error a través de la expresión:

$$E(w + \Delta w) \approx E(w) + \Delta w^T E'(w),$$

de forma que los pesos se actualizan mediante:

$$\Delta w = -\alpha E'(w), \alpha > 0$$

donde, α → tasa de aprendizaje

$0 < \alpha \leq 1$

En el algoritmo del Gradiente Conjugado se desarrolla una búsqueda alrededor de la "Dirección Conjugada", produciendo, generalmente, una convergencia más rápida que la dirección del Gradiente Descendente (Bishop, 1995; Masters, 1995; Caicedo y López, 2009). La potencia de este método radica en minimizar la función de error en una dirección que es conjugada a la dirección previa, es decir, intenta conseguir direcciones de búsqueda que no interfieran con las realizadas en las iteraciones anteriores.

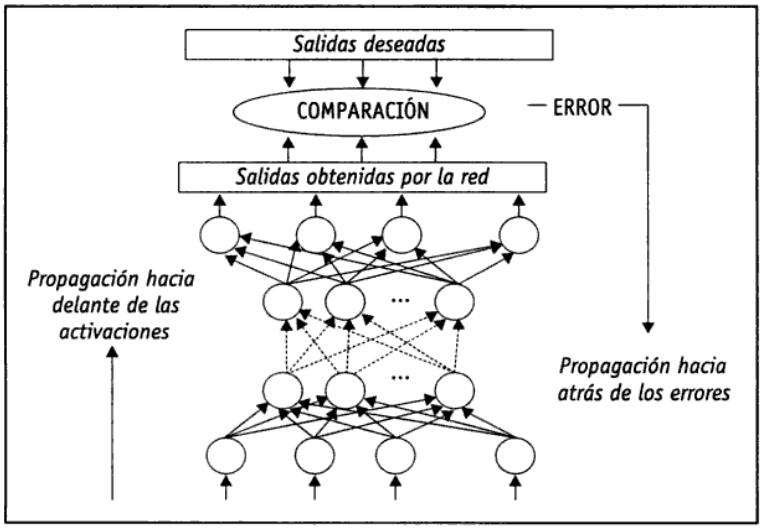
Desarrollado por Werbos (1974), el Backpropagation busca minimizar el error cuadrático total en la salida computada de la red, por medio del descenso del gradiente. El método consiste en el aprendizaje de un conjunto predefinido de patrones de entrada-salida,

empleando un ciclo de “propagación-adaptación” con dos fases (Flórez y Fernández, 2008).

La primera es la fase de aprendizaje “hacia adelante”, donde los patrones ingresados a la red estimulan todas las capas posteriores hasta generar una salida. En la segunda fase, o fase de aprendizaje “hacia atrás”, se compara el resultado obtenido en la fase inicial con la salida esperada, para lo cual se calcula el error para cada neurona de la última capa. El valor obtenido se transmite a cada una de las neuronas de la(s) capa(s) de procesamiento, y de acuerdo a la participación de cada una de estas en el error, se ajustan sus pesos sinápticos. Este proceso se realiza iterativamente hasta minimizar el error de la red.

El Backpropagation, cuyo esquema se presenta en la figura 8, es actualmente el método más utilizado en las arquitecturas multicapa (Caicedo y López, 2009). Esta afirmación se confirma en el estudio realizado por Adya y Collopy (1998) en el que se llegó a la conclusión que de 48 modelos evaluados para la elaboración de pronósticos, el 88% de estos lo utilizan como algoritmo de aprendizaje.

Figura 8. Esquema del algoritmo Backpropagation.



Fuente: Flórez y Fernández (2008).

Una vez ha sido entrenada la red, ésta se encuentra lista para su operación, por lo que es necesario usar algún conjunto de prueba que no haya sido utilizado en la etapa de entrenamiento con el fin de evaluar su desempeño (Toro et al, 2004).

Para este proyecto de investigación las RNA son importantes, porque nos permite a partir de una información de entrada, sacada de unos datos históricos, poder construir un modelo para pronosticar la demanda en un restaurante institucional, donde la serie es no lineal y discontinua. Esto será objeto de estudio en el próximo capítulo.

5. PROCESO METODOLÓGICO

En este capítulo se describe el caso de estudio abordado a lo largo de este proyecto. Así mismo, se analizan los factores que influyen en el comportamiento de la demanda diaria, los cuales serán el insumo principal del modelo de RNA que se propone como solución del problema planteado en el *capítulo 1*. Este modelo se simuló mediante el uso de software especializados y los resultados son comparados con los obtenidos a través de la aplicación de los métodos clásicos de pronósticos.

5.1 CASO DE ESTUDIO

El objeto de estudio de esta investigación es el restaurante adscrito a la Vicerrectoría de Bienestar Universitario (VBU) de la Universidad del Valle (UV).

El restaurante universitario cuenta con tres comedores en la sede Meléndez (edificio 389) y un punto de servicio en la sede San Fernando (Plazoleta de Salud), para prestar el servicio de almuerzo a estudiantes y empleados (Bienestar UV, 2012) de lunes a viernes entre las 11:30 am y las 2:30 pm. En San Fernando, debido a la limitada infraestructura que se tiene, el servicio también es ofrecido mediante un proveedor externo a través de un convenio realizado con éste.

De acuerdo al portafolio de servicios de la VBU, el restaurante posee una infraestructura física y operativa para atender máximo 4.500 almuerzos diarios en ambas sedes (Bienestar UV, 2012). Lo anterior implica que, a pesar de que los 27.094 estudiantes y los 2.170 empleados de la universidad (Planeación UV, 2011) tienen derecho a almorzar diariamente en el restaurante (Consejo Superior UV, 1997), realmente sólo un 16% de éstos aproximadamente podrían hacer uso de este servicio cada día.

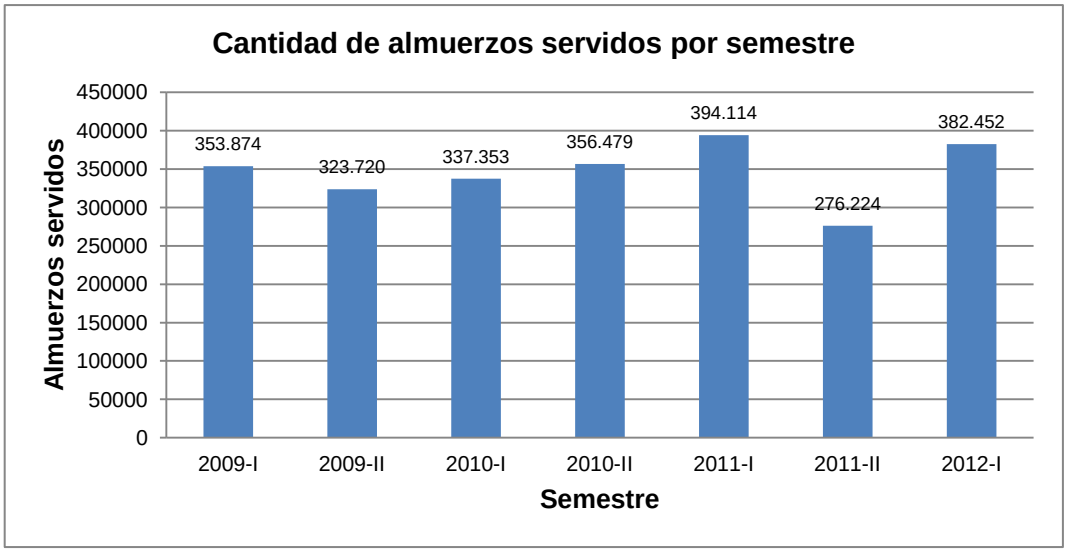
Las políticas de la VBU establecen que “el servicio de restaurante universitario tiene como misión promover la posibilidad de acceder a un almuerzo suficiente y nutricionalmente adecuado con los macro y micronutrientes para el desarrollo de la salud y el intelecto del individuo” (Bienestar UV, 2012). Debido a esto, el grupo encargado de la planeación del

restaurante, semestralmente organiza los menús que se prepararán diariamente durante cada semana, teniendo en cuenta los requerimientos nutricionales dispuestos en la normativa.

Cada menú de almuerzo que se elabora está compuesto por seis elementos: sopa, carne, principio, arroz, ensalada y jugo. Para su respectiva preparación, el restaurante compra los insumos necesarios a través de la Bolsa Agropecuaria (Consejo Superior UV, 2006); lo anterior puede acarrear que durante ciertas épocas los menús deban ser ajustados, al tener que utilizar para la elaboración de los almuerzos, alimentos que se encuentren en temporada.

Durante los últimos siete semestres, entre el 13 de enero del 2009 y el 15 de junio del 2012, el restaurante universitario prestó su servicio durante 622 días, en los cuales sirvió a sus usuarios 2.424.216 almuerzos. La figura 9 registra la cantidad de almuerzos servidos durante estos periodos.

Figura 9. Cantidad de almuerzos servidos por cada semestre.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Lo expuesto anteriormente, describe las principales características del caso de estudio de este proyecto de investigación, el cual será abordado a lo largo de este documento.

5.2 ANÁLISIS DE LOS FACTORES QUE AFECTAN LA DEMANDA DIARIA

Para la realización de este estudio, y con el fin de analizar y definir los factores que influyen en el comportamiento de la demanda diaria, se solicitó a la dirección del restaurante universitario información de la cantidad de almuerzos servidos durante los últimos años y los menús elaborados durante los respectivos períodos.

El grupo técnico encargado del manejo de los datos, bajo la aprobación de las directivas del restaurante, suministró a los investigadores la información recolectada durante los dos semestres de los años 2009, 2010, 2011 y el primer semestre del 2012.

Los datos proporcionados incluyen el número de almuerzos servidos (demanda) por el restaurante universitario durante cada día de cada mes de los respectivos períodos de forma consolidada y discriminada por estamentos (grupo de usuarios de la UV, estudiantes y empleados) y por sedes. La cantidad de días (registros) en los cuales el restaurante ofreció el servicio a sus usuarios, durante cada período, se presenta en la tabla 2.

Tabla 2. Cantidad de registros de demanda diaria por cada semestre.

	2009-I	**2009-II**	**2010-I**	**2010-II**	**2011-I**	**2011-II**	**2012-I**	**Total**
Número de registros	98	74	88	82	104	78	98	**622**

Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

De igual manera, fue suministrada la programación de los menús elaborados diariamente en los diferentes períodos. En ella se describe mediante un código definido previamente

por el restaurante universitario, para cada elemento del almuerzo, el tipo de preparación que se elaboró el respectivo día; estos datos se encuentran organizados por semanas para cada mes del semestre. Un ejemplo de la programación, se presenta en la tabla 3.

Tabla 3. Programación de menús para la semana del 20 al 24 de febrero del 2012.

Preparación	Lunes 20		Martes 21		Miércoles 22		Jueves 23		Viernes 24	
	Cód.	Menú	Cód.	Menú	Cód.	Menú	Cód.	Menú	Cód.	Menú
Sopa	115	Frita	108	De cuchuco	114	Frijoles	138	De verduras	190	Crema de champiñones
Arroz	201	Blanco	201	Blanco	201	Blanco	201	Blanco	201	Blanco
Carne	209	Filete de pollo	218	Pescado	299	Chorizo de cerdo	232	Asada	261	Pernil de cerdo en salsa roja
Principio	310	Papa al vapor	340	Yuca frita	316	Tajadas	301	Arveja guisada	312	Papas a la francesa
Ensalada	429	Lechuga	439	Repollo	402	Dorada	427	Tomate campestre	419	Especial
Jugo	508	Mora	507	Maracuyá	512	Lulo	520	Mandarina	513	Uva

Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

El grupo técnico también proporcionó un listado de las preparaciones de cada uno de los elementos que componen el almuerzo. La tabla 4 presenta una muestra del listado.

Toda esta información, suministrada por el restaurante universitario al grupo investigador, se organizó y consolidó en una base de datos, con el fin de tener una herramienta que permitiera consultarla y analizarla de una forma más fácil y rápida. Una muestra de la información consolidada es presentada en la tabla 5.

Tabla 4. Muestra del listado de preparaciones.

Código	Nombre de la preparación	Tipo
101	Sopa de arroz	Sopa
102	Crema de pollo	Sopa
103	Sopa de arveja	Sopa
114	Sopa de frijoles	Sopa
115	Sopa frita	Sopa
201	Arroz blanco	Arroz
207	Carne sudada	Carne
211	Chuleta de cerdo	Carne
215	Pollo al limón	Carne
218	Pescado a la plancha	Carne
221	Pollo al horno	Carne
306	Maduro al horno	Principio
309	Papa guisada	Principio
314	Puré de papa	Principio
316	Tajadas de maduro	Principio
321	Yuca guisada	Principio
405	Habichuelas guisadas	Ensalada
412	Repollo y zanahoria	Ensalada
415	Tomate en rebanadas	Ensalada
429	Lechuga, cebolla y pepino	Ensalada
443	Repollo morado y blanco	Ensalada
507	Jugo de maracuyá	Jugo
508	Jugo de mora	Jugo
509	Jugo de naranja	Jugo
512	Jugo de lulo	Jugo
514	Jugo de mango	Jugo

Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Tabla 5. Muestra de los datos consolidados.

			Demanda			Código de cada preparación del menú					
Fecha	**Día semana**	**Época período**	**Estudiantes**	**Empleados**	**Total**	**Sopa**	**Arroz**	**Carne**	**Principio**	**Ensalada**	**Jugo**
13/01/2009	Martes	Inicio	119	596	715	115	201	288	310	476	508
14/01/2009	Miércoles	Inicio	131	668	799	153	201	248	341	404	513
15/01/2009	Jueves	Inicio	155	666	821	114	201	299	325	401	501
16/01/2009	Viernes	Inicio	155	575	730	124	201	221	364	415	507
19/01/2009	Lunes	Inicio	189	633	822	156	201	209	370	476	505
20/01/2009	Martes	Inicio	198	657	855	117	201	232	316	402	511
21/01/2009	Miércoles	Inicio	174	679	853	138	201	271	303	412	509
22/01/2009	Jueves	Inicio	194	679	873	101	201	215	363	423	521
23/01/2009	Viernes	Inicio	193	601	794	190	201	264	406	406	512
26/01/2009	Lunes	Inicio	228	652	880	156	201	288	313	469	520
27/01/2009	Martes	Inicio	247	688	935	114	201	248	325	412	507
28/01/2009	Miércoles	Inicio	282	644	926	138	201	266	324	443	505
29/01/2009	Jueves	Inicio	242	682	924	144	201	234	316	476	512
02/02/2009	Lunes	Inicio	263	650	913	101	201	221	308	476	508
03/02/2009	Martes	Inicio	286	667	953	153	201	256	325	423	505
04/02/2009	Miércoles	Inicio	295	691	986	114	201	299	306	425	501
05/02/2009	Jueves	Inicio	304	689	993	102	201	288	312	443	512
06/02/2009	Viernes	Inicio	286	557	843	124	201	203	340	427	509
09/02/2009	Lunes	Clases	2.195	700	2.895	121	201	232	324	404	507
10/02/2009	Martes	Clases	3.314	676	3.990	117	201	248	341	439	520
11/02/2009	Miércoles	Clases	1.619	484	2.103	144	201	209	364	415	512
12/02/2009	Jueves	Clases	3.637	675	4.312	108	201	221	350	429	513
13/02/2009	Viernes	Clases	3.638	649	4.287	114	201	271	316	412	501
16/02/2009	Lunes	Clases	3.387	679	4.066	156	201	221	325	430	508

Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Con base en estos datos y apoyados en la opinión de los expertos, se plantearon algunos interrogantes que permitieran identificar los factores que tienen un fuerte impacto en el comportamiento de la demanda diaria. Estos son:

- ¿El comportamiento de la demanda varía durante las diferentes épocas del semestre?

- ¿Hay alguna diferencia en el comportamiento de la demanda de los estudiantes respecto a la de los empleados?
- ¿El día de la semana influye en el incremento o disminución de la demanda?
- ¿Existe alguna preferencia o rechazo de los usuarios por algún tipo de preparación? Por ejemplo, ¿hay mayor demanda cuando se preparan frijoles que cuando se prepara pescado? ¿Influye el tipo de carne utilizada en el menú?

