


UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA



ESTIMACIÓN Y PLANIFICACIÓN DE LA  
RECOLECCIÓN DE PRODUCTOS RETORNABLES EN  
UNA EMPRESA CERVECERA

POR

DANIEL ALEJANDRO LOERA ZERMEÑO

EN OPCIÓN AL GRADO DE

MAESTRÍA EN CIENCIAS

EN INGENIERÍA DE SISTEMAS


SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

JULIO 2016

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA

SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



ESTIMACIÓN Y PLANIFICACIÓN DE LA  
RECOLECCIÓN DE PRODUCTOS RETORNABLES EN  
UNA EMPRESA CERVECERA

POR

DANIEL ALEJANDRO LOERA ZERMEÑO

EN OPCIÓN AL GRADO DE

MAESTRÍA EN CIENCIAS

EN INGENIERÍA DE SISTEMAS

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

JULIO 2016

**Universidad Autónoma de Nuevo León**  
**Facultad de Ingeniería Mecánica y Eléctrica**  
**Subdirección de Estudios de Posgrado**

Los miembros del Comité de Tesis recomendamos que la Tesis «Estimación y planificación de la recolección de productos retornables en una empresa cervecera», realizada por el alumno Daniel Alejandro Loera Zermeño, con número de matrícula 1266447, sea aceptada para su defensa como opción al grado de Maestría en Ciencias en Ingeniería de Sistemas.

El Comité de Tesis

---

Dra. María Angélica Salazar Aguilar  
Asesor

---

Dr. Vincent André Lionel Boyer  
Revisor

---

Dra. María Guadalupe Villarreal Marroquín  
Revisor

Vo. Bo.

---

Dr. Simón Martínez Martínez  
Subdirector de Estudios de Posgrado

San Nicolás de los Garza, Nuevo León, Julio 2016

*A Mi Familia*

# ÍNDICE GENERAL

---

<b>Agradecimientos</b>	<b>XI</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Justificación . . . . .	2
1.2. Hipótesis . . . . .	3
1.3. Objetivos . . . . .	3
1.4. Metodología de la Investigación . . . . .	4
1.5. Estructura de la Tesis . . . . .	4
<b>2. Conceptos Generales y Trabajo Relacionado</b>	<b>6</b>
2.1. Correlación . . . . .	6
2.2. Redes Neuronales Artificiales . . . . .	8
2.2.1. Red Neuronal Artificial (RNA) . . . . .	9
2.2.2. Pronósticos con RNAs . . . . .	19
2.3. Logística Inversa . . . . .	23
2.3.1. Revisión de Literatura Logística Inversa . . . . .	25

---

<b>3. Correlación venta-retorno</b>	<b>28</b>
3.1. Análisis de Correlación por SKU . . . . .	28
<b>4. Pronóstico de Retorno con RNAs</b>	<b>40</b>
4.0.1. Modelos de pronóstico basados en RNAs . . . . .	40
4.1. RNA vs Promedios Móviles . . . . .	41
4.2. Estimaciones de Retorno por SKU . . . . .	44
<b>5. Planificación de la Recolección de Envases Retornables</b>	<b>62</b>
5.1. Descripción del modelo de optimización . . . . .	63
5.1.1. Formulación . . . . .	63
5.1.2. Ejemplo de solución . . . . .	66
5.2. Metodología basada en la experiencia . . . . .	66
5.2.1. <b>Caso de estudio</b> . . . . .	67
<b>6. Conclusiones</b>	<b>69</b>

# ÍNDICE DE FIGURAS

---

2.1. Correlación entre dos variables . . . . .	7
2.2. Partes de una neurona biológica . . . . .	9
2.3. Esquema de una Red Neuronal Artificial Multicapa . . . . .	10
2.4. Función Lineal . . . . .	13
2.5. Función Escalón . . . . .	13
2.6. Función Mixta . . . . .	14
2.7. Función Sigmoide . . . . .	15
2.8. Función gauss . . . . .	15
2.9. Función sinusoidal . . . . .	16
2.10. Arquitecturas de RNAs utilizadas en trabajos relevantes . . . . .	22
2.11. Ciclo de Logística Tradicional y Ciclo de Logística Inversa . . . . .	24
3.1. Observaciones venta-retorno de SKU 1 . . . . .	33
3.2. Observaciones venta-retorno de SKU 2 . . . . .	33
3.3. Observaciones venta-retorno de SKU 3 . . . . .	34

---

3.4. Observaciones venta-retorno de SKU 4 . . . . .	34
3.5. Observaciones venta-retorno de SKU 5 . . . . .	34
3.6. Observaciones venta-retorno de SKU 6 . . . . .	35
3.7. Observaciones venta-retorno de SKU 7 . . . . .	35
3.8. Observaciones venta-retorno de SKU 8 . . . . .	35
3.9. Observaciones venta-retorno de SKU 9 . . . . .	36
3.10. Observaciones venta-retorno de SKU 10 . . . . .	36
3.12. Observaciones venta-retorno de SKU 12 . . . . .	36
3.11. Observaciones venta-retorno de SKU 11 . . . . .	37
3.13. Observaciones venta-retorno de SKU 13 . . . . .	37
3.15. Observaciones venta-retorno de SKU 15 . . . . .	37
3.14. Observaciones venta-retorno de SKU 14 . . . . .	38
3.16. Observaciones venta-retorno de SKU 16 . . . . .	38
3.17. Observaciones venta-retorno de SKU 17 . . . . .	38
3.18. Observaciones venta-retorno de SKU 18 . . . . .	39
4.1. Pronóstico de retorno SKU 1 . . . . .	44
4.2. Pronóstico de retorno SKU 2 . . . . .	45
4.3. Pronóstico de retorno SKU 3 . . . . .	46
4.4. Pronóstico de retorno SKU 4 . . . . .	47
4.5. Pronóstico de retorno SKU 5 . . . . .	48



---

4.6. Pronóstico de retorno SKU 6 . . . . .	49
4.7. Pronóstico de retorno SKU 7 . . . . .	50
4.8. Pronóstico de retorno SKU 8 . . . . .	51
4.9. Pronóstico de retorno SKU 9 . . . . .	52
4.10. Pronóstico de retorno SKU 10 . . . . .	53
4.11. Pronóstico de retorno SKU 11 . . . . .	54
4.12. Pronóstico de retorno SKU 12 . . . . .	55
4.13. Pronóstico de retorno SKU 13 . . . . .	56
4.14. Pronóstico de retorno SKU 14 . . . . .	57
4.15. Pronóstico de retorno SKU 15 . . . . .	58
4.16. Pronóstico de retorno SKU 16 . . . . .	59
4.17. Pronóstico de retorno SKU 17 . . . . .	60
4.18. Pronóstico de retorno SKU 18 . . . . .	61
5.1. Ejemplo de solución . . . . .	66

# ÍNDICE DE TABLAS

---

2.1. Historia de redes neuronales artificiales . . . . .	11
2.2. Algoritmos de aprendizaje . . . . .	18
3.1. Mejor correlación venta-retorno, venta realizada en la semana $t$ y retorno registrado en la semana que se muestra en la tabla. . . . .	30
3.2. Cantidad de SKUs en los que el retorno registrado en la semana $t$ se relaciona con la venta realizada $t - 1$ semanas atrás, para $t > 1$ . Si $t = 1$ , el retorno de la semana actual se relaciona con la venta de la misma semana. . . . .	31
4.1. Comparación de ECM para cada SKU: RNAs vs Promedios Móviles .	42

# AGRADECIMIENTOS

---

Esta tesis es el trabajo de dos años, durante los cuales tuve la fortuna de contar con el apoyo de personas e instituciones que merecen mis más sinceros agradecimientos por la oportunidad otorgada y por contribuir a mi crecimiento personal y profesional.

Agradezco a la Universidad Autónoma de Nuevo León, a la Facultad de Ingeniería Mecánica y Eléctrica y al Programa de Posgrado en Ingeniería de Sistemas por haberme dado la oportunidad de ser parte del posgrado, asimismo agradezco al Consejo Nacional de Ciencia y Tecnología por haberme otorgado una beca que me permitió entrar al posgrado que tanto deseaba.

Agradezco de manera personal, a mi familia, padres, esposa, y suegros que me apoyaron en los momentos difíciles, que tuve en el transcurso de los estudios del posgrado. A mis compañeros de YALMA y de generación por su ayuda en durante los cursos de la maestría, y por los momentos vividos en la convivencia diaria.

Mis más sinceros agradecimientos a mi directora de tesis la Dra. Angélica Salazar, por haberme apoyado en el transcurso del tiempo de la Maestría, por ser una excelente profesora y como directora de tesis, por los comentarios y revisiones realizadas para mejorar mi trabajo. Agradezco de manera personal por haber escuchado y aconsejado en momentos difíciles pasados en el transcurso de la maestría.

---

Agradezco a mis revisores Dr. Vincent Boyer y Dra. María Guadalupe Villarreal Marroquín por dedicar su tiempo a la lectura de este trabajo y por los comentarios realizados.

Daniel Alejandro Loera Zermeño  
San Nicolás de los Garza, Nuevo León, 2016.

## CAPÍTULO 1

# INTRODUCCIÓN

---

En las empresas embotelladoras, la reutilización de productos retornables es una práctica común y la planificación de su recolección y manejo pertenece al área de logística inversa. Rogers et al. [1999] define a la logística inversa como "*El proceso de planificación, ejecución y control eficaz del costo de flujo de las materias primas, el inventario en proceso, el producto terminado y la información relacionada desde el punto de consumo hasta el punto de origen, con el fin de recuperar su valor o su correcta eliminación . Más precisamente, la logística inversa es el proceso de mover mercancías desde su destino final típico con el propósito de capturar valor, o su correcta eliminación.*". Las actividades de refabricación y reacondicionamiento también se pueden incluir en la definición de la logística inversa

La logística inversa es una práctica que poco a poco se está volviendo común puesto que permite minimizar costos de producción y contribuir a la protección del medio ambiente. Los primeros vestigios de la logística inversa pueden datar, de la industria de lácteos, al momento de recolectar los frascos de vidrio que contenían el producto vendido.

Esta tesis consiste en el estudio de tres diferentes situaciones que enfrenta el área de logística inversa de una empresa cervecera. En primer lugar, se estudia el ciclo de retorno de productos retornables mediante un análisis de correlación

venta-retorno. En segundo lugar, se estudia el pronóstico del retorno de envases retornables; para esta situación se propone un modelo de predicción basado en Redes Neuronales Artificiales (RNAs). Finalmente, se estudia la planeación de la recolección de productos retornables y la compra de envases nuevos para satisfacer la demanda en las plantas de producción al costo mínimo; en este caso se propone un modelo lineal entero mixto que permite planificar la recolección de envases retornables desde centros de distribución y plantas, así como la compra de envase nuevo a proveedores.

Los resultados experimentales revelaron que para cada tipo de envase (SKU) tiene un ciclo de retorno distinto y en varios casos se observó que la venta de una semana  $t$  se relaciona con el retorno de la misma semana. Con respecto a los pronósticos, las RNAs utilizadas fueron capaces de reportar pronósticos con menor error cuadrático medio que el método de promedios móviles. Además, el modelo de programación lineal entera mixta en conjunto con CPLEX permitió la obtención de resultados que superan el desempeño de la metodología basada en la experiencia del tomador de decisiones.

## 1.1 JUSTIFICACIÓN

Existen en la literatura muchos problemas de logística inversa que tienen implementaciones en diferentes ramas de la industria, tales como el área de electrodomésticos (Casas et al. [2015]), equipo de cómputo (Olivares [2006]), envases retornables de plaguicidas (Castañeda et al. [2014]), etc. En la práctica, diferentes industrias como las de refresco y las de cerveza (tal como es el caso en esta tesis), son las empresas más populares para implementar técnicas de logística inversa ya que los industriales ven en sus envases de vidrio un activo para la empresa.

La industria tiene un gran interés en la implementación de diversas metodologías de logística inversa o ingeniería reversa dado que esto representa un ahorro económico para la empresa. Si se encuentran en buen estado los productos recolecta-

dos y/o requieren una reparación sencilla, estos pueden salir a la venta nuevamente sin tener un alto costo de producción para la empresa. En el caso de los envases retornables, el costo de la reutilización de los productos incluye principalmente costos de recolección (transporte), de inspección y de lavado.

## 1.2 HIPÓTESIS

- El ciclo de retorno de los envases retornables es de ocho semanas.
- Las RNAs son una alternativa capaz de proveer mejores pronósticos del retorno de envases que el método de promedios móviles.
- Un modelo de optimización permitirá representar de manera adecuada la recolección de envases desde centros de distribución hacia plantas, la ayuda entre plantas y la compra de envase nuevo, para minimizar los costos totales de recolección y compra de envases.