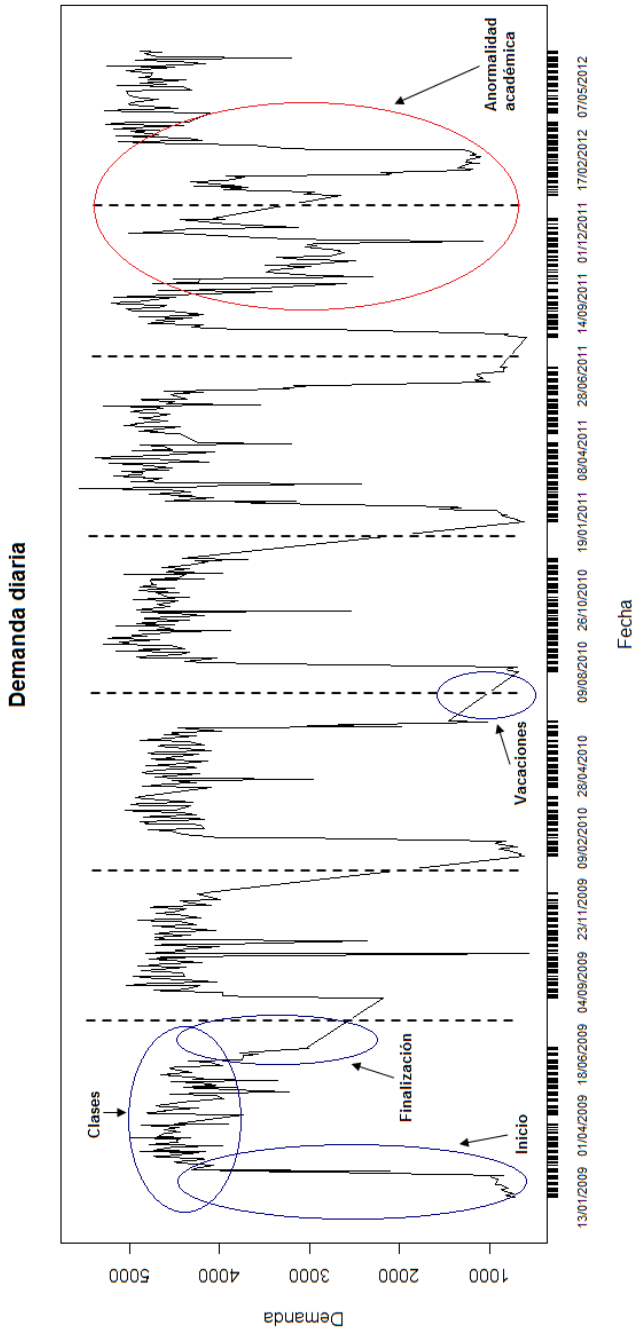
Para dar respuesta a los anteriores interrogantes se realizó un análisis estadístico, se graficaron los valores de la demanda diaria y se calcularon sus principales estadísticos descriptivos, los cuales se presentan en la figura 10 y la tabla 6.

En la figura, se identifican tres épocas diferentes durante cada semestre:

- Inicio: época del período en el cual inicia el semestre y la asistencia de los estudiantes al restaurante universitario es prácticamente poca o nula; debido a que es el momento entre el regreso de las vacaciones por parte de los empleados y el comienzo de las clases.
- Clases: época de mayor actividad de los estudiantes en el restaurante, ya que es cuando se desarrolla la temporada académica.
- Finalización: época donde las clases han finalizado oficialmente y se acerca el inicio del período de vacaciones, por lo cual disminuye considerablemente la cantidad de usuarios, principalmente por parte de los estudiantes, que asisten a almorzar al restaurante.

Esto permitió observar que durante el segundo semestre del año 2011 y el inicio del primer semestre del 2012, la demanda tiene un comportamiento diferente a los demás periodos. Esto se debe a las dificultades que se presentaron en la UV a causa del Proyecto de Reforma Educativa o Reforma a la Ley 30 presentado por el Ministerio de Educación Nacional de la República de Colombia (El Espectador, 2011; La Silla Vacía, 2011). Durante este tiempo se vivió inestabilidad en la universidad por los diferentes paros y manifestaciones realizadas por parte la comunidad académica como medida de protesta frente a este proyecto del Gobierno, lo que afectó el número de usuarios diarios que hicieron uso del servicio de almuerzo del restaurante universitario.

Figura 10. Comportamiento de la demanda diaria.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Tabla 6. Estadísticos descriptivos de la demanda diaria por semestre.

Semestre	Mínimo	Máximo	Media		Desv. Est.	Varianza	Asimetría		Curtosis	
	Estadístico	Estadístico	Estadístico	Error típico	Estadístico	Estadístico	Estadístico	Error típico	Estadístico	Error típico
2009-I	715	4.996	3.610,96	140,138	1.387,293	1.924.581,936	-1,308	0,244	0,090	0,483
2009-II	564	5.036	4.374,59	74,940	644,656	415.580,820	-3,834	0,279	18,562	0,552
2010-I	613	5.048	3.833,56	152,712	1.432,565	2.052.242,181	-1,495	0,257	0,560	0,508
2010-II	679	5.295	4.347,30	111,425	1.008,997	1.018.075,276	-2,861	0,266	7,873	0,526
2011-I	614	5.560	3.789,56	148,776	1.517,226	2.301.975,472	-1,096	0,237	-0,387	0,469
2011-II	590	5.198	3.541,33	147,841	1.305,695	1.704.840,563	-0,919	0,272	-0,060	0,538
2012-I	1.098	5.279	3.902,57	138,482	1.370,899	1.879.365,072	-1,135	0,244	-0,224	0,483

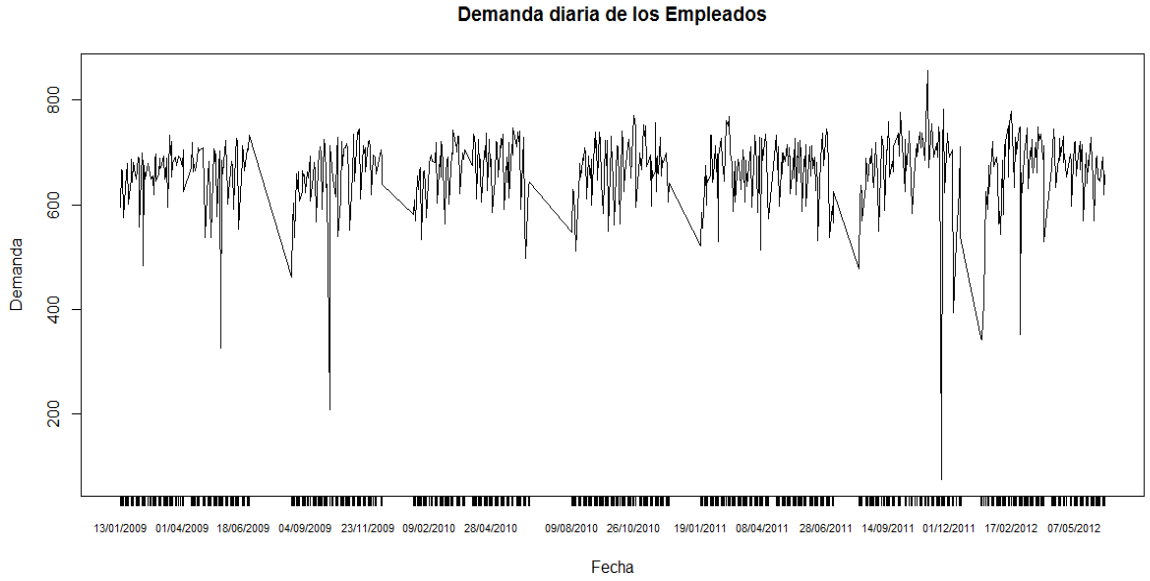
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Con base en lo anterior, se consideran la época del semestre y la fecha como factores que influyen en la forma como se comporta la demanda.

Así mismo, se analizó el comportamiento de la demanda diaria de los estudiantes y los empleados; los resultados obtenidos se presentan en las figuras 11-13. En ellas se observa que a diferencia de la demanda de los estudiantes, donde, al igual que la demanda total, se presentan tres épocas durante los semestres, la demanda de los empleados presenta un patrón de comportamiento perpetuo o uniforme en el tiempo. Lo anterior se explica en que los empleados asisten al restaurante universitario durante todo el periodo, mientras que los estudiantes lo hacen principalmente durante la época de clases.

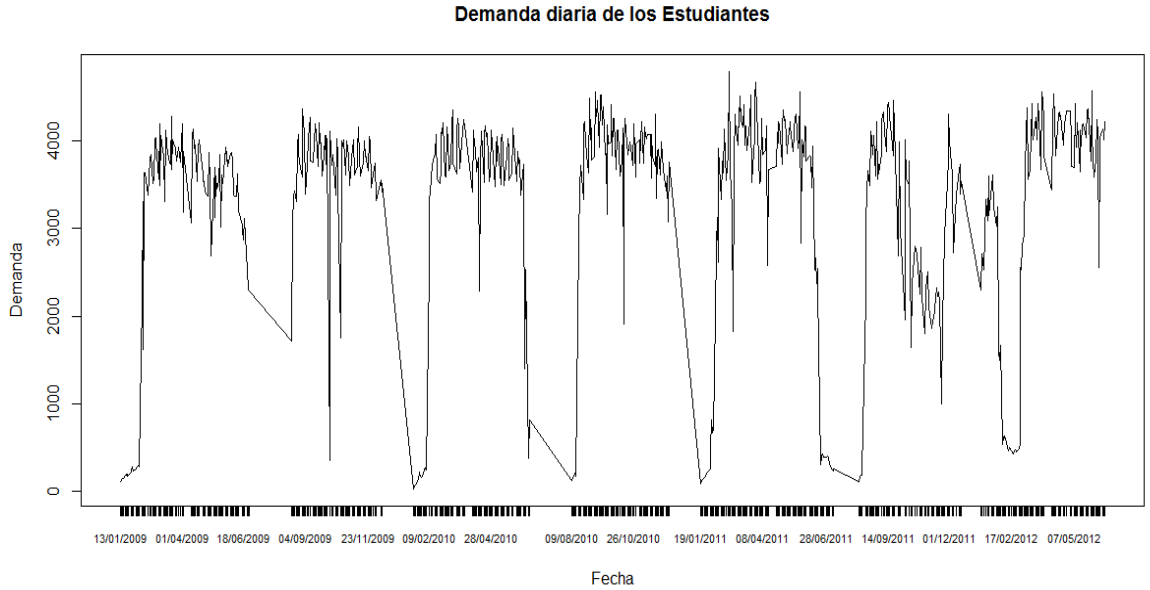
Dado que, la variable en estudio que se desea pronosticar es la demanda diaria total, el tipo de usuario no se consideró como un factor que influya en el comportamiento de la serie.

Figura 11. Comportamiento de la demanda diaria de los empleados.



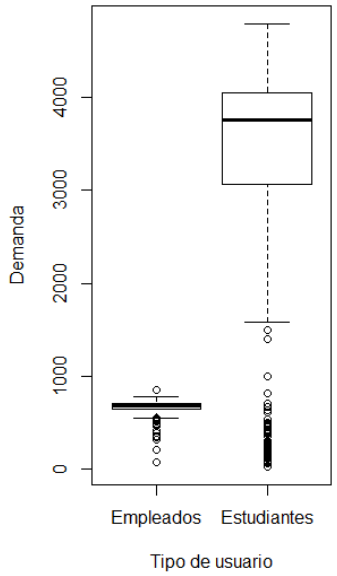
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 12. Comportamiento de la demanda diaria de los estudiantes.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 13. Boxplot de la demanda según el tipo de usuario.

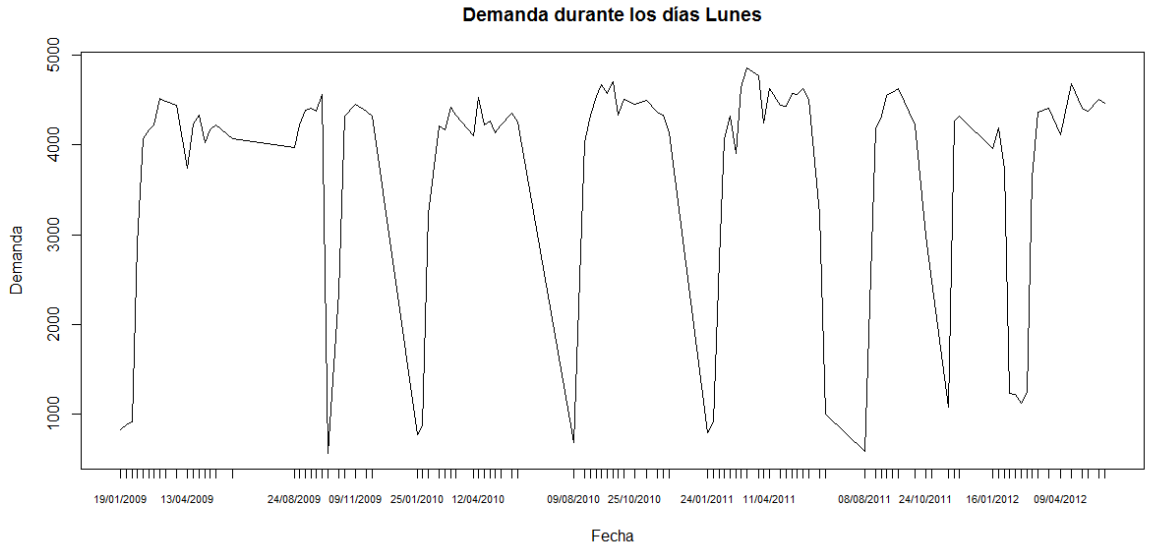


Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Por otra parte, se realizó un análisis sobre el impacto que puede tener el día de semana sobre la demanda; esto debido a que al observar durante varias semanas el flujo de usuarios en el restaurante universitario y teniendo en cuenta la experiencia de los expertos, se pudo percibir que en algunos días el número de personas que hacían fila para almorzar era mayor que en otros. Los resultados obtenidos se presentan en las figuras 14-19.

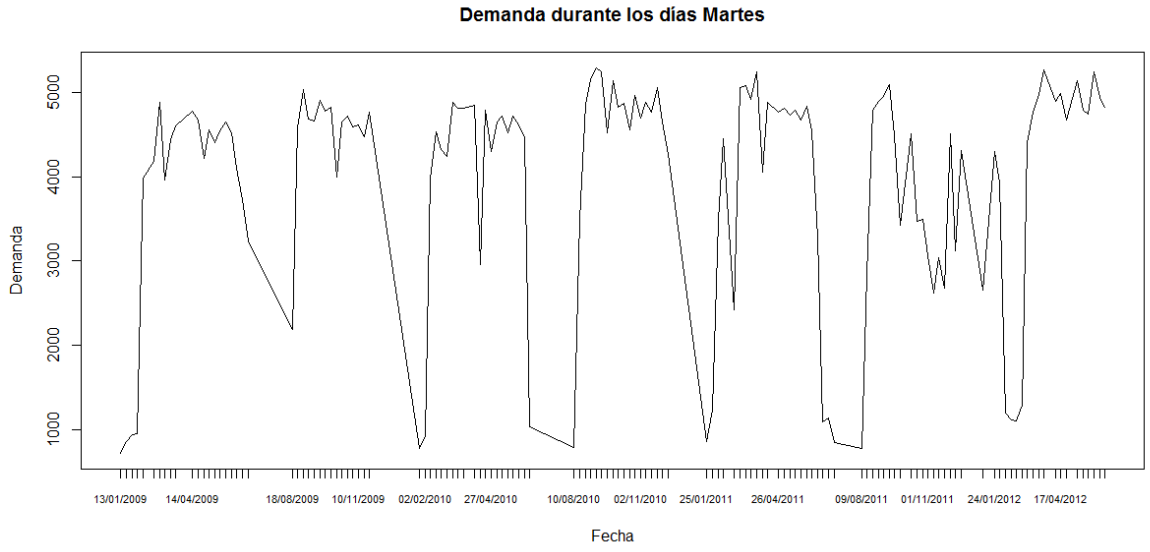
Estas figuras muestran que durante los días lunes y viernes, el promedio de la demanda es menor a la que se presenta en los días martes, miércoles y jueves. Sin embargo, en estos últimos días se observa una mayor variabilidad respecto a los otros. Esto indica que el día de la semana afecta la demanda diaria y se puede considerar como un factor que influye en su comportamiento.

Figuras 14. Comportamiento de la demanda durante los días lunes.