## 1.3 OBJETIVOS

- Realizar un análisis de correlación venta-retorno de los principales productos retornables que maneja la empresa. Esto con el fin de estimar el ciclo de retorno de cada producto.
- Proponer un método que sea capaz de generar pronósticos confiables del retorno de envases y que permita una mejor estimación realizada mediante promedios móviles.
- Formular el problema de recolección de envases desde centros de distribución hacia plantas, considerando la ayuda entre las diferentes plantas de la empresa, así como la compra de envase nuevo; esto con el fin de minimizar los costos totales de recolección de envases retornables y compra de envase nuevo.

## 1.4 METODOLOGÍA DE LA INVESTIGACIÓN

La metodología que se siguió para la realización de la tesis se presenta a continuación

- Estudio de diversos problemas que enfrenta el departamento de logística inversa en una empresa cervecera.
- Visitas a la empresa y recolección de información.
- Revisión del estado del arte de problemas de logística inversa.
- Análisis de correlación venta-retorno de los principales productos (diferentes presentaciones de envase) que maneja la empresa.
- Formulación del modelo matemático de la aplicación de la logística inversa dentro de la empresa.
- Validación del modelo matemático en una instancia real, el modelo se escribió en GAMS y se resolvió con CPLEX.
- Diseño de las redes neuronales artificiales multicapa en el Software Estadístico R (para cada uno de los productos de la empresa).
- Experimentación con las redes neuronales artificiales.
- Análisis de los resultados obtenidos.
- Escritura de la tesis

## 1.5 ESTRUCTURA DE LA TESIS

El Capítulo 1 presenta una breve introducción al caso de estudio, en este se define la motivación, objetivos y metodología que se siguió para el desarrollo de esta



tesis.

En el Capítulo 2 se discuten conceptos básicos relacionados a los diversos temas relacionados con esta tesis: análisis de correlación, redes neuronales artificiales y logística inversa.

En el Capítulo 3 se presenta un análisis de correlación venta-retorno, realizado para cada uno de los principales productos (SKUs) que maneja la empresa.

En el Capítulo 4 se muestra el diseño experimental que se llevó a cabo con las RNAs, así como los resultados obtenidos y su comparación con el método de promedios móviles.

En el Capítulo 5, se presenta el modelo matemático propuesto para representar la recolección de envases desde centros de distribución a plantas, ayuda entre plantas y compra de envase nuevo. Así como los resultados obtenidos por CPLEX y los que se obtienen al implementar el procedimiento que toma lugar en la práctica.

Finalmente, en el Capítulo 6 se muestran las conclusiones del trabajo realizado.

## CAPÍTULO 2

# CONCEPTOS GENERALES Y TRABAJO RELACIONADO

---

En este capítulo se presentan los conceptos básicos y trabajos relacionados con los temas más importantes en esta tesis: análisis de correlación, redes neuronales artificiales y logística inversa.

### 2.1 CORRELACIÓN

De acuerdo con Martínez Ortega et al. [2009], la correlación expresa el grado de asociación entre dos variables, según el sentido de la relación de estas en términos más de aumento o de disminución.

Una definición de correlación simple, se cita como el análisis que se ocupa de medir la relación entre una sola variable independiente y la variable dependiente.

La fórmula matemática de la correlación propuesta en el libro Fundamentos de Estadística de Peña [2014] es la siguiente:

$$r = \frac{Cov(x, y)}{S_x S_y} \quad (2.1)$$

Donde:

- $S_x$  y  $S_y$  son las desviaciones típicas de  $x$  y  $y$ .
- $Cov(x, y)$  es la covarianza de  $x$  y  $y$ .

Es importante recordar que el coeficiente de correlación es una medida resumen de la estructura de un diagrama de dispersión, por eso siempre conviene graficar la información necesaria. Observando la gráfica nos ayuda a llegar a una conclusión si las variables a las que estamos haciendo el análisis tienen un alto grado de correlación.

Un ejemplo de cómo podemos identificar gráficamente, si dos variables cuentan con algún grado de correlación se ve en la Figura 2.1.




Figura 2.1: Correlación entre dos variables

van Dalen et al. [2005] describen un trabajo realizado en Holanda por el grupo Heineken, en el cual se instaló una prueba piloto que consistió en marcar las cajas

con chip. El objetivo del proyecto consiste en medir el tiempo total de circulación de las cajas marcadas a través de la cadena logística Red Hat Package Manager (RPM). El chip contiene la información de la caja de las botellas y complementa la información existente acerca de la duración de almacenamiento de la caja en la cervecería, este conteo está basado en conteos diarios del RPM lleno y vacío.

Es este trabajo, es importante determinar la correlación entre las ventas y el retorno de envases retornables. De ahí que la variable independiente serán las ventas y la dependiente el retorno. En el siguiente capítulo se mostrarán los resultados de este análisis.

## 2.2 REDES NEURONALES ARTIFICIALES

Una red neuronal artificial es un procesador paralelo distribuido masivamente, formado por unidades de proceso simples, las cuales son naturalmente propensas para el almacenamiento exponencial de conocimiento y ponerlo disponible para su uso. Se asemejan con el cerebro en dos aspectos:

- El conocimiento es adquirido por la red desde su ambiente a través del proceso de aprendizaje.
- Las fuerzas de la conexión entre neuronas, conocida como pesos sinápticos, son usadas para almacenar el aprendizaje adquirido.

**Red Neuronal Biológica** La red neuronal biológica está constituida por las partes que se muestran en la Figura 2.2.

Las neuronas y las conexiones entre ellas que se llaman potenciales de acción, son una serie breve de pulsos periódicos y se propagan a través del axón, después llega a la sinapsis (que es la interconexión entre dos neuronas) y esta es la clave para el procesamiento de la información.




Figura 2.2: Partes de una neurona biológica.

Fuente:<https://gruporedesneuronales.wordpress.com/redes-neuronales/>

### 2.2.1 RED NEURONAL ARTIFICIAL (RNA)

Las redes neuronales artificiales (RNA) pueden verse como una implementación abstracta de los sistemas nerviosos biológicos, están constituidas por un conjunto de neuronas o nodos conectados entre sí.

El primer modelo de red neuronal fue propuesto por McCulloch and Pitts [1943]. En el modelo propuesto, se implementó un algoritmo binario, donde cada neurona tenía un escalón o un umbral preespecificado y sirvió de base para los modelos posteriores.

Las redes neuronales artificiales tienen aplicaciones en diversos campos tales como, modelación, análisis de series de tiempo, reconocimiento de patrones, procesamiento de señales y control, debido a una propiedad muy importante: la habilidad para aprender de los datos de entrada (ver Haykin [2001]).

En el área de análisis de series de tiempo, las aplicaciones más relevantes de las RNAs son en las predicciones de ventas, inventarios, consumo de energía, y retorno

de productos. En la Tabla 2.2.1, se muestra un poco de la historia de las redes neuronales, desde los pioneros de esta área hasta los avances más significativos que han tenido.

Existen diferentes arquitecturas de las RNAs, la más usada en el análisis de series de tiempo es la arquitectura multi-capa. En la Figura 2.3 se muestra una representación gráfica de una Red Neuronal Artificial de tres capas.




Figura 2.3: Esquema de una Red Neuronal Artificial Multicapa,

Fuente: Cabello et al. [2005]

Las redes neuronales artificiales multicapa, como lo explica Wang [2003], están constituidas por múltiples capas, la primera capa son las neuronas de entrada (recibe los datos de entrada), las siguientes son capas ocultas, en cada una de las neuronas ocultas se tiene una función de activación, y finalmente se tiene una capa de salida, la cual reporta el resultado de la estimación.

Las características más importantes de la RNA son las siguientes:

- Auto-Organización y Adaptabilidad : Utilizan algoritmos de aprendizaje adaptativos y auto-organización, por lo que ofrecen mejores posibilidades de procesamiento robusto y adaptativo.
- Procesado no Lineal: aumenta la capacidad de la red para aproximar funciones,

Año	Autor	Aporte
1936	Alan Turing	Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación
1943	Warren McCulloch/Walter Pitts	Modelaron una red neuronal simple mediante circuitos eléctricos.
1949	Donald Hebb	Explicó que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados.
1950	Karl Lashley	Encontró que la información no era almacenada en forma centralizada en el cerebro, sino que era distribuída encima de él.
1956	Congreso de Dartmouth.	En este año fue el nacimiento de la inteligencia artificial.
1957	Frank Rosenblatt	Comenzó el desarrollo del Perceptron. Esta es la red neuronal más antigua.
1959	Frank Rosenblatt	En el libro Principios de Neurodinámica se confirmó que, bajo ciertas condiciones, el aprendizaje del Perceptron convergía hacia un estado finito
1960	Bernard Widrow/Marcian Hoff	Desarrollaron el modelo Adaline. Esta fue la primera red neuronal aplicada a un problema real.
1961	Karl Steinbeck/Die Lernmatrix	Red neuronal para simples realizaciones técnicas (memoria asociativa).
1969	Marvin Minsky/Seymour Papert	Probaron que el Perceptron no era capaz de resolver problemas relativamente fáciles.
1974	Paul Werbos	Desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás.
1977	Stephen Grossberg	La Teoría de Resonancia Adaptada. La misma simula habilidades del cerebro, memoria a largo y corto plazo.
1985	John Hopfield	Provocó el renacimiento de las redes neuronales con su libro: Computación neuronal de decisiones en problemas de optimización.
1986	David Rumelhart/G. Hinton.	Descubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation)

Tabla 2.1: Historia de redes neuronales artificiales

clasificar patrones y aumenta su inmunidad frente al ruido.

- Procesado Paralelo: normalmente se usa un gran número de nodos de procesado, con alto nivel de interconectividad.

Para el desarrollo de un modelo de RNAs existen dos fases principales:

**Fase de Entrenamiento:** se usan un conjunto de datos o patrones de entrenamiento para determinar los pesos(parámetros) que definen el modelo de red neuronal. Se calculan de manera iterativa de acuerdo con los valores de entrenamiento, minimizando el error del pronóstico.

**Fase de Prueba:** En la fase anterior, el modelo puede que se ajuste demasiado a las particularidades presentes en los patrones de entrenamiento, perdiendo su habilidad de generalizar su aprendizaje. Para evitar este problema es aconsejable utilizar un segundo grupo diferente a los de entrenamiento, conocido como grupo de validación, el cual permite controlar el proceso de aprendizaje.

La siguiente formulación descrita es una formula general de una red neuronal artificial propuesta por Tanco [2003].

$$\Theta_i = \sum_{i=1}^n W_i X_i \quad (2.2)$$

- La entrada  $X_i$  representa las señales que provienen de otras neuronas y que son capturadas por las dendritas.
- Los pesos  $W_i$  son la intensidad de la sinápsis que conecta dos neuronas, tanto  $X_i$  como  $W_i$  son valores reales.
- $\Theta_i$  es la función umbral que la neurona debe sobre pasar para activarse, este proceso ocurre biológicamente en el cuerpo de la célula.



**Funciones de Activación:** Existen múltiples funciones de activación, entre las más conocidas se encuentran las descritas en el libro López and Fernandez [2008]:

1. La *función lineal o identidad*, que devuelve directamente el valor de activación de la neurona. Este tipo de función se utiliza en redes de baja complejidad.




Figura 2.4: Función Lineal

2. La función *escalón o signo*, que presenta salidas binarias (habitualmente 0,1 o -1,1). En este caso, si la activación de la neurona es inferior a un determinado umbral, la salida se asocia con un determinado output y si es igual o superior al umbral, la salida se asocia con otro determinado output.




Figura 2.5: Función Escalón

3. La Función *Mixta o lineal por trozos*, es una variante progresiva de la función escalón. Si la activación de la unidad es menor que un límite inferior establecido, la salida se asocia con un determinado valor, si la activación es igual




Figura 2.6: Función Mixta

o superior que un límite superior, la salida se asocia con otro valor, si se encuentra comprometido entre ambos límites se utiliza la función identidad.

4. La Función *Sigmoide*, Definida en un determinado intervalo monótonico con límites superiores e inferiores. Entre las funciones sigmoides de transferencia más aplicadas destacan la función sigmoide o logística y la función tangente hiperbólica.