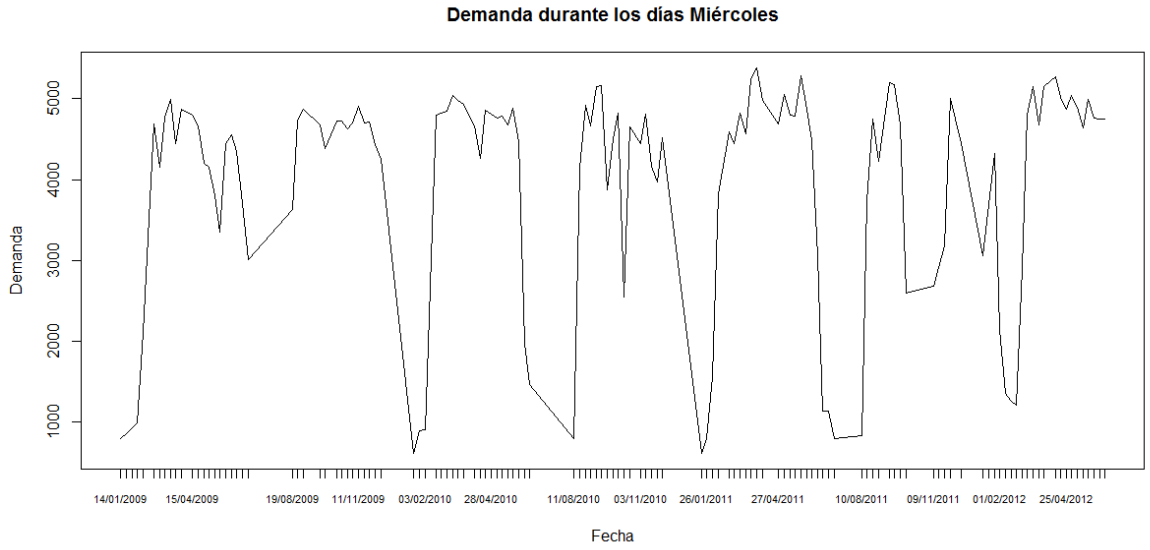
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 15. Comportamiento de la demanda durante los días martes.



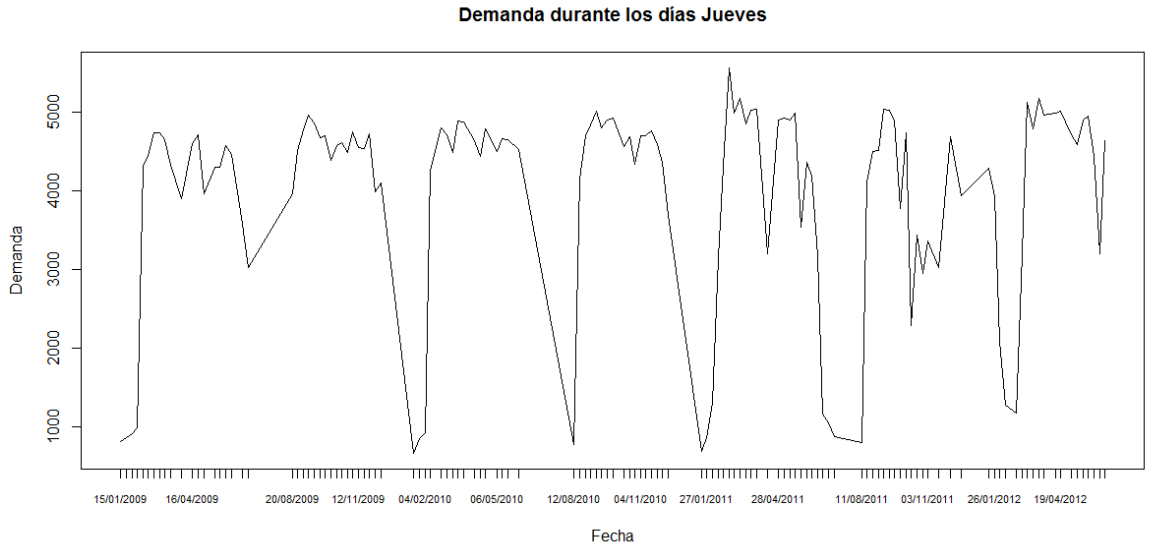
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 16. Comportamiento de la demanda durante los días miércoles.



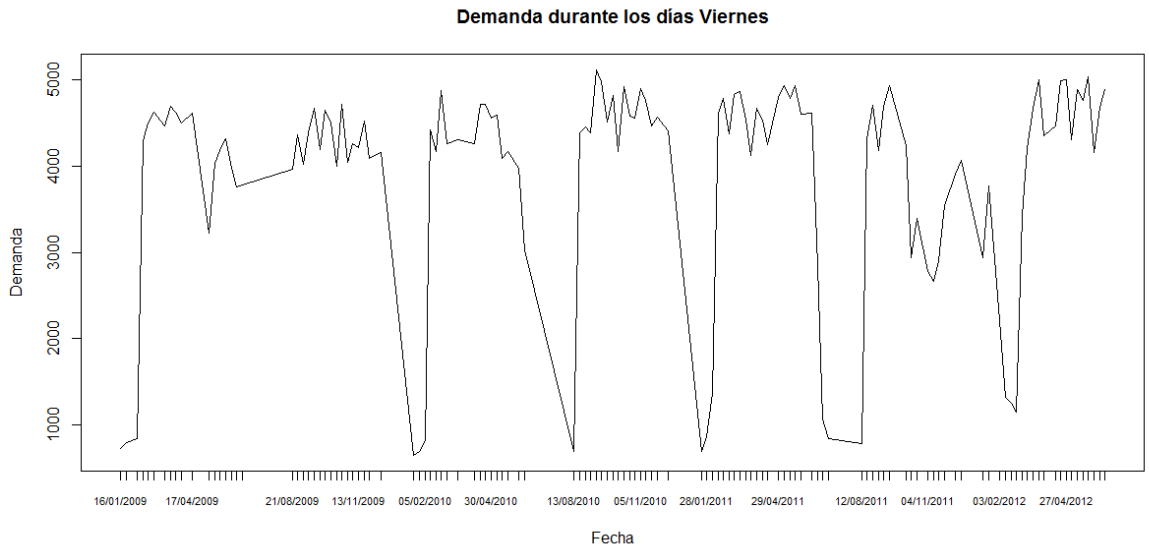
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 17. Comportamiento de la demanda durante los días jueves.



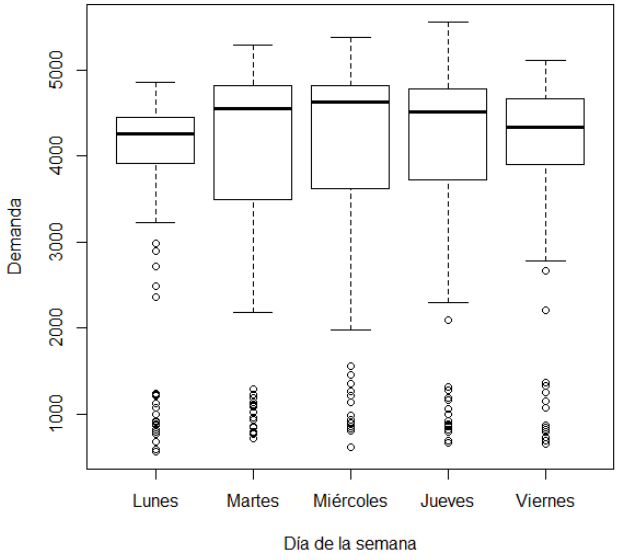
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 18. Comportamiento de la demanda durante los días viernes.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 19. Boxplot de la demanda según el día de la semana.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Por otra parte, se analizó si el menú, o algunos elementos de él, influyen en el número de personas diarias que hacen uso del servicio de almuerzo. Según la opinión de los expertos, algunas preparaciones como los frijoles tienen una buena acogida por parte de los usuarios, mientras que otras como el pescado tienden a ser rechazadas. Teniendo en cuenta estos hallazgos, se determinó evaluar los siguientes casos:

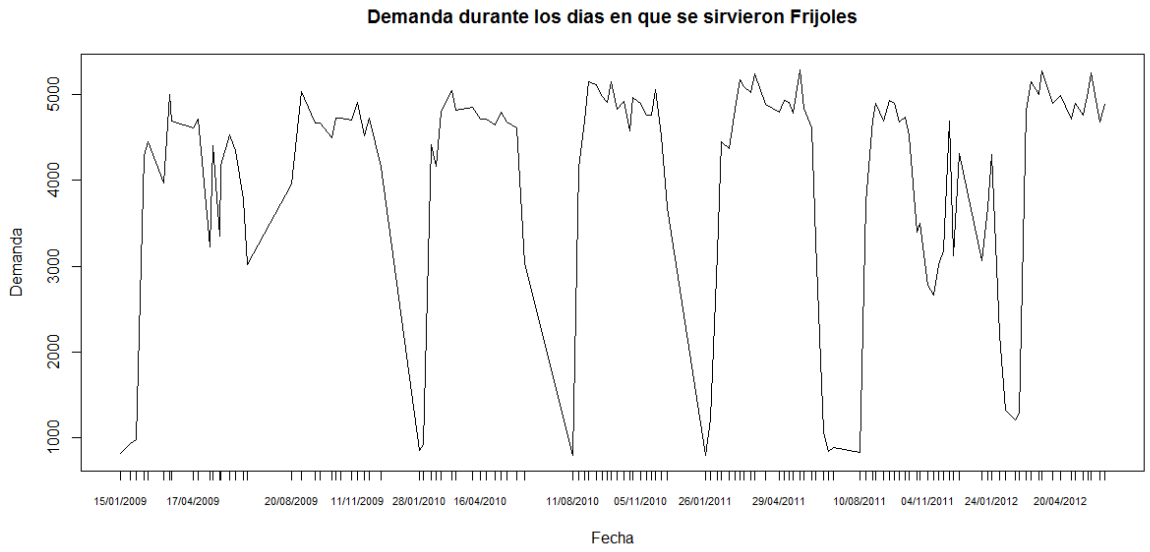
- Comportamiento de la demanda en los días en que el menú incluyó frijoles y en los días en que se sirvió pescado.
- Comportamiento de la demanda según el tipo de carne servida.

Como se observa en las figuras 20-22, los menús que incluyen frijoles tienen mayor demanda promedio que aquellos que contienen pescado. Sin embargo, la demanda de frijoles tiene una mayor variabilidad que la del pescado.

Respecto al comportamiento de la demanda según el tipo de carne servida, las figuras 23-26 muestran que los menús que contienen carne de cerdo o carne de res son los que tienen un mayor número de almuerzos servidos en promedio. Sin embargo, los primeros junto a los que contienen pollo, son los que presentan mayor variabilidad en la serie. Por otra parte, a pesar de que los almuerzos que incluyen pescado son los que tienen una menor demanda diaria promedio, estos presentan una menor variabilidad en comparación a los demás.

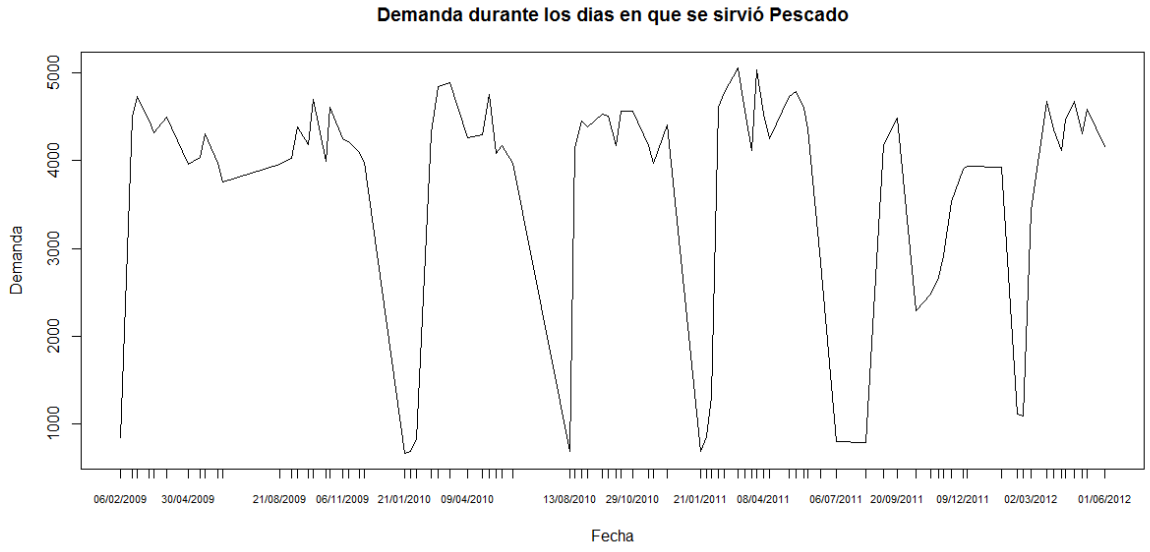
Debido a esto, se puede afirmar que la forma como se comporta la serie sí está influenciada por el menú preparado para cada día, por lo que éste se considera como un factor a tener en cuenta.

Figura 20. Comportamiento de la demanda de los días en que se sirvieron frijoles.



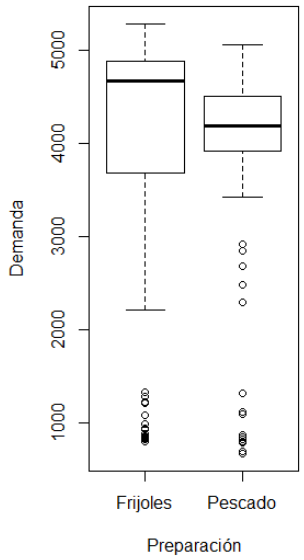
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 21. Comportamiento de la demanda de los días en que se sirvió pescado.



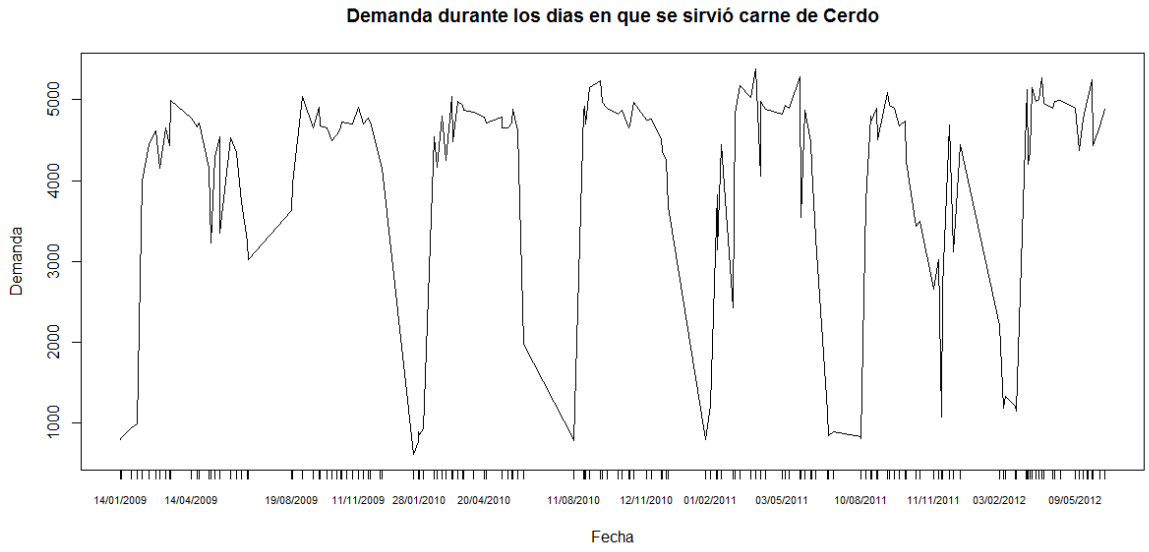
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figuras 22. Boxplot de la demanda de los días en que se sirvieron frijoles y los días en que se sirvió pescado.