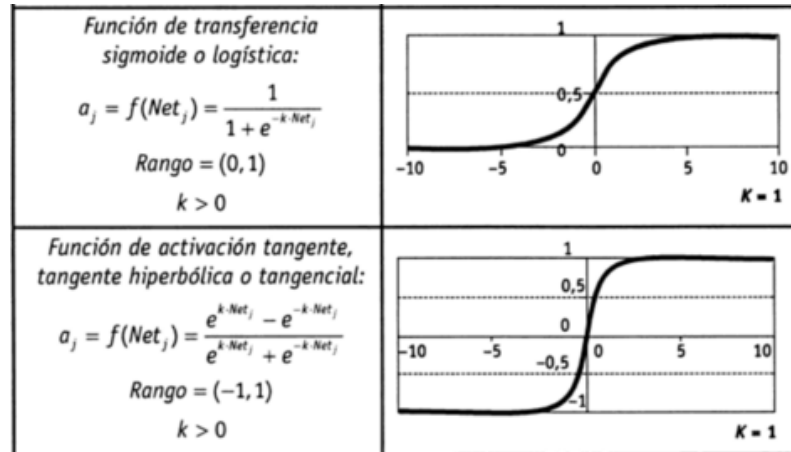


Figura 2.7: Función Sigmoide

5. La función *Gaussiana* que adapta la forma de una campana de Gauss cuyo centro, radio y apuntamiento son susceptibles de adaptación, lo que la hace muy versátil. Esta función suele aplicarse a redes complejas con  $m$  capas ocultas.




Figura 2.8: Función gauss

6. La Función *sinusoidal*, que genera salidas continuas en el intervalo  $[-1,+1]$ . Esta función suele emplearse en los casos en lo que requiere explícitamente una periodicidad temporal.




Figura 2.9: Función sinusoidal

Las redes neuronales se clasifican comúnmente en términos de sus correspondientes algoritmos o métodos de entrenamiento, redes de peso fijo, no supervisadas y supervisadas. Para las redes de pesos fijos no existe ningún tipo de entrenamiento.

**Reglas de Entrenamiento Supervisado** Los datos para este tipo de entrenamiento están constituidos por diferentes patrones de entrenamiento de entrada y salida. Cuando se conoce la salida implica que el entrenamiento se beneficia con la supervisión de un maestro.

**Reglas de Entrenamiento No Supervisado** Para este tipo de entrenamiento, el conjunto de datos que se utiliza consiste sólo en los patrones de entrada. Por lo tanto, la red aprende a adaptarse basada en las experiencias recogidas de los patrones de entrenamiento anteriores.

A continuación, en la Tabla 2.1 se muestran los diferentes paradigmas, reglas de aprendizaje, arquitectura, algoritmo de aprendizaje y tareas de RNAs, propuesta por Marín [2013].

Paradigma	Reglas de Aprendizaje	Arquitectura	Algoritmo de aprendizaje	Tareas
Supervisado	Corrección del error	Perceptrón o Perceptrón multicapa	retro propagación del error, ADALINE, MADALINE	Clasificación de Patrones, aproximación de funciones, predicción y control.
		Elma y Jordan recurrentes	Retro propagación del error	Síntesis de series temporales
	Boltzman	Recurrente	Boltzman	Clasificación de Patrones.
	Competitivo	Competitivo	LVQ	Categorización intra-clase, compresión de datos
Red ART		ARTMap	Clasificación de Patrones, Categorización intra-clase	
No Supervisado	Corrección del error	Red de Hopfield	Aprendizaje de memoria asociativa	Memoria asociativa
		Multicapa sin realimentación	Proyección de Sannon	Análisis de datos
	Competitiva	Competitiva	VQ	Categorización, compresión de datos
		SOM	Kohonen	Categorización, análisis de datos
Redes ART	ART1, ART2	Categorización		

Tabla 2.2: Algoritmos de aprendizaje

### 2.2.2 PRONÓSTICOS CON RNAs

Cottrell et al. [1995] utilizaron una RNA feed forward para modelar y pronosticar series de tiempo. Los autores enfrentaron el difícil problema de elección de arquitectura de las redes neuronales artificiales, lo cual los llevó a proponer una metodología sistemática para determinar los pesos que no son significativos y eliminarlos para simplificar la arquitectura. El método mencionado anteriormente se compara con otras técnicas de poda y se aplica a algunas series artificiales para observar su comportamiento.

Foster et al. [1992] realizaron una comparación entre diferentes metodologías para saber cuál es la que tenía el menor error de predicción. Compararon una RNA con los métodos de regresión lineal, media y suavización exponencial. Observaron que el uso de pre-procesamiento para eliminar la variación estacional mejoró los pronósticos de las RNAs.

Gorr et al. [1994] realizaron una comparación entre cuatro modelos, regresión lineal, regresión polinómica paso a paso, regresión lineal completamente conectada, que son modelos estadísticos y una RNA con una capa oculta, el caso donde se prueba la efectividad de los modelos de predicción es pronosticar el promedio de las calificaciones de los estudiantes de la Universidad Estatal de Dakota del Norte, esto con el fin de ayudar a la toma de decisiones en el proceso de admisión.

En el artículo de Kuan and Liu [1995] se investiga la capacidad de predicción fuera de muestra de una RNA hacia adelante (feedforward) y una RNA recurrente basada en datos reales empíricos. Se propone un procedimiento de dos etapas para construir la red adecuada, en este procedimiento las redes se seleccionan en función de la complejidad estocástica predictiva.

García et al. [2008] desarrolló un modelo para realizar la predicción de la concentración de ozono en la zona metropolitana de Guadalajara-México. La arquitectura de la red fue la siguiente: 9 datos de entrada, donde seis variables son

meteorológicas y tres químicas, los nodos entre capas ocultas se variaron entre doce y quince, se empleó un algoritmo de entrenamiento de Levenberg-Marquardt, para el entrenamiento usaron datos históricos de cinco años y uno más para verificar la capacidad predictiva de la red.

En el artículo de Mattar et al. [2015] utilizaron RNAs para estimar el volumen de infiltración de agua bajo riego por surcos. Usaron una RNA de alimentación hacia adelante usando el algoritmo de retro propagación del error; se consideraron cuatro datos de entrada: tasa de flujo de entrada, longitud del surco, tiempo de avance frente, y el tiempo de infiltración oportuno, con un nodo de capa de salida. Los datos fueron tomados de la literatura.

Este artículo de de Souza et al. [2015] se implementó una RNA para la predicción de precios de las hortalizas debido a la estacionalidad. La RNA fue entrenada a partir de series de tiempo de los precios. Los resultados fueron muy prometedores y alentadores porque era posible pronosticar los precios de estos alimentos a través del tiempo, lo que le convierte en una buena herramienta para ayudar los empresarios de la industria hortícola.

En el artículo de White and Safi [2016] se realiza la comparación de RNAs, ARIMA y modelos de regresión, usando la simulación por computadora. La principal relevancia en presencia de autocorrelación de los errores observaron que las RNAs son mejores que ARIMA y que los modelos de regresión lineales.

En el artículo Chakraborty et al. [1992] se presenta una RNA para el análisis de series de tiempo multivariadas. Para la experimentación consideraron el precio de la harina en tres ciudades. Usaron una RNA de conexiones hacia adelante, el modelo cubre el precio de la harina y abarca el periodo desde agosto 1972 a noviembre 1980 para la ciudad de Buffalo, Minneapolis, and Kansas City, los sucesos deben ser archivados para entrenar la red neuronal para aprender las curvas de los precios de cada ciudad y hacer la predicción de los precios.



Lachtermacher and Fuller [1995] desarrollaron una metodología donde reducen los requisitos de datos necesarios para entrenamiento, esto debido a las limitaciones del uso de la retro propagación. Utilizaron el modelo Box-Jenkins en una fase exploratoria que identificaba los componentes de entrada (lags) de la RNA. Lo anterior con el objetivo de determinar una estructura de red compacta. Esta metodología redujo el tamaño de la red y por consecuencia se redujeron los datos necesarios para el entrenamiento de la misma.

En Grudnitski and Osburn [1993] se investiga la opción de utilizar redes neuronales artificiales en los pronósticos del precio de la bolsa de valores en los índices Standard & Poor's, donde se pronostica los precios del oro, basados en precios pasados y en patrones históricos encontrados en las series de tiempo.

En el artículo de Kohzadi et al. [1996] utilizaron una RNA hacia adelante que es capaz de encontrar las relaciones no lineales en los precios del trigo que datan de 1950 a 1990. Se repitió el experimento siete veces durante tres períodos sucesivos de tiempo. Esto implicó el uso del deslizamiento enfoque ventana desde 1970 hasta 1990, el modelo de las redes neuronales logró un 27 por ciento y 56 por ciento menor error cuadrático medio que el ARIMA.

A continuación se presenta una tabla de trabajos relevantes de RNAs, la cual fue propuesta por Zhang et al. [1998]:

Researchers	Data type	Training/ test size	#input nodes	#hidden layer:node	#output nodes	Transfer fun. hidden:output	Training algorithm	Data normalization	Performance measure
Chakraborty et al. (1992)	Monthly price series	90/10	8	1:8	1	Sigmoid:sigmoid	BP*	Log transform.	MSE
Cottrell et al. (1995)	Yearly sunspots	220/?	4	1:2-5	1	Sigmoid:linear	Second order	None	Residual variance and BIC
De Groot and Wurtz (1991)	Yearly sunspots	221/35,55	4	1:0-4	1	Tanh:tanh	BP,BFGS LM** etc.	External linear to [0,1]	Residual variance
Foster et al. (1992)	Yearly and monthly data	$N-k/k^{***}$	5,8	1:3,10	1	N/A****	N/A	N/A	MdAPE and GMARE
Ginzburg and Horn (1994)	Yearly sunspots	220/35	12	1:3	1	Sigmoid:linear	BP	External linear to [0,1]	RMSE
Gorr et al. (1994)	Student GPA	90%/10%	8	1:3	1	Sigmoid:linear	BP	None	ME and MAD
Grudnitski and Osburn (1993)	Monthly S and P and gold	N/A	24	2:(24)(8)	1	N/A	BP	N/A	% prediction accuracy
Kang (1991)	Simulated and real time series	70/24 or 40/24	4,8,2	1,2:varied	1	Sigmoid:sigmoid	GRG2	External linear [-1,1] or [0.1,0.9]	MSE, MAPE MAD, U-coeff.
Kohzadi et al. (1996)	Monthly cattle and wheat prices	240/25	6	1:5	1	N/A	BP	None	MSE, AME, MAPE
Kuan and Liu (1995)	Daily exchange rates	1245/ varied	varied	1:varied	1	Sigmoid:linear	Newton	N/A	RMSE
Lachtermacher and Fuller (1995)	Annual river flow and load	100%/ synthetic	n/a	1:n/a	1	Sigmoid:sigmoid	BP	External simple	RMSE and Rank Sum
Nam and Schaefer (1995)	Monthly airline traffic	3,6,9 yrs/ 1 yr.	12	1:12,15,17	1	Sigmoid:sigmoid	BP	N/A	MAD
Nelson et al. (1994)	M-competition monthly	$N-18/18$	varied	1:varied	1	N/A	BP	None	MAPE
Schoneburg (1990)	Daily stock price	42/56	10	2:(10)(10)	1	Sigmoid:sine, sigmoid	BP	External linear to [0.1,0.9]	% prediction accuracy
Sharda and Patil (1992)	M-competition time series	$N-k/k^{***}$	12 for monthly	1:12 for monthly	1,8	Sigmoid:sigmoid	BP	Across channel linear [0.1,0.9]	MAPE
Srinivasan et al. (1994)	Daily load and relevant data	84/21	14	2:(19)(6)	1	Sigmoid:linear	BP	Along channel to [0.1,0.9]	MAPE
Tang et al. (1991)	Monthly airline and car sales	$N-24/24$	1,6,12,24	1:=input node #	1,6,12,24	Sigmoid:sigmoid	BP	N/A	SSE
Tang and Fishwick (1993)	M-competition	$N-k/k^{***}$	12:month 4:quarter	1:=input node #	1,6,12	Sigmoid:sigmoid	BP	External linear to [0.2,0.8]	MAPE
Vishwakarma (1994)	Monthly economic data	300/24	6	2:(2)(2)	1	N/A	N/A	N/A	MAPE
Weigend et al. (1992)	Sunspots exchange rate (daily)	221/59 501/215	12 61	1:8,3 1:5	1 2	Sigmoid:linear Tanh:linear	BP	None along channel statistical	ARV ARV
Zhang (1994)	Chaotic time series	100 000/ 500	21	2:(20)(20)	1-5	Sigmoid:sigmoid	BP	None	RMSE

Figura 2.10: Arquitecturas de RNAs utilizadas en trabajos relevantes

En la última columna se muestra la función de error utilizada: MAPE.- Mean absolute percentage error; MAD.- Mean absolute deviation; MSE.- Mean squared error; RMSE.-root-mean-square error; SSE.- sum of squared errors of prediction; BP .- Backpropagation

## 2.3 LOGÍSTICA INVERSA

En la actualidad, con el acelerado crecimiento de la población, el consumo de productos manufacturados a gran escala va en aumento. Esto provoca la necesidad de incrementar la tasa de producción en las empresas, con el fin de satisfacer la demanda de la población y de otras empresas.