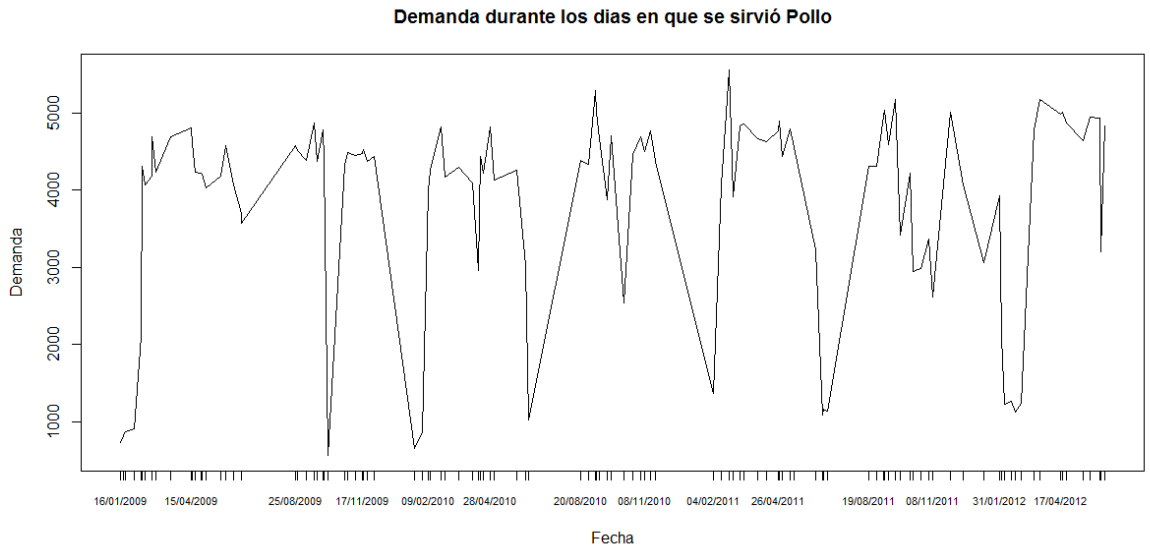
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 23. Comportamiento de la demanda de los días en que se sirvió carne de cerdo.



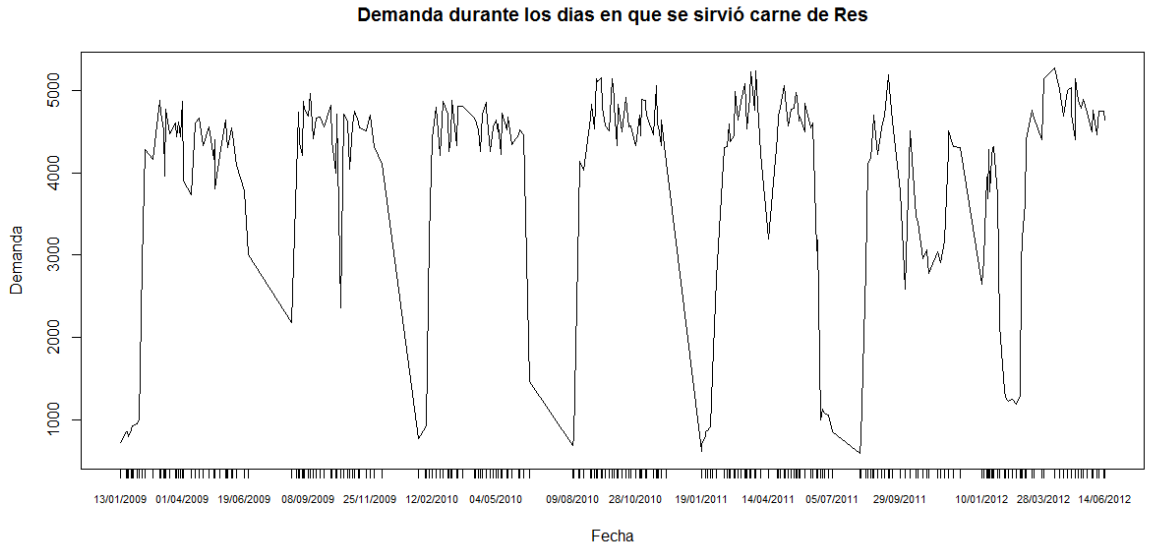
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 24. Comportamiento de la demanda de los días en que se sirvió pollo.



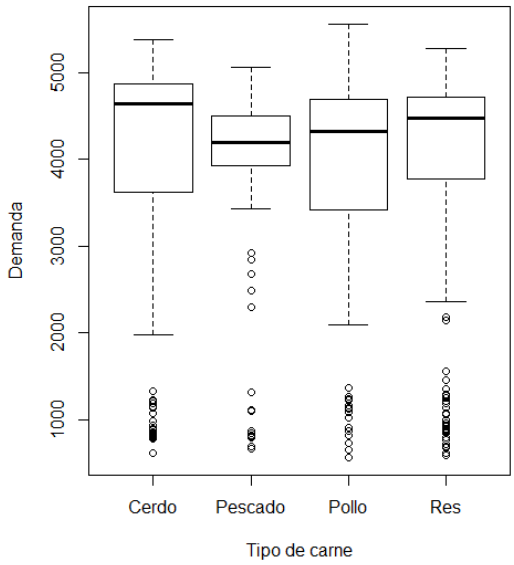
Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 25. Comportamiento de la demanda de los días en que se sirvió carne de res.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Figura 26. Boxplot de la demanda según el tipo de carne servida.



Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

A partir de lo anterior, se encontró que los factores que influyen en el comportamiento de la demanda diaria son: la fecha, el día de la semana, la época del semestre y el menú preparado. Estos serán el principal insumo del modelo propuesto, el cual se describe en detalle en la siguiente sección.

5.3 MODELO DE PRONÓSTICO DE DEMANDA CON REDES NEURONALES ARTIFICIALES

En esta sección se presenta el modelo propuesto como solución del problema planteado en el *capítulo 1*. Este modelo es simulado a través del uso de software especializados y los resultados obtenidos se comparan respecto a los alcanzados mediante el uso de los métodos clásicos de pronósticos.

5.3.1 Planteamiento del modelo de Redes Neuronales Artificiales para el pronóstico de la demanda diaria

A partir de los factores definidos en la *sección 5.2*, y teniendo en cuenta los conceptos teóricos explicados en el *capítulo 4*, se planteó un modelo de RNA para pronosticar la demanda diaria del restaurante de la UV. Estos factores son la fecha (día, mes, año), el día de la semana (lunes, martes, miércoles, jueves o viernes), la época del semestre y el menú preparado.

La época del semestre define el momento de actividad de los usuarios, principalmente de los estudiantes, en el restaurante universitario. Para este caso de estudio, se definieron tres posibles valores: inicio, clases y finalización.

Por otra parte, el menú es un factor que la componen seis elementos (sopa, carne, principio, arroz, ensalada y jugo) y que se elabora utilizando diferentes tipos de preparaciones. Un ejemplo se presenta en la tabla 7.

Tabla 7. Ejemplo de preparaciones para cada elemento de menú.

Sopa	Carne	Principio	Arroz	Ensalada	Jugo
Sopa de arroz	Bistec de hígado	Papa al perejil	Arroz blanco	Repollo y zanahoria	Jugo de lulo
Crema de tomate	Carne encebollada	Yuca guisada		Habichuelas guisadas	Jugo de naranja
Sopa de cuchuco	Pollo con champiñones	Puré de papa		Tomate campestre	Jugo de mora
Sopa de frijoles	Costilla frita	Arepa		Zanahoria y remolacha	Agua panela con limón
Consomé	Pollo al horno	Tajadas de maduro		Lechuga y apio	Jugo de maracuyá

Fuente: Elaborado por los autores a partir de la información suministrada por el restaurante de la Universidad del Valle.

Para cada uno de los elementos, se definen conjuntos codificados, en los cuales las preparaciones utilizadas para elaborarlos se puedan agrupar. La tabla 8 muestra los conjuntos definidos para cada componente del menú.

Tabla 8. Grupos de preparaciones para cada elemento de menú.

	Sopa	Carne	Principio	Arroz	Ensalada	Jugo
Grupos	Carne (C) Granos (G) Harinas (H) Verduras (V)	Cerdo (C) Pescado (F) Pollo (P) Res (R)	Harinas (H) Plátano (P) Tubérculos (T) Otros (O)	Arroz (A)	Verduras (V)	Frutas (F)

Fuente: Los autores.

Teniendo en cuenta lo anterior, se buscó establecer un patrón que arrojara un valor único para el menú. Con base en la opinión de los expertos del restaurante universitario, se analizó el impacto de cada uno de los componentes en la toma de la decisión por parte de los usuarios de hacer uso o no del servicio de almuerzo, de acuerdo al menú ofrecido. Este análisis arrojó que solamente la sopa, la carne y el principio influyen en la decisión, mientras que los otros componentes tienen una baja influencia; debido a que tanto el arroz, la ensalada y el jugo son preparados con un sólo tipo de alimentos (arroz blanco, verduras y frutas respectivamente) y la preparación que se hace puede depender de la temporada de los insumos (principalmente en el caso de las frutas). Por lo tanto, estos componentes fueron descartados para la construcción del patrón.

Utilizando las agrupaciones de cada uno de elementos seleccionados, se generó una codificación (patrón) para cada menú elaborado durante los períodos a evaluar. Esta codificación está compuesta de la siguiente manera: Sopa/Carne/Principio. Un ejemplo de patrón es GCP que corresponde a Sopa de Granos, Carne de Cerdo y Principio de Plátano se presenta en la tabla 9.

Tabla 9. Ejemplo de construcción de un patrón de menú.

Sopa	Grupo Sopa	Carne	Grupo Carne	Principio	Grupo Principio	Patrón
Sopa de lentejas	Granos (G)	Chuleta de cerdo	Cerdo (C)	Maduro al horno	Plátano (P)	GCP

Fuente: Los autores.

Al hacer la combinatoria con cada uno de los grupos de los tres elementos que componen el código, se obtienen 64 patrones. Sin embargo, al revisar la información de la base de datos y de acuerdo a lo que se observa en las tabla 10 y 11, durante todos los períodos sólo se usaron 45 de éstos; lo que equivale al 70% de todos los patrones disponibles.

Tabla 10. Número de veces que fue utilizado cada patrón durante los períodos analizados.

Patrón	Frecuencia	Patrón	Frecuencia	Patrón	Frecuencia	Patrón	Frecuencia
CCH	0	GCH	48	HCH	0	VCH	0
CCP	0	GCP	56	HCP	0	VCP	0
CCO	0	GCO	12	HCO	8	VCO	6
CCT	1	GCT	2	HCT	8	VCT	20
CFH	0	GFH	1	HFH	0	VFH	6
CFP	0	GFP	4	HFP	0	VFP	10
CFO	0	GFO	0	HFO	0	VFO	3
CFT	4	GFT	13	HFT	19	VFT	25
CPH	9	GPH	6	HPH	1	VPH	1
CPP	6	GPP	5	HPP	3	VPP	0
CPO	0	GPO	4	HPO	12	VPO	0
CPT	23	GPT	23	HPT	8	VPT	13
CRH	3	GRH	30	HRH	6	VRH	17
CRP	3	GRP	41	HRP	4	VRP	0
CRO	0	GRO	25	HRO	11	VRO	18
CRT	29	GRT	18	HRT	34	VRT	23

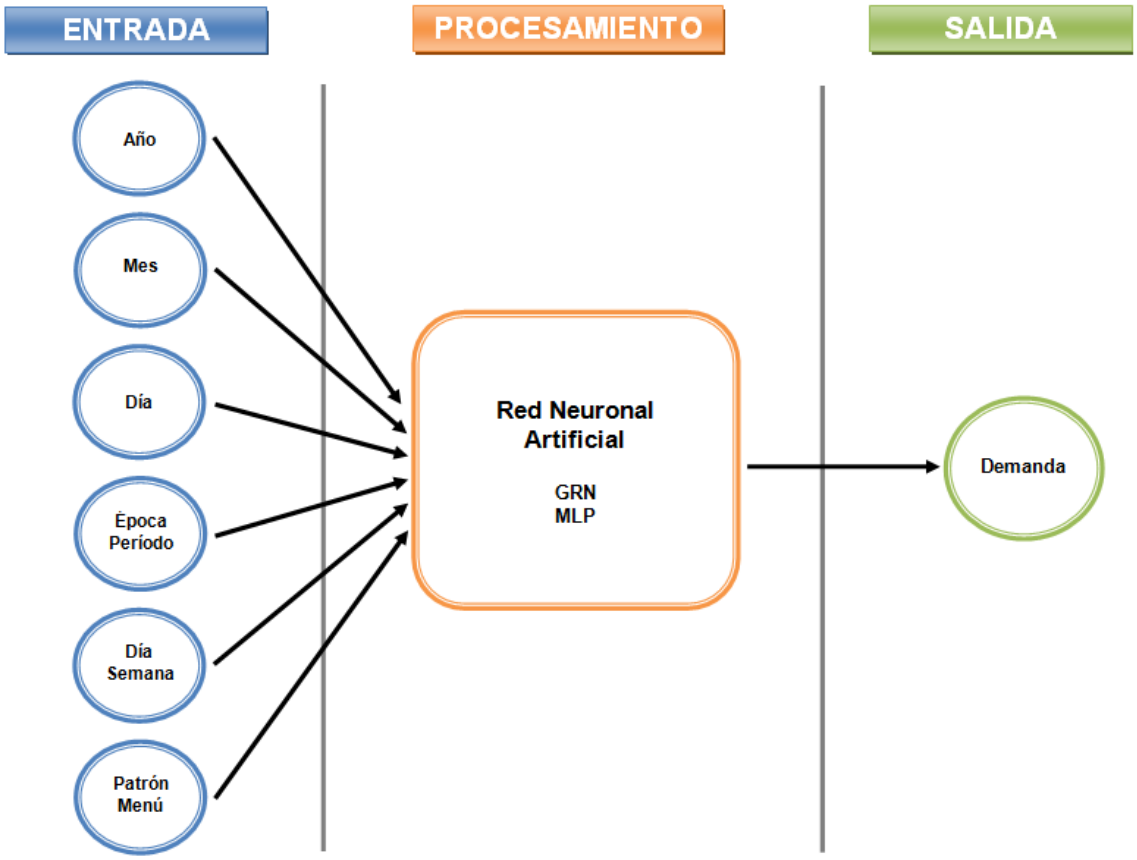
Fuente: Los autores.

Tabla 11. Porcentaje de utilización de los patrones de menú.

	Patrones	Porcentaje
Usados	45	70%
No usados	19	30%
Total	**64**	**100%**

Fuente: Los autores.

Figura 27. Modelo propuesto de Red Neuronal Artificial.



Fuente: Los autores.

Con base en lo planteado anteriormente en esta sección, la figura 27 presenta el modelo de RNA que se propone como solución del problema para este caso de estudio y que incluye tres etapas:

- Entrada: en esta etapa es donde ingresan los valores de los factores identificados durante el análisis y que influyen en el comportamiento de la variable de salida.
- Procesamiento: es donde se encuentra definida la arquitectura de la RNA que será utilizada para procesar los datos de la entrada.
- Salida: en esta etapa se obtienen los valores calculados durante el procesamiento, para la variable pronosticada.

En la siguiente sección, se presentarán los resultados obtenidos en la evaluación de este modelo, al simularlo mediante el uso de software especializados.

5.3.2 Evaluación del modelo de Redes Neuronales Artificiales para el pronóstico de la demanda diaria

Para la simulación del modelo de RNA propuesto en la sección anterior, se utilizaron dos software comerciales, cuyas características principales se presentan en la tabla 12.

Tabla 12. Principales características de los software utilizados.

	Software A	Software B
Tipos de redes	MLP	MLP y GRN
Tipos de variables	Numéricas y cadenas	Numéricas y cadenas
Configuración de la red	▪ Selección automática de la mejor arquitectura y topología. ▪ Selección manual del número de nodos por cada capa (para las MLP). ▪ Selección del porcentaje de casos utilizados para los procesos de entrenamiento y las pruebas.	▪ Selección automática de la mejor arquitectura y topología. ▪ Selección manual del número de nodos por cada capa (para las MLP). ▪ Selección del porcentaje de casos utilizados para los procesos de entrenamiento y las pruebas.