Con el objetivo de incrementar la productividad en las empresas, la logística inversa juega un papel fundamental y de acuerdo con Anónimo [2016], esta se define como: *El proceso de proyectar, implementar y controlar un flujo de materia prima, inventario en proceso, productos terminados e información relacionada desde el punto de consumo hasta el punto de origen, de una forma eficiente y lo más económica posible con el propósito de recuperar su valor o el de la propia devolución*".

En la mayoría de los trabajos relacionados a la logística inversa está subyacente la idea del movimiento de productos en el sentido inverso al tradicional, tal como se muestra en la Figura 2.11. Nótese que en la logística tradicional los productos van de las plantas hacia los centros de distribución y/o cliente final, mientras que en la logística inversa, los productos retornables se recolectan en el cliente final, van hacia los centros de distribución (o recolección) y finalmente a las plantas donde son reutilizados.




Figura 2.11: Ciclo de Logística Tradicional y Ciclo de Logística Inversa

Con la gran parte de los trabajos investigados, se encontró que en la logística inversa se manejan cinco fases para cumplir con una implementación exitosa.

**Recaudación.-** La primera fase de la logística inversa es la de reciclaje. El cual consiste en obtener una cantidad basta de los productos dañados o con fallas para tener un mayor número de piezas reutilizables.

**Valoración y Separación.-** Se basa primordialmente en la separación de los productos que son recaudados para su clasificación de acuerdo al estado en el que se encuentran en el momento de la recolección.

**Remanufactura.-** En la valoración se identifica en qué condiciones se encuentra el producto y se determina si se desecha completamente el producto o se envía para su reciclaje, muchas empresas priorizan la restauración o refabricación del producto, lo que implica un reacondicionamiento o mejora de la calidad del mismo (López Parada [2010]).

**Eliminación.-** Inmediatamente después de haber pasado la fase de remanufactura, cuando se observa que no tiene solución el producto o el material retornado, se lleva a cabo su eliminación.

**Redistribución.-** Los productos o los equipos que fueron remanufacturados, son nuevamente distribuidos a los clientes o a los centros de distribución pertinentes para su venta.

### 2.3.1 REVISIÓN DE LITERATURA LOGÍSTICA INVERSA

Del Castillo and Cochran [1996] realizaron un trabajo en una empresa refresquera ubicada en la ciudad de México, se creó y se implementó un modelo para la operación diaria en la línea de producción y distribución de la empresa. Este modelo incluye ventanas de tiempo, límite en inventarios, máximo número de viajes, diferentes tipos de botellas, tiempo de lavado de cada botella, múltiples centros de distribución, y múltiples plantas.

En Fleischmann et al. [2002] se menciona que de acuerdo a la legislación y a los clientes con expectativas ambientales, obligan cada vez más a los fabricantes a retirar sus productos después del uso. Una de las áreas en cuestión es la gestión de inventarios. Este trabajo proporciona un paso hacia un análisis sistemático de control de inventarios en el contexto de la reutilización.

En de Brito and Dekker [2003] verificaron la hipótesis, si la demanda y el retorno son procesos homogéneos e independientes el uno del otro, para validar o rechazarla mediante el análisis de datos reales de los flujos de retornos.

En la tesis doctoral de Rubio [2003] dividió a la logística inversa en dos: logística de devoluciones y logística para la recuperación. Lo único diferente es que la primera se ve desde el punto del consumidor, pero los dos tipos de metodologías generan un flujo de materiales y productos desde el consumidor hacia el fabricante,

implementación de estrategias tácticas y operativas.

En Ortega Mier [2008] estudian el problema de Utilización de métodos cuantitativos para el análisis de problemas de localización en logística inversa y el estudio se realiza en España. Proponen una formulación entera mixta (MILP) y emplea técnicas metaheurísticas, búsqueda dispersa y algoritmos genéticos. Realiza comparación entre técnicas exactas, búsqueda dispersa y algoritmos genéticos. El modelo propuesto resultó con un buen desempeño para las instancias pequeñas, en las instancias grandes la búsqueda dispersa obtuvo mejores resultados.

En el artículo Carrasco-Gallego and Ponce-Cueto [2010] implementaron un modelo que pretende ser una guía de acción que permite a los gestores logísticos abordar de forma estructurada los retos que surgen al realizar prácticas de reutilización. Así mismo el modelo constituye un primer paso hacia la mitigación de estos aspectos problemáticos desde el punto de vista logístico, se implementó en 6 diferentes áreas.

En la tesis doctoral de Hernández Landa [2011] propusieron un modelo que determina la localización de los centros de inspección o recolección, centro de distribución y plantas para manufacturar productos, consideran un solo tipo de producto, múltiples plantas y centros de distribución, con tasa de retorno estocástica.

En el artículo de Lee and Lam [2012] se implementó un marco de comercialización industrial sostenible de la última exigencia verde y se propone una operación sustentable. Con las lecturas que se revisaron, las estrategias de marketing y operación han proporcionado información acerca de la eficiencia de la logística inversa y el valor del negocio para el cliente. El estudio plantea la cuestión de que los fabricantes podrían determinar las estrategias ecológicas y la metodología que se va tomar para la implementación de la logística inversa.

En Castañeda et al. [2013] se presenta una extensa revisión para conocer qué herramientas metodológicas son de utilidad para el desarrollo de estudios cualitativos y exploratorios, y muestran que los estudios basados en investigación empírica permite conocer el desarrollo y aplicación de la logística inversa en la industria.

En el artículo de García-Rodríguez et al. [2013] se tiene como objetivo entender los beneficios de la adquisición de materias primas a través de la logística inversa. El estudio se hizo en Venezuela, se utilizó una metodología de caso de estudio para probar el efecto de las variables independientes, así como el efecto de la incertidumbre, se determinó que es preferible comprar a través de la logística inversa, que únicamente por la incertidumbre.

En el artículo Saravanan and Kumar [2016] se implementó un modelo para calcular el retorno de los medicamentos farmacéuticos (productos perecederos). Nótese que en este caso el tiempo tiene un papel importante con el fin de curar, prevenir, y diagnosticar enfermedades. Se examinaron diversas prácticas de eliminación de los medicamentos no deseados o caducados de acuerdo al tipo de material y a la cantidad.