	Software A	Software B
Configuración de la red	▪ Selección manual de los casos que son utilizados para los procesos de entrenamiento y las pruebas. Selección manual de la función de activación. Selección manual del algoritmo de entrenamiento.	▪ Selección manual de los casos que son utilizados para los procesos de entrenamiento y las pruebas. ▪ Selección automática o manual de la función de activación y del algoritmo de entrenamiento, según el tipo de la variable de salida.
Condiciones de parada en el entrenamiento	▪ Tiempo máximo de entrenamiento. ▪ Número máximo de ensayos en el proceso de entrenamiento. ▪ Porcentaje de cambio del error en el entrenamiento.	▪ Tiempo máximo de entrenamiento. ▪ Número máximo de ensayos en el proceso de entrenamiento. ▪ Porcentaje de cambio del error en el entrenamiento.
Reportes	▪ Diagrama de la red. ▪ Valores de los pesos sinápticos. ▪ Impacto de las variables independientes. ▪ Diagrama de dispersión. ▪ Diagrama de los residuales. ▪ Errores de los procesos de entrenamiento y pruebas (MAD y ECM) ▪ Error Relativo	▪ 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 y ECM). ▪ Diagrama de dispersión. ▪ Histograma de los residuales.

Fuente: Los autores.

Previo a la realización de la evaluación, se llevaron a cabo varias pruebas con estas herramientas para determinar los valores óptimos de los parámetros de parada para el proceso de entrenamiento. Las pruebas realizadas arrojaron lo siguiente:

- Tiempo máximo de entrenamiento: Se modificó este parámetro con valores entre dos (definido por defecto en el software) y cinco horas. Sin embargo, se observó que el mayor tiempo utilizado por la red en la realización de este proceso (MLP

con seis nodos en las dos capas ocultas) fue siempre inferior a los cuarenta minutos.

- Número máximo de ensayos en el proceso de entrenamiento: Se utilizaron valores dentro del rango 1.000.000-5.000.000 y se observó que con el valor del límite inferior era suficiente, ya que durante cada simulación nunca realizaron más de 1.000.000 ensayos en el entrenamiento.
- Porcentaje de cambio del error de cálculo en el entrenamiento: Este parámetro se utiliza como límite del crecimiento del error en los cálculos, para un tiempo determinado. Su valor fue modificado utilizando valores entre 0,1% y 2%, y se obtuvo que 1% (valor definido por defecto) es el que mejores resultados genera, ya que los otros incrementan el error de los pronósticos respecto al valor real de la serie.

Teniendo en cuenta lo anterior y que en la evaluación de estos tipos de redes serían utilizados ambos software, fue necesario definir unas condiciones básicas para la implementación de la RNA, para establecer un punto de comparación igual para los resultados obtenidos con este par de herramientas.

Las condiciones definidas para la implementación de las RNA son las siguientes:

- Los 622 registros de la base de datos son utilizados en los procesos de entrenamiento, pruebas y simulación (pronóstico).
- El porcentaje de datos utilizados para los procesos de entrenamiento y pruebas son del 80% (481 registros) y 20% (120 registros) respectivamente. Estos datos son escogidos aleatoriamente y se marcan con una variable de etiqueta (tag) que indica en qué proceso serán utilizados.
- Los datos utilizados para la predicción corresponden a las fechas del último mes del 2012-I en las que se tienen registros, es decir, el periodo del 16 de mayo al 15 de junio del 2012 (21 registros).
- La topología de la red es escogida automáticamente por el software con el fin de obtener la mejor configuración de ésta. En caso de no lograr un resultado satisfactorio, es decir, que la tasa de error de la red (seleccionada por el software) durante el entrenamiento o las pruebas sea mayor al 10%, la topología se ajusta manualmente y se simula de nuevo; lo que significa que se aumenta o disminuye

el número de nodos en cada capa oculta, hasta generar un pronóstico adecuado para la serie.

- La función de activación seleccionada para el proceso de aprendizaje es la Tangente Hiperbólica. Por otra parte, los algoritmos de entrenamiento utilizados en el software A y B, son el Gradiente Conjugado Escalado y el Gradiente Descendente Conjugado, respectivamente.
- La función de activación seleccionada para la capa de salida es la Función Identidad, la cual toma los argumentos del valor real y los devuelve sin modificar.
- Tiempo máximo de entrenamiento es de dos horas.
- El número máximo de ensayos para el proceso de entrenamiento es de 1.000.000.
- El porcentaje de cambio del error en el entrenamiento es del 1%.

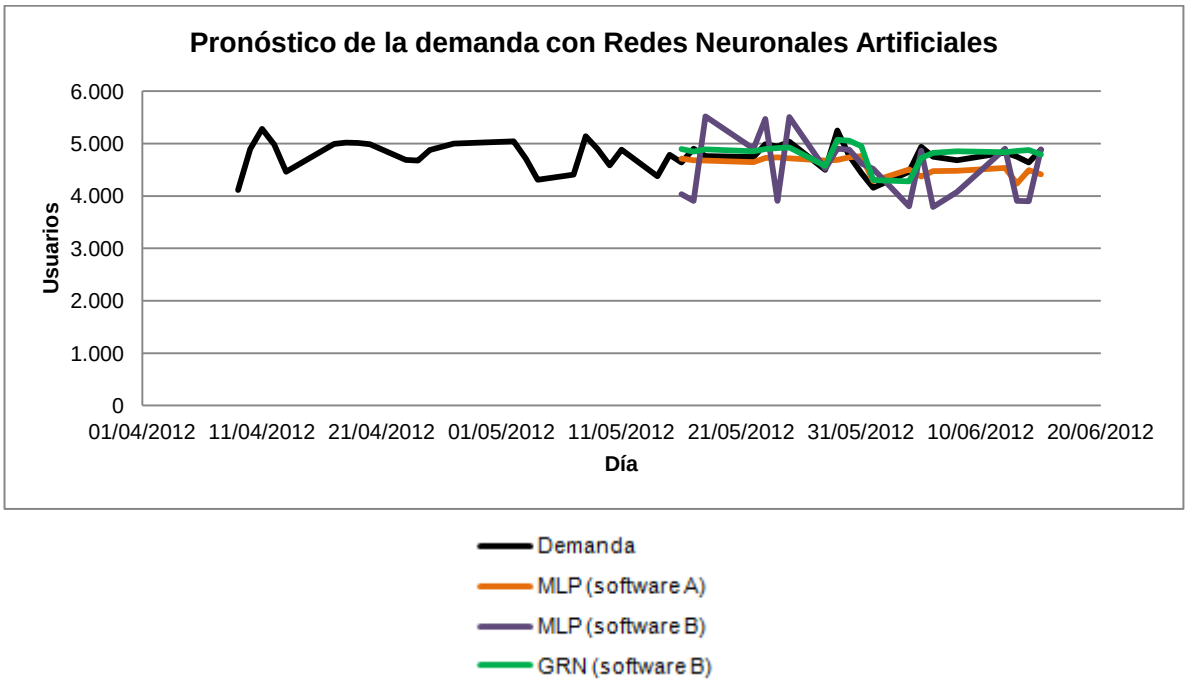
Enseguida, se evaluó el modelo planteado en la *sección 5.3.1* mediante la simulación de los dos tipos de redes, obteniendo los resultados que se presentan en la tabla 13 y la figura 28.

Tabla 13. Indicadores de la evaluación de las Redes Neuronales Artificiales para el pronóstico de la demanda del 16 de mayo al 15 de junio de 2012.

Red	Topología	MAD	Desv. MAD	ECM	Desv. ECM
MLP (software A)	3 nodos en la primera capa y 0 nodos en la segunda capa oculta	249,95	312,44	89.850,35	299,75
MLP (software B)	5 nodos en la primera capa y 0 nodos en la segunda capa oculta	474,65	593,31	339.052,55	582,28
GRN (software B)	Una capa oculta de patrón y una capa oculta de suma	153,30	191,63	35.928,50	189,55

Fuente: Los autores.

Figura 28. Pronóstico de la demanda del 16 de mayo al 15 de junio del 2012 obtenido con las Redes Neuronales Artificiales.

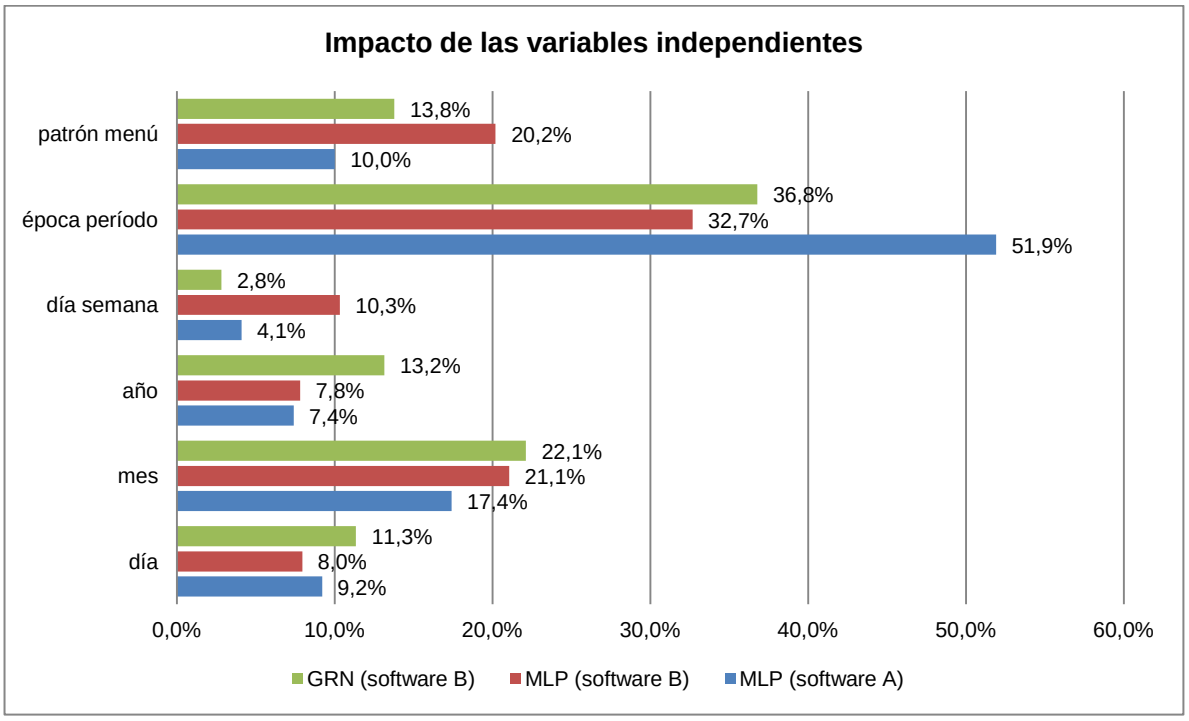


Fuente: Los autores.

Como se observa en la tabla 13, la GRN es la RNA que presenta los mejores resultados de la evaluación realizada, ya que su ECM es menor al obtenido con el MLP simulado con ambos software. Esto ocurre debido a que los pronósticos generados con este tipo de red se ajustan mejor al comportamiento real de la serie, en comparación a las predicciones obtenidas con el MLP, como se puede verificar en la figura 28.

Por otra parte, la figura 29 muestra que la época del periodo es la variable independiente que tiene el mayor impacto en todas las redes simuladas para este caso. Por el contrario, el día de la semana en general es la variable que presenta los porcentajes de impacto de más pequeños sobre la predicción; los otros factores varían en importancia según el tipo de red utilizada. El impacto de una variable mide la sensibilidad de las predicciones de la red al cambio; entre más bajo sea este porcentaje, menor es el efecto que tiene la variable sobre el pronóstico alcanzado.

Figura 29. Impacto de las variables independientes en cada tipo de red simulada para pronosticar la demanda del 16 de mayo al 15 de junio del 2012.



Fuente: Elaborado por los autores a partir de la información de los reportes generados por los software en la simulación del modelo.

Con base en lo anterior, se afirma que las RNA son una buena técnica para pronosticar la demanda, ya que las predicciones realizadas por estas se adaptan muy bien a la forma como se comporta la serie. Esto a pesar de que los días pronosticados están influenciados por la alta variabilidad de la demanda que se presentó en el 2011-II y que impactó el inicio del 2012-I, como se pudo observar en la figura 10. Lo anterior se puede comprobar en la figura 28, donde se registra el comportamiento de las predicciones generadas mediante la simulación de los dos tipos de redes.

Se debe tener en cuenta que la predicción generada por las RNA a pesar de tener una buena precisión, es un valor aproximado al real. Por lo tanto, es necesario considerar un inventario de seguridad para un nivel de servicio determinado, que permita disminuir el riesgo de presentar faltantes o excesos de almuerzos durante la prestación del servicio. Así, el valor de la demanda máxima para un día determinado i, está dado por:

$$demanda\ máxima_i = \ pronosticoRNA_i + inventario\ seguridad$$

donde, según lo planteado en Vidal (2010):

$$inventario\ seguridad = k\sigma_1$$

donde, K → Factor de seguridad dependiente del nivel de servicio deseado.

σ_1 → Desviación estándar de los errores de pronóstico de la demanda total, es decir, la desviación estándar del ECM, sobre un periodo de duración de un día.

Considerando lo anterior, la tabla 14 presenta el inventario de seguridad para los pronósticos obtenidos en la simulación del modelo con los dos tipos de redes. En ella se observa que la red con el menor valor del ECM, requiere un menor inventario de seguridad.

Tabla 14. Inventario de seguridad para el pronóstico de la demanda del 16 de mayo al 15 de junio de 2012.

Red	Desv. ECM	Inventario de seguridad según el nivel de servicio		
		95% (k = 1,65)	97,5% (k = 1,96)	99% (k = 2,33)
MLP (software A)	299,75	495	588	698
MLP (software B)	582,28	961	1141	1231
GRN (software B)	189,55	313	372	442

Fuente: Los autores.

Sin embargo, esta evaluación y sus respectivos resultados, no son suficientes para concluir que las RNA son adecuadas para pronosticar la demanda en sistemas donde el comportamiento de la serie no es lineal. Para ello, es necesario comparar su desempeño respecto al presentado por los métodos clásicos de pronósticos.

5.3.3 Pronósticos de demanda con Redes Neuronales Artificiales vs. Pronósticos de demanda con Métodos Clásicos

Debido a que el objetivo principal de este proyecto es construir un modelo basado en RNA para pronosticar la demanda en un restaurante institucional, para este caso el de la UV, es fundamental evaluar su rendimiento respecto al obtenido mediante el uso de los métodos clásicos de pronósticos. Con el fin tener un punto de comparación igual para los diferentes métodos, se determinó construir un escenario base con el cual serían evaluados cada uno de ellos.

Para su construcción, inicialmente se definieron los periodos a utilizar en la evaluación. Dadas las dificultades presentadas en la UV durante los semestres 2011-II y 2012-I, descritas en la *sección 5.2*, se decidió ignorar los datos de estos periodos; por lo cual, los semestres escogidos para ser incluidos en el escenario son el 2009-I, 2009-II, 2010-I, 2010-II y 2011-I.

Para cada uno los periodos seleccionados se descartaron todos los datos atípicos (Vidal, 2010), y se calculó el número de registros que tenían después de este proceso. Este cálculo arrojó que el 2009-II, con setenta registros, era el semestre que tenía la menor cantidad de datos; por lo tanto, se determinó que este valor sería el número de registros que se tomarían por cada período para realizar la evaluación. Para la selección de los datos de los semestres que tenían un número mayor de estos y después de la depuración de los atípicos, se decidió eliminar registros aleatoriamente hasta que la cantidad de datos que se tuviera por cada período fuera igual a la del 2009-II.

Con la información anterior, se define que el escenario con el que se llevó a cabo la evaluación está compuesto por cinco semestres, cada uno con setenta registros. Cuatro de estos períodos (2009-I, 2009-II, 2010-I, 2010-II) se utilizaron para la inicialización de cada método a evaluar y el semestre (2011-I) se tomó para realizar su respectivo pronóstico.

En esta evaluación de los métodos clásicos de pronósticos se empleó la metodología propuesta en Vidal (2010). Como parámetros de comparación, se utilizaron los

indicadores de precisión denominados Desviación Absoluta Media (en inglés Mean Absolute Deviation, MAD) y Error Cuadrático Medio (ECM) (en inglés Mean Square Error, MSE), para señalar los promedios de los errores de los valores pronosticados mediante la aplicación de cada método. A continuación, se describen los resultados que se obtuvieron para cada método evaluado.

- Promedio Móvil

Como primer paso, se construyó una Regresión Lineal Simple con los datos de inicialización, con el fin de encontrar los valores del intercepto y la pendiente, los cuales son respectivamente: a = 3.720 y b = 3,51. Esta información indica que se tiene una tendencia creciente de la demanda, aunque esta es muy baja.

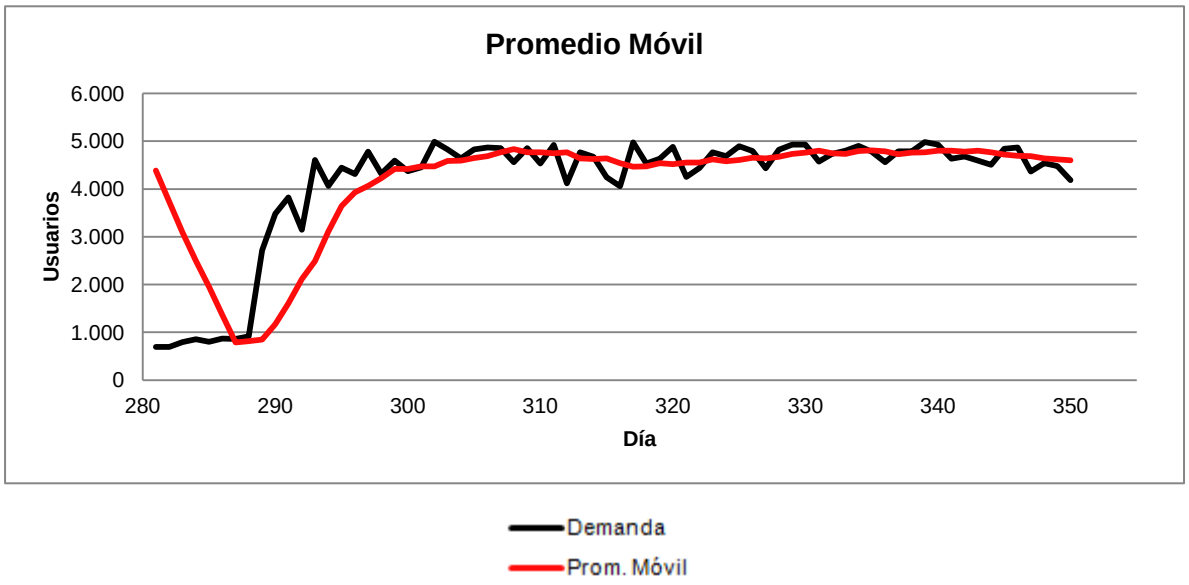
Posteriormente, se simuló el pronóstico de la demanda para el período 2011-I y se comparó los resultados con los valores reales de esta variable. Enseguida se optimizó el valor de N, cambiando su valor entre 6 y 20 (Vidal, 2010), obteniendo que N = 6 es el parámetro optimo que minimiza el valor del ECM para este escenario. Los resultados obtenidos se presentan en la tabla 15 y el figura 30.

Tabla 15. Indicadores de la evaluación del método del Promedio Móvil.

Parámetros	MAD	Desviación MAD	ECM	Desviación ECM
a = 3.720 b = 3,51 N = 6	498,98	623,72	811.774,05	900,99

Fuente: Los autores.

Figura 30. Pronóstico de la demanda obtenido con el método del Promedio Móvil.



Fuente: Los autores.

Como se observa en la figura anterior, el Promedio Móvil presenta grandes errores en la predicción de la demanda al inicio y final de semestre, debido su rápido crecimiento y disminución de la serie durante las épocas mencionadas. Lo anterior implica que el método de Promedio Móvil requiere un mayor tiempo para ajustarse al comportamiento de la demanda real, al inicio cuando esta crece por lo que se requiere un N muy bajo y al final, cuando la serie disminuye, ocasiona que el pronóstico quede sesgado nuevamente.

- Suavización Exponencial Simple (SES)

Para este método se calculó el valor de la constante de suavización α teniendo en cuenta lo planteado en Vidal (2010), es decir, que para este parámetro su valor debe estar entre 0,01 y 0,30. Para ello se utilizó la herramienta *solver* de *Excel*, con el fin de obtener el valor óptimo de α que minimiza el del ECM. En la tabla 16 se presentan los resultados obtenidos.

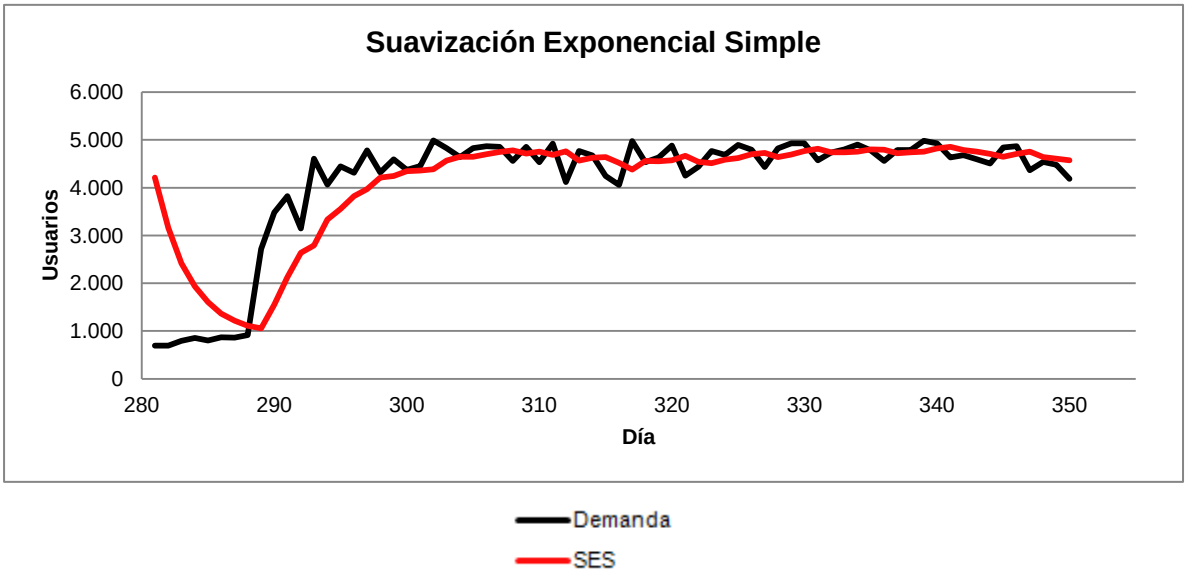
Tabla 16. Indicadores de la evaluación del método de la SES.

Parámetros	MAD	Desviación MAD	ECM	Desviación ECM
α = 0,30	455,18	568,98	597.338,63	772,88

Fuente: Los autores.

La tabla anterior muestra que el ECM obtenido mediante la aplicación de este método es menor al que se obtuvo con el Promedio Móvil. De igual manera, como se observa en la figura 31 y como sucede con en el Promedio Móvil, el inicio de semestre es la época donde se presentan los valores pronosticados con más altos errores respecto a la demanda real. Sin embargo, en la SES el pronóstico se ajusta más rápido, debido a la suavización que realiza el α en este método.

Figura 31. Pronóstico de la demanda obtenido con el método de la SES.



Fuente: Los autores.

- Suavización Exponencial Doble (SED)

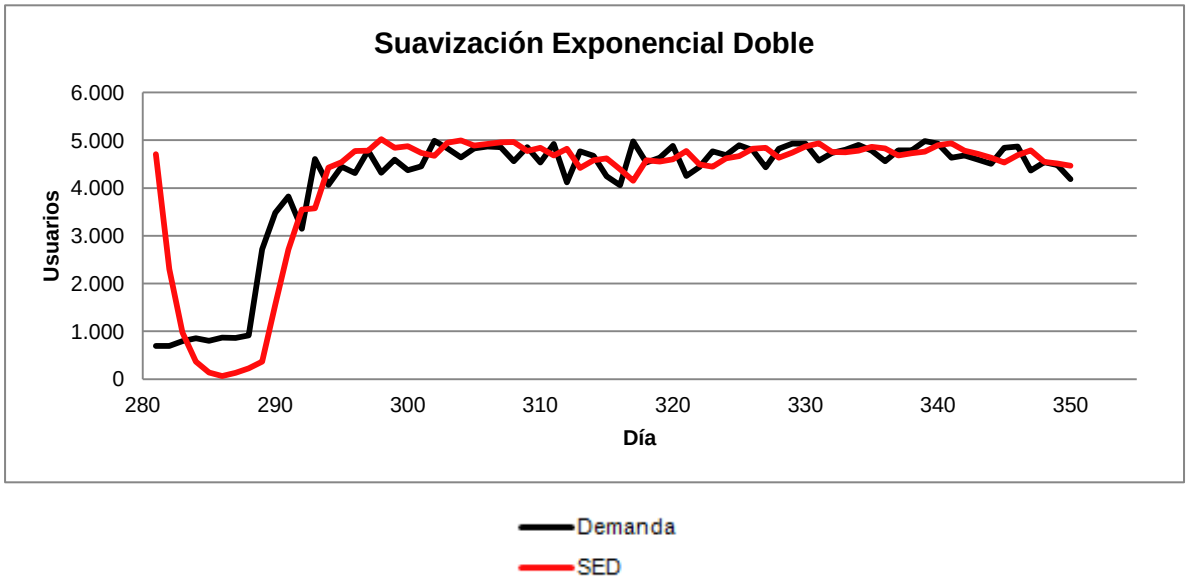
Este método al tener en cuenta la tendencia de la demanda, fija dos valores iniciales: la constante que representa el componente fijo de la demanda y el componente de tendencia lineal, que para este caso es creciente, y cuyos valores fueron 4.694 y 4.686 respectivamente. Con estos valores iniciales, se simuló el pronóstico de la demanda para el período 2011-I con el α de suavización, el cual fue optimizado con la herramienta *solver* de *Excel* mediante la minimización del valor encontrado para el ECM. Los parámetros utilizados y los resultados obtenidos se presentan en la tabla 17.

Tabla 17. Indicadores de la evaluación del método de la SED.

Parámetros	MAD	Desviación MAD	ECM	Desviación ECM
α = 0,3 β = 0,7	415,02	518,78	538.437,26	733,78

Fuente: Los autores.

Figura 32. Pronóstico de la demanda obtenido con el método de la SED.



Fuente: Los autores.

Como se registra en la tabla anterior, el valor de ECM es inferior al encontrado en el Promedio Móvil y la Suavización Exponencial Simple. Sin embargo, como se visualiza en la figura 32, al igual que en los métodos anteriores, la época del período donde los valores pronosticados presentan un mayor error respecto al valor real es al inicio del semestre simulado.

- Método Combinado

Este método permite realizar una combinación lineal convexa de los pronósticos obtenidos mediante los tres métodos anteriores (Vidal, 2010), multiplicando cada uno de ellos por un factor (a_1, a_2 y a_3 para Promedio Móvil, SES y SED respectivamente) con valor entre 0 y 1, que establece la influencia de cada uno de los métodos sobre el resultado final; la suma de los tres factores deber ser igual a 1.

Se utiliza *solver* de *Excel* para encontrar el valor de estos parámetros que minimizan el valor del ECM. En la tabla 18 y la figura 33 se presentan los resultados encontrados.

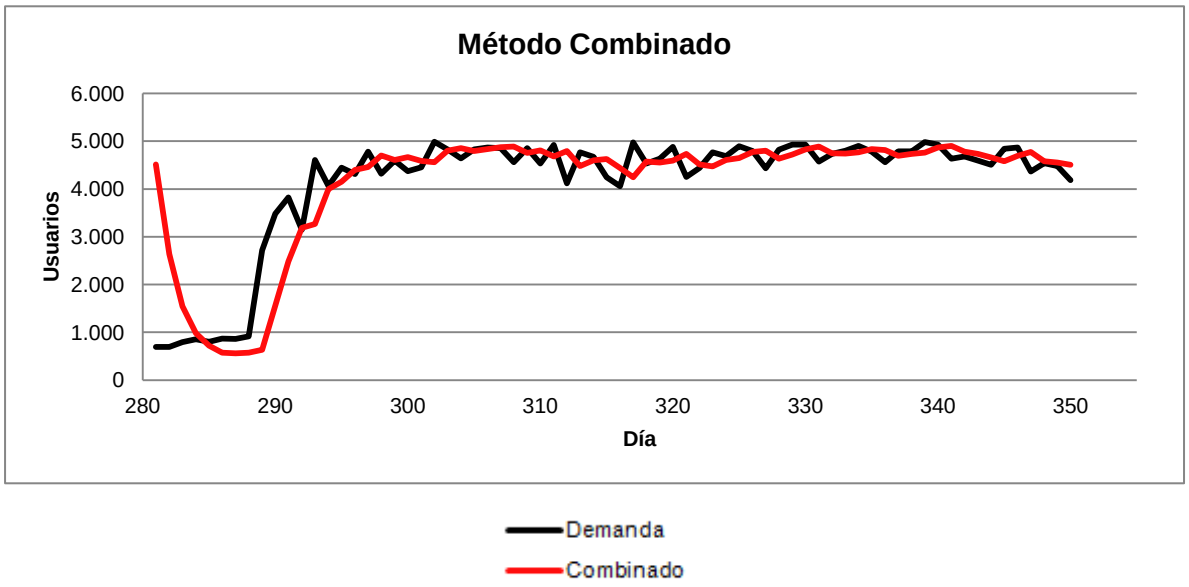
Tabla 18. Indicadores de la evaluación del método Combinado.

Parámetros	MAD	Desviación MAD	ECM	Desviación ECM
a_1 = 0,00 a_2 = 0,39 a_3 = 0,61	370,10	462,63	495.035,04	703,59

Fuente: Los autores.

En la tabla anterior se observa que el valor de ECM es mejor respecto al Promedio Móvil, la SES y la SED, debido a que el método combina lo mejor de cada uno de ellos.

Figura 33. Pronóstico de la demanda obtenido con el método Combinado.



Fuente: Los autores.

La figura 33 muestra que el método Combinado se ajusta mejor y más rápido al comportamiento de serie, que los métodos evaluados previamente.

- Método Multiplicativo de Winters

Al observar los datos de la demanda diaria y su gráfico de comportamiento, figura 10, se identifica que tiene tendencia y estacionalidad al ser analizada por semestres. Por lo cual, el método Multiplicativo de Winters puede ser una herramienta adecuada para pronosticar su valor (Vidal, 2010).

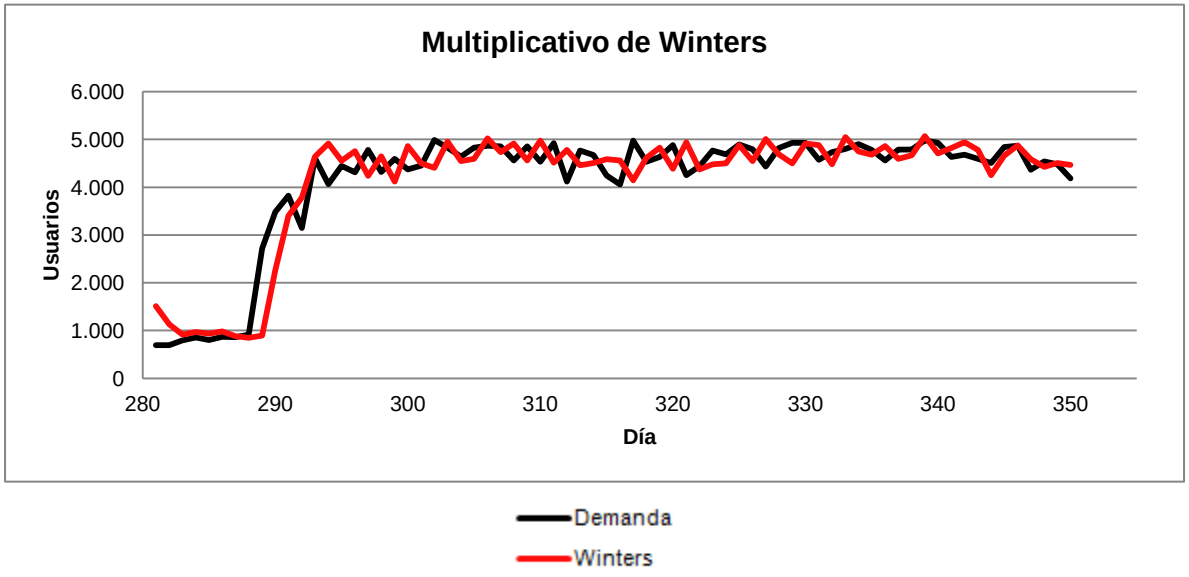
Con los datos de inicialización, se calcularon los valores de arranque, los factores estacionales, el componente permanente y la estimación de la tendencia. Se optimizó con *solver* de *Excel* el valor de las constantes de suavización α, β y ϒ (Vidal, 2010; Silver et al 1998) que minimizan el ECM. Estos resultados se presentan en la tabla 19 y la figura 34.

Tabla 19. Indicadores de la evaluación del método Multiplicativo de Winters.

Parámetros	MAD	Desviación MAD	ECM	Desviación ECM
L = 70 m = 4 α = 0,71 β = 0,00 Ɣ = 1,00	314,51	393,14	187.352,85	432,84

Fuente: Los autores.

Figura 34. Pronóstico de la demanda obtenido con el método Multiplicativo de Winters.



Fuente: Los autores.

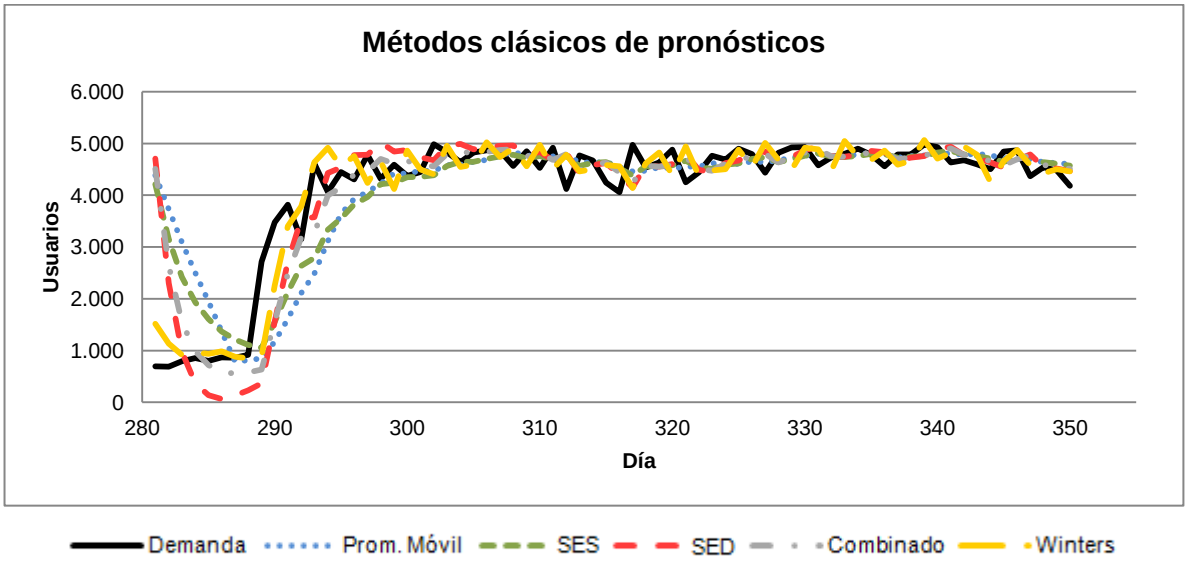
La tabla 19 muestra que el valor del ECM obtenido mediante este método es el más bajo de todos los procedimientos evaluados. El pronóstico generado por Winters se ajusta rápidamente al comportamiento de la demanda real al inicio del semestre, creciendo a medida que inicia el período de clases y ajustando su valor cuando está finalizando el período. Esto corrobora lo planteado al inicio de la evaluación de este método, es decir,

que para este caso de estudio el método Multiplicativo de Winters es una herramienta adecuada para pronosticar el valor de la demanda.

Con base en lo anterior, se puede concluir que de los métodos clásicos de pronósticos, el método Multiplicativo de Winters es el que mejor se comporta para el escenario planteado para este caso de estudio. Esto es debido a que la demanda tiene un comportamiento tanto creciente como estacional durante cada semestre; presenta valores pequeños en diferentes épocas, al inicio del semestre, los cuales rápidamente se incrementan al ingresar los estudiantes a clases, para después mantenerse con valores altos durante gran parte del tiempo y disminuir al final del período con motivo de la finalización de las clases y el inicio de las vacaciones. Por lo que se podría realizar para cada época de la serie un tipo de pronóstico diferente; sin embargo, eso implicaría estar modificando el sistema de pronósticos constantemente y ocasionaría la perdida de la continuidad en la serie.

A continuación, en la figura 35 y la tabla 20 se presenta el consolidado de los resultados obtenidos mediante la evaluación de los métodos clásicos de pronósticos.

Figura 35. Pronóstico de la demanda obtenido con cada uno de los métodos clásicos evaluados.



Fuente: Los autores.

Tabla 20. Indicadores de la evaluación de los métodos clásicos de pronósticos.

Método	Parámetros	MAD	Desv. MAD	ECM	Desv. ECM
Promedio Móvil	a = 3.720 b = 3,51 N = 6	498,98	623,72	811.774,05	900,99
SES	α = 0,30	455,18	568,98	597.338,63	772,88
SED	α = 0,3 β = 0,7	415,02	518,78	538.437,26	733,78
Combinado	a_1 = 0,00 a_2 = 0,39 a_3 = 0,61	370,10	462,63	495.035,04	703,59
Multiplicativo de Winters	L = 70 m = 4 α = 0,71 β = 0,00 Ɣ = 1,00	314,51	393,14	187.352,85	432,84

Fuente: Los autores.

Por otra parte, para la evaluación de las RNA se utilizaron los mismos datos usados en la evaluación de los métodos clásicos y adicional se aplicaron las condiciones definidas en la *sección 5.3.2* para la simulación de los dos tipos de redes. Los resultados obtenidos se presentan en la tabla 21.

Como se observa en esta tabla, la GRN es la red que presentó el mejor resultado en la evaluación de las RNA, ya que su ECM es significativamente menor al obtenido con el otro tipo de red. Igualmente, puede observarse que el MLP arrojó valores muy similares para el ECM, al ser simulado en ambos software.

Tabla 21. Indicadores de la evaluación de las Redes Neuronales Artificiales.

Red	Topología	MAD	Desv. MAD	ECM	Desv. ECM
MLP (software A)	5 nodos en la primera capa y 0 nodos en la segunda capa oculta	285,03	356,29	170.606,66	413,05
MLP (software B)	4 nodos en la primera capa y 0 nodos en la segunda capa oculta	298,50	373,13	172.778,13	415,67
GRN (software B)	Una capa oculta de patrón y una capa oculta de suma	229,17	286,46	89.163,32	298,60

Fuente: Los autores.

En la tabla 22 son presentados los resultados que se obtuvieron mediante la evaluación de los métodos tradicionales y las RNA en relación a la predicción de la serie para el escenario planteado. Así mismo, la figura 36 presenta los pronósticos generados por los métodos que presentaron mejor desempeño y su comportamiento respecto a la demanda real.

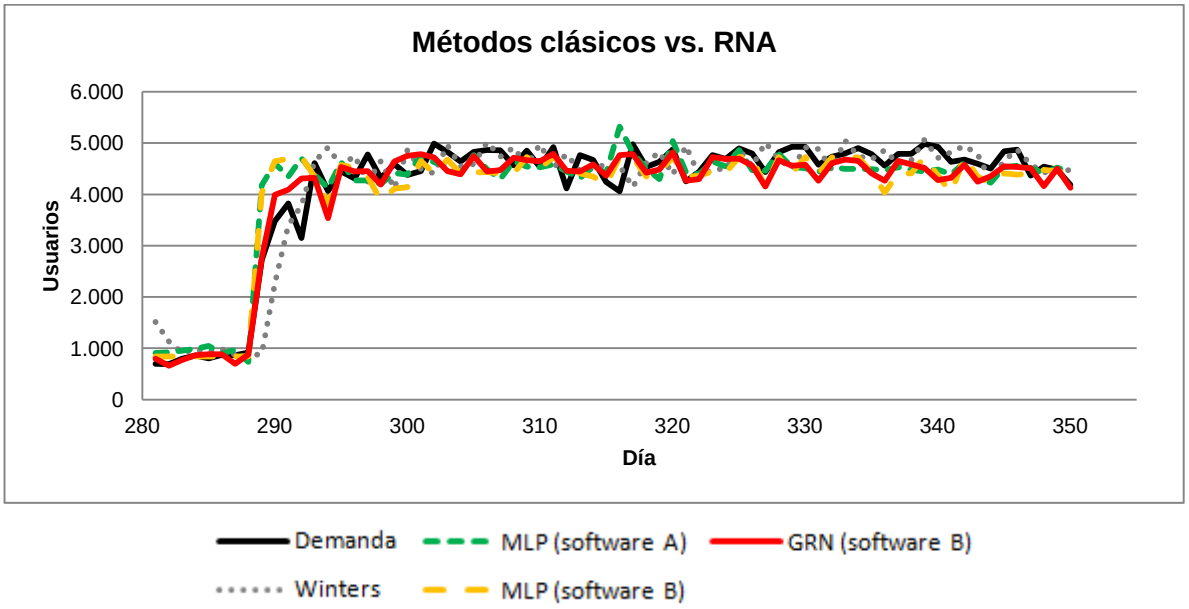
Con base en los indicadores de precisión, se puede afirmar que el modelo de RNA propuesto como solución del problema tiene un mejor rendimiento que los métodos clásicos para el escenario planteado en este caso de estudio. Esto se debe a que el valor del ECM arrojado, para ambos tipos de redes, es menor que el obtenido con método clásico que generó los mejores resultados; es decir, con el método Multiplicativo de Winters. En esta evaluación, la GRN fue el método que arrojó los mejores pronósticos para el valor de la demanda, siendo su ECM significativamente menor al de los otros métodos.

Tabla 22. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales.

Método / Red	MAD	Desv. MAD	ECM	Desv. ECM
Promedio Móvil	498,98	623,72	811.774,05	900,99
SES	455,18	568,98	597.338,63	772,88
SED	415,02	518,78	538.437,26	733,78
Combinado	370,10	462,63	495.035,04	703,59
Multiplicativo de Winters	314,51	393,14	187.352,85	432,84
MLP (software A)	285,03	356,29	170.606,66	413,05
MLP (software B)	298,50	373,13	172.778,13	415,67
GRN (software B)	229,17	286,46	89.163,32	298,60

Fuente: Los autores.

Figura 36. Pronóstico de la demanda obtenido con los métodos que presentaron mejor desempeño en la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales.



Fuente: Los autores.

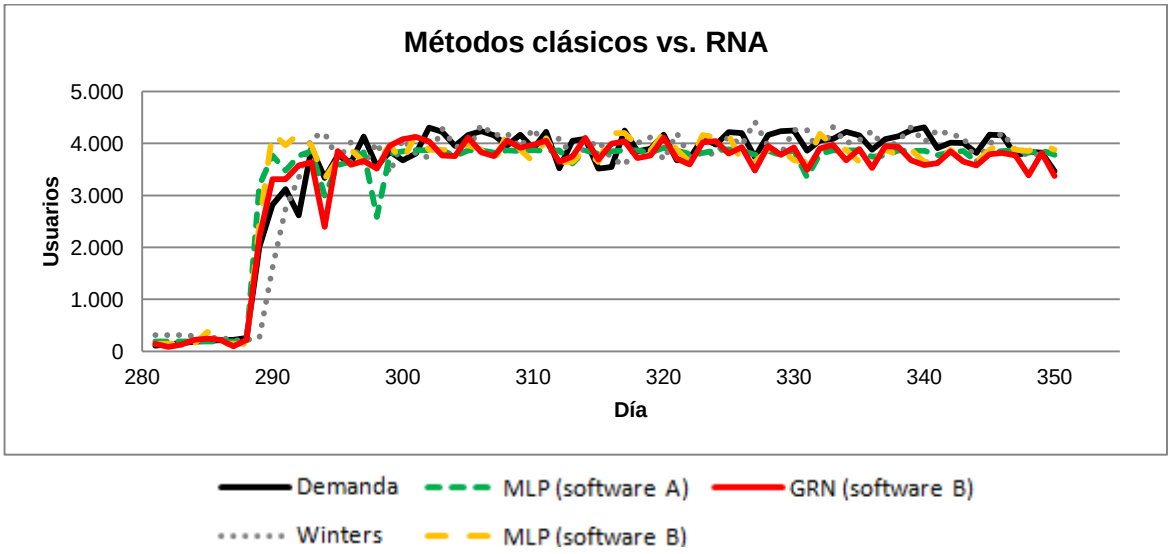
Adicionalmente, se evaluó el rendimiento de estos métodos para el mismo escenario, pero con la demanda discriminada por estudiantes y empleados. Los resultados obtenidos para la demanda del primer grupo de usuarios se presentan en la tabla 23 y en la figura 37.

Tabla 23. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales para la demanda diaria de los estudiantes.

Método / Red	MAD	Desv. MAD	ECM	Desv. ECM
Promedio Móvil	487,84	609,80	785.838,07	886,48
SES	447,02	558,77	573.461,90	757,27
SED	400,90	501,13	511.055,79	714,88
Combinado	364,29	455,36	470.711,47	686,08
Multiplicativo de Winters	290,05	362,56	165.993,48	407,42
MLP (software A)	267,23	334,04	129.248,66	359,51
MLP (software B)	264,37	330,47	146.479,26	382,73
GRN (software B)	241,08	301,35	99.537,75	315,50

Fuente: Los autores.

Figura 37. Pronóstico obtenido con los métodos clásicos y las Redes Neuronales Artificiales para la demanda diaria de los estudiantes.



Fuente: Los autores.

Como se observa en la tabla anterior las RNA son los métodos que presentan el mejor rendimiento para este escenario, al igual que en la evaluación realizada para la demanda total, considerando los valores obtenidos en el ECM. Esto se debe a que las RNA se ajustan más rápido a la alta variabilidad y estacionalidad de la serie.

Por otra parte, la evaluación realizada respecto a la demanda de los empleados arrojó los resultados que se presentan en la tabla 24 y la figura 38.

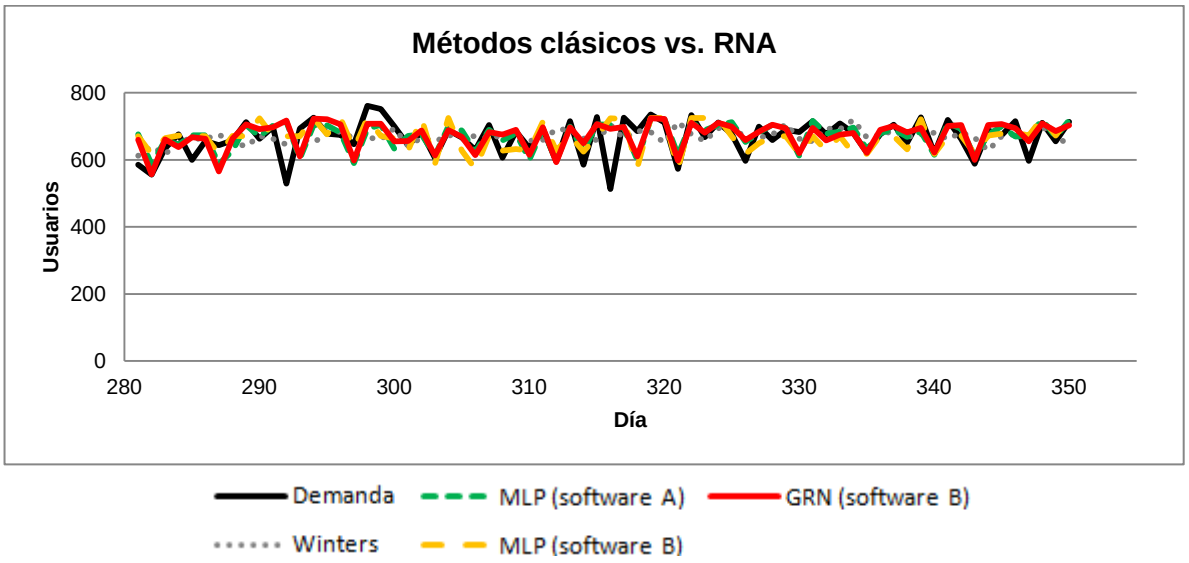
Tabla 24. Indicadores de la evaluación de los métodos clásicos de pronósticos y las Redes Neuronales Artificiales para la demanda diaria de los empleados.

Método / Red	MAD	Desv. MAD	ECM	Desv. ECM
Promedio Móvil	40,68	50,85	2.790,23	52,82
SES	41,39	51,74	2.797,67	52,89
SED	41,76	52,20	2.895,99	53,81
Combinado	40,76	50,95	2.790,09	52,82
Multiplicativo de Winters	42,13	52,66	3.026,19	55,01
MLP (software A)	32,07	40,09	2.289,67	47,85
MLP (software B)	35,12	43,90	2.395,72	48,95
GRN (software B)	30,24	37,80	2.112,62	45,96

Fuente: Los autores.

Basado en la información de la tabla 24 y la figura 38, se puede afirmar que los resultados obtenidos mediante el uso de las RNA respecto al de los métodos clásicos no presentan mejora significativa, teniendo en cuenta los valores del ECM. Esto se justifica debido a que el comportamiento de la demanda de los empleados no es muy variable y es perpetua o uniforme en el tiempo durante los periodos evaluados. Por lo tanto, se puede concluir que para este tipo de escenarios es mejor usar los métodos clásicos, ya que el desarrollo de un modelo de RNA requiere un gran esfuerzo y no se genera un mayor rendimiento.

Figura 38. Pronóstico obtenido con los métodos clásicos y las Redes Neuronales Artificiales para la demanda diaria de los empleados.



Fuente: Los autores.

A partir de estos resultados, se plantean las conclusiones a las que se llegan con este proyecto y se proponen algunos estudios o trabajos que pueden desarrollarse a partir de esta investigación. Esto será descrito en detalle en el siguiente capítulo.

6. CONCLUSIONES Y TRABAJOS FUTUROS

En este capítulo se presentan las conclusiones resultantes en este proyecto y se plantean propuestas de investigación futuras que podrían llevarse a cabo tomando como base los resultados obtenidos en este trabajo.

6.1 CONCLUSIONES

Pronosticar la demanda en sistemas no lineales o con variabilidad muy alta, puede ser poco eficiente mediante el uso de los métodos clásicos. El principal problema que presentan es que requieren de un mayor tiempo para ajustarse al comportamiento de la serie. Lo anterior, se comprobó al realizar una evaluación de estos métodos en la generación del pronóstico de la demanda para el servicio de almuerzo en el restaurante de la Universidad del Valle.

A partir de un análisis de los datos históricos, se encontraron cuatro factores que afectan la demanda del restaurante universitario, los cuales corresponden a la fecha (día, mes, año), el día de la semana, la época del semestre y el menú servido. Estos factores presentaron variabilidades significativas, así como comportamientos no lineales y discontinuos respecto a la demanda.

La evaluación realizada con los métodos clásicos para el caso de estudio arrojó que el Promedio Móvil, la Suavización Exponencial Simple (SES) y la Suavización Exponencial Doble (SED), al no contemplar la influencia de la estacionalidad en los períodos evaluados, presentan errores más altos que su similar el método Multiplicativo de Winters. Este último fue el método clásico que presentó un mejor rendimiento al pronosticar la demanda para el escenario propuesto, generando un ECM más bajo que los demás.

Sin embargo, el rendimiento de estos métodos es inferior comparado al obtenido con el modelo basado en RNA, ya que éste presenta un valor más bajo para el ECM que los clásicos, al identificar los factores que influyen en la demanda y ajustarse rápidamente al comportamiento real de ésta. De igual manera, se encontró que de los dos tipos de redes

simuladas, el Perceptrón Multicapa (MLP) y la Red de Regresión Generalizada (GRN), esta última fue la que presentó mejores resultados, al ser su ECM el más bajo de la evaluación.

Con base en lo anterior, este estudio concluye que utilizar un modelo basado en RNA es mejor alternativa que los métodos clásicos para pronosticar la demanda en sistemas productivos donde la serie es no lineal y discontinua, como la que se presenta en el restaurante de la Universidad del Valle. Esto debido a la capacidad que tiene de ajustarse rápidamente a los cambios producidos en el comportamiento de la demanda, a causa de los diferentes factores que puedan afectarla.

En sistemas donde el comportamiento de la demanda no es muy variable y se convierte en perpetua, se sugiere usar mejor los métodos clásicos, ya que el desarrollo de un modelo de RNA requiere un gran esfuerzo y los resultados obtenidos respecto a los clásicos no presentan una mayor mejora.

6.2 TRABAJOS FUTUROS

Este trabajo puede ser la base de un proyecto que investigue la aplicación de las Redes Neuronales Artificiales para la elaboración del pronóstico de la demanda de productos de consumo masivo como el caso de la producción de medicamentos. Su análisis debe hacerse a través de factores específicos encontrados en un estudio de investigación.

Respecto al caso estudio revisado, se sugiere evaluar el impacto económico de la sub y sobre-producción generada por el no uso de un método adecuado para pronosticar la demanda. La sub-producción, requiere una cantidad adicional de almuerzos a la proyectada debido al ingreso inesperado de usuarios; dando como resultado, mayor presión y trabajos extras en el área de cocinas, así como posibles incrementos de los costos productivos cuando se debe compensar a los clientes reemplazando un producto faltante en el menú por uno de mayor valor. Por otra parte, la sobre-producción conduce al desperdicio de los alimentos, contribuyendo a incrementar los costos de la operación, entre otras cosas, por el manejo adicional que los alimentos requieren; incluso si éstos pueden ser integrados al menú del día siguiente, se incurriría en costos adicionales de

almacenamiento, reduciendo la calidad de los mismos e incrementando el riesgo de contaminación.

Adicionalmente, se plantea el estudio de otros factores que pueden tener influencia en el comportamiento de la demanda en el restaurante de la Universidad del Valle, como el perfil socio-económico de los estudiantes y empleados que hacen uso constante del servicio de almuerzo, o las proyecciones de crecimiento de la demanda. Esto último, a causa del incremento en la cobertura educativa por parte del Gobierno Nacional y el ingreso de los nuevos estudiantes a la Universidad del Valle en el inicio del año, debido al cambio de calendario de los colegios públicos en la ciudad de Santiago de Cali.

Para finalizar, se plantea el uso de otras tecnologías de Inteligencia Artificial como los Algoritmos Genéticos, los Sistemas Difusos o las Redes Bayesianas, para el desarrollo de nuevos modelos para pronosticar la demanda de productos o servicios. Se sostiene lo planteado por Zhang et al (1998), es decir, que el futuro de la generación de pronósticos mediante el uso de tecnologías de Inteligencia Artificial y en especial de las Redes Neuronales Artificiales, será brillante en la medida que más esfuerzos de investigación se dediquen a este campo de estudio.

BIBLIOGRAFÍA

Adya, M. y Collopy, F. (1998). How Effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation. Journal of Forecasting, 17: 481-495.

Anderson, D.R., Sweeney, D.J. y Williams, T.A. (2004). Métodos cuantitativos para los negocios. México: International Thomson Editores, novena edición.

Bacha, M. y Meyer, W. (1992). A neural network architecture for load forecasting. Proceedings of the IEEE International Joint Conference on Neural Networks, 2: 442-447.

Bazán, N. (2012). Nuevas herramientas de investigación: Las Redes Neuronales. Revista electrónica de Ciencias Aplicadas al Deporte, 5; 17.

Beccali, M., Cellura, M., Lo Brano, V. y Marvuglia, A. (2004). Forecasting daily urban electric load profiles using artificial neural networks. Energy Conversion and Management, 45; 2879-2900.

Bienestar UV (2012). Política de Bienestar Universitario. Consultado el 12 de abril del 2012. Disponible en http://vicebienestar.univalle.edu.co/vicerrectoria/Politica%20VBU.pdf.

Bishop, C.M. (1995). Neural Networks for Pattern Recognition: Estados Unidos: Oxford University Press, primera edición.

Blecher, L. (2004). Using forecasting techniques to predict meal demand in Title IIIc congregate lunch programs. Journal of the American Dietetic Association, 104: 1281-1283.

Bowerman, B.L., O'Connell, R.T. y Koehler, A.B. (2007). Pronósticos, series de tiempo y regresión: un enfoque aplicado. Mexico: Cengage Learning Editores, cuarta edición.

Box, G.E.P. y Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control. Estados Unidos: Holden-Day.

Bustamante, E. (2007). El sistema nervioso: desde las neuronas hasta el cerebro humano. Colombia: Universidad de Antioquia, primera edición.

Caicedo, E.F. y López, J.A. (2009). Una aproximación práctica a las redes neuronales artificiales. Colombia: Universidad del Valle, primera edición.

Castaño, N., Montoya, O.L. y Velásquez, J.D. (2009). Una comparación entre los modelos de componentes no observables y las redes neuronales artificiales. Revista Avances en Sistemas e Informática, 6; 191-195.

Chase, C. (2009). Demand-Driven Forecasting: A Structured Approach to Forecasting. Estados Unidos: John Wiley&Sons, Inc., primera edición.

Chen, F.I. y Ou, T.Y. (2009). Gray relation analysis and multilayer functional link network sales forecasting model for perishable food in convenience store. Expert Systems with Applications, 36: 7054-7063.

Consejo Superior UV (1997). Acuerdo No. 009: Noviembre 13 de 1997. Consultado el 12 de abril del 2012. Disponible en http://secretariageneral.univalle.edu.co/consejo-superior/reglamento-estudiantil/acuerdo%20009.pdf.

Consejo Superior UV (2006). Resolución No. 067: Septiembre 29 de 2006. Consultado el 12 de abril del 2012. Disponible en http://secretariageneral.univalle.edu.co/consejo-superior/resoluciones/2006/RCS-067.pdf.

Dayhoff, J.E. y DeLeo, J.M. (2001). Artificial neural networks. Cancer, 91: 1615-1635.

Doganis, P., Alexandridis, A., Patrinos, P. y Sarimveis, H. (2006). Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. Journal of Food Engineering, 75: 196-204.

El Espectador (2011). Reforma educativa, ¿sí o no? Consultado el 30 de abril del 2012. Disponible en http://www.elespectador.com/impreso/nacional/articulo-305218-reforma-educativa-si-o-no

Fitzsimmons, J.A. y Fitzsimmons, M.J. (2006). Service Management: Operations, Strategy, and Information Technology. Estados Unidos: McGraw-Hill, quinta edición.

Flórez, R. y Fernández, J.M. (2008). Las Redes Neuronales Artificiales: Fundamentos teóricos y aplicaciones prácticas. España: NetBiblo S.L., primera edición.

Ghiassi, M., Saidane, H. y Zimbra, D.K. (2005).A dynamic artificial neural network model for forecasting time series events. International Journal of Forecasting, 21; 341-362.

Gorr, W.L., Nagin, D. y Szczypula, J. (1994). Comparative study of artificial neural network and statistical models for predicting student grade point averages. International Journal of Forecasting, 10: 17-34.

Gutierrez, R.S., Solis, A.O. y Mukhopadhyay, S. (2008). Lumpy demand forcasting using neural networks. International Journal of Production Economics, 111; 409-420.

Hamzaçebi, C. (2008). Improving artificial neural networks' performance in seasonal timeseries forecasting.Information Sciences, 178; 4550-4559.

Hann, T.H. y Steurer, E. (1996). Much ado about nothing? Exchange rate forecasting: Neural networks vs. linear models using monthly and weekly data. Neurocomputing, 10: 323-339.

Haykin, S. (2005). Neural Networks: A Comprehensive Foundation. India: Prentice Hall, novena edición.

Hirschey, M. (2008). Managerial Economics. Estados Unidos: South-Western Pub, duodécima edición.

Khashei, M. y Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. Experts Systems with Applications, 37; 479-489.

Krajewski, L.J. y Ritzman, L.P. (2000). Administración de operaciones: estrategia y análisis. México: Pearson Educación, quinta edición.

Lahoz-Beltrá, R. (2004). Bioinformática: Simulación, vida artificial e inteligencia artificial. España: Ediciones Díaz de Santos.

La Silla Vacía (2011). Los cinco puntos que enfrentan a los estudiantes y profesores con la Ministra. Consultado el 30 de abril del 2012. Disponible en http://www.lasillavacia.com/historia/los-cinco-puntos-que-enfrentan-los-estudiantes-y-profesores-con-la-ministra-23117

Lubero, R.G. (1991). Neural networks for water demand time series forecasting. Proceedings of the International Workshop on Artificial Neural Networks, 453-460.

Masters, T. (1995). Advanced Algorithms for Neural Networks. Estados Unidos: Wiley, primera edición.

McCulloch W.S. y Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5; 115-133.

Mena, N.A., Lario, F.C. y Vicens, E. (2006). Planificación de la Demanda en la Gestión de Cadena de Suministro con Redes Neuronales y Lógica Difusa. X Congreso de Ingeniería de Organización. Valencia, España.

Nojek, S., Britos, P., Rossi, B. y García Martínez, R. (2003). Pronostico de Ventas: comparación de predicción basado en Redes Neuronales versus Método Estadístico. Reportes técnicos en Ingeniería del Software, 5: 1-12.

Park, J. y Sandberg, I.W. (1991). Universal approximation and radial basis function networks. Neural Computation, 3: 246-257.

Pino, R., Gómez, G. y De Abajo, N. (2001). Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva. España: Universidad de Oviedo.

Planeación UV (2011). Universidad del Valle en cifras. Consultado el 12 de abril del 2012. Disponible en http://paginasweb.univalle.edu.co/~planeacion/Analisis/Documentos/UVCifras/ uv-cifras_2011-II.pdf.

Render, B., Stair Jr, R.M. y Hanna, M.E. (2006). Métodos cuantitativos para los negocios. México: Prentice Hall, novena edición.

Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. Psychological Review, 65; 386-408.

Ryu, K., Jang, S. y Sanchez, A. (2003). Forecasting Methods and Seasonal Adjustment for a University Foodservice Operation. Journal of Foodservice Business Research, 6: 17-34.

Salazar, M.A., Moreno, G.J. y Cabrera, M. (2006). Statistical characterization and optimization of artificial neural networks in time series forecasting: The one-period forecast case. Computación y sistemas, 10; 69-81.

Sanchez, A., Miller, J.L. y Sanchez, N. (1995). Foodservice Forecasting: A Comparative Study of Exponential Smoothing and Expert System Models. Journal of the American Dietetic Association, 95: A40.

Shah, J. (2009). Supply Chain Management: Text and Cases. India: Pearson Education Inc, primera edición.

Sharda, R. (1994). Neural networks for the MS/OR analyst: An application bibliography. Interfaces, 24: 116-130.

Silver, E.A., Pyke D.F. y Peterson, R. (1998). Inventory Management and Production Planning and Scheduling. Estados Unidos: John Wiley&Sons, Inc., tercera edición.

Specht, D.F. (1991). A General Regression Neural Networks. IEEE Transactions on Neural Networks, 2; 568-576.

Srinivasan, D., Liew, A.C. y Chang, C.S. (1994). A neural network short-term load forecaster. Electric Power Systems Research, 28: 227-234.

Tang, Z., Almeida, C. y Fishwick, P.A. (1991). Time series forecasting using neural networks vs Box-Jenkins methodology. Simulation, 57: 303-310.

Toro, E.M., Mejía, D.A. y Salazar, H. (2004). Pronóstico de ventas usando redes neuronales. Scientia et Technica, 26: 25-30.

Vera, M. y Bustamante, J. (2007). Modelo dinámico para la generación de pronóstico usando redes neuronales artificiales. Visión gerencial, 6; 130-142.

Vidal, C.J. (2010). Fundamentos de Control y Gestión de Inventarios. Colombia: Universidad del Valle, primera edición.

Villada, F., Cadavid, D.R. y Molina, J.D. (2008). Pronóstico del precio de la energía eléctrica usando redes neuronales artificiales. Revista de Ingeniería de la Universidad de Antioquia, 44; 111-118.

Wang, L. y Fu, K. (2009). Artificial Neural Networks. Wiley Encyclopedia of Computer Science and Engineering, 181-188.

Werbos, P. (1974). Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis. Harvard University.

Winters, P.R. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. Management Science, 6; 324-342.

Yang, X (2009). Artificial Neural Networks. Handbook of Research on Geoinformatics. IGI Global, 122-128.

Zhang, G., Patuwo, B.E. y Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 14: 35-62.

Zhang, G.P. y Qi, M. (2005). Neural network forecasting for seasonal and trend time series, 160; 501-514.

Zhan, R., Chen, R., Xie, X. y Wu, G. (2008). A Case-Based Reasoning System for Individual Demand Forecasting. 4th International Conference on Wireless Communications, Networking and Mobile Computing, 1-6.