## CAPÍTULO 3

# CORRELACIÓN VENTA-RETORNO

---

En esta capítulo se presenta el estudio de correlación que se realizó, con el fin de estimar el ciclo de retorno de los principales productos (SKUs) retornables que maneja la empresa. Se parte del supuesto de que el ciclo de retorno es de ocho semanas.

Para llevar a cabo el estudio, la empresa nos proporcionó información del año 2013, de cada uno de los principales SKUs relacionados con una de sus plantas. Cabe destacar que en el caso de estudio, se considera la recolección desde centros de distribución hacia plantas. Los centros de distribución cuentan con espacio para guardar temporalmente los envases vacíos, mismos que son seleccionados y clasificados de acuerdo a su estado.

### 3.1 ANÁLISIS DE CORRELACIÓN POR SKU

Con el fin de determinar la relación entre las ventas pasadas y el retorno de productos, se calculó el coeficiente de correlación entre venta y retorno de cada uno de los principales SKUs que maneja la empresa. Para cada uno de los 18 SKUs principales, se consideraron datos de los registros de las ventas y retornos semanales, ya que el periodo de planeación de producción se realiza de manera semanal.



Nótese que el coeficiente de correlación mide la fuerza y la relación entre dos variables usando datos de muestra y se calcula de la siguiente manera:

$$r = \frac{n(\sum_i X_i Y_i) - \sum_i X_i \sum_i Y_i}{\sqrt{[n(\sum_i X_i^2) - (\sum_i X_i)^2] [n(\sum_i Y_i^2) - (\sum_i Y_i)^2]}}$$

Donde :

- $n$  número de observaciones.
- $X_i$  valor de la observación  $i$  de la variable independiente.
- $Y_i$  valor de la observación  $i$  de la variable dependiente.

El rango del coeficiente de correlación es de -1 a 1 . Si la relación lineal entre la variable dependiente y la independiente es positiva, significa que el valor de la variable dependiente incrementa con el valor de la variable independiente y el valor de  $r$  están entre 0 y 1. En contraste, si el valor de la variable dependiente decrece cuando la variable independiente aumenta, entonces la relación de correlación es negativa y el valor de  $r$  está entre -1 y 0.

Durante las visitas a la empresa, el tomador de decisiones nos comentó que consideran que el ciclo de retorno es de aproximadamente 8 semanas (60 días) en cualquiera de los principales SKUs que manejan. Por esta razón, se decidió calcular el coeficiente de correlación para diferentes semanas del retorno, de la 1 a la 10. Es decir, se calculó el coeficiente de correlación suponiendo que la venta de una semana  $t$  está relacionada con el retorno de la semana  $t$ , luego con la semana  $t + 1$ , posteriormente con la  $t + 2$  y así sucesivamente hasta la semana  $t + 9$ . Posteriormente, se identificó la semana con la que la venta-retorno tienen mayor correlación, negativa o positiva según fuese el caso.

En la Tabla 3.1 se muestran la mejor correlación encontrada para los 18 SKUs analizados. la primera columna es la etiqueta que usamos para identificar el SKU, la segunda muestra el valor del coeficiente de correlación y la tercer columna contiene la

semana de la venta pasada que tiene esa correlación con el retorno. Por ejemplo, para el SKU 1 se observa que la mejor correlación es la que existe entre la venta realizada 9 semanas anteriores a la semana de retorno, con un coeficiente de correlación mayor a 0.64, con eso podemos concluir que el retorno del SKU 1 tiene una correlación positiva con la venta realizada 9 semanas atrás.

SKU	$r$	Semana de Retorno
1	0.640286591	$t + 9$
2	0.576219395	$t$
3	0.405400337	$t + 4$
4	-0.362149511	$t + 8$
5	-0.293588816	$t + 7$
6	0.843443942	$t$
7	0.259495060	$t + 5$
8	-0.388886322	$t + 6$
9	0.757858511	$t$
10	0.356673417	$t + 4$
11	0.191189135	$t + 3$
12	-0.416352635	$t + 6$
13	0.354322721	$t + 2$
14	0.516061111	$t$
15	0.695843565	$t$
16	0.380160512	$t + 2$
17	0.269193218	$t + 5$
18	0.345605590	$t + 2$

Tabla 3.1: Mejor correlación venta-retorno, venta realizada en la semana  $t$  y retorno registrado en la semana que se muestra en la tabla.

Como podemos observar en la tabla anterior, cada uno de los SKUs tienen diferente ciclo de retorno, ya que la semana que representa mejor correlación entre

venta y retorno es diferente para cada SKU. Más aún, sólo en el SKU 4 es donde se observa correlación, en este caso negativa, entre la venta realizada 8 semanas anteriores a la semana del retorno. Con esto, podemos concluir empíricamente, que el ciclo de retorno de ocho semanas no parece ser adecuado para la mayoría de los productos.

Con el fin de identificar qué semana se podría considerar para el ciclo de retorno, para cada semana se contó el número de SKUs en los que esa semana representa la mejor correlación (ver Tabla 3.1). Nótese que la mejor correlación que existe es en el caso venta-retorno registrados en la misma semana  $t$ , esto quiere decir que el retorno de la semana actual incrementa con la venta de la misma semana. Con esto concluimos que al menos para 5 de los 18 SKUs, el retorno de la semana  $t$  se correlaciona de manera positiva con la venta realizada en esa misma semana.

<b>Retorno en semana <math>t</math></b>	<b>Cantidad de SKUs</b>
1	5
2	0
3	3
4	1
5	2
6	2
7	2
8	1
9	1
10	1

Tabla 3.2: Cantidad de SKUs en los que el retorno registrado en la semana  $t$  se relaciona con la venta realizada  $t - 1$  semanas atrás, para  $t > 1$ . Si  $t = 1$ , el retorno de la semana actual se relaciona con la venta de la misma semana.

---

A continuación se muestran las gráficas de los registros de venta y retorno de cada uno de los SKUs analizados, RR denota el retorno real. Nótese que las observaciones de las ventas corresponden con la semana etiquetada en el eje X, sin embargo, las observaciones mostradas en el retorno están desfasadas  $t$  semanas atrás. Por ejemplo, en la Figura 3.1 el valor de retorno mostrado en la semana 1 corresponde con el que se registró en la semana 10 y el valor de la venta sí corresponde a la registrada en la semana 1; se graficó de esa forma para mostrar mejor el comportamiento de las ventas y retornos que arrojaron mejor correlación para el SKU 1.

## Gráficas de Venta-Retorno con mejor correlación, por SKU.




Figura 3.1: Observaciones venta-retorno de SKU 1, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 9$ .




Figura 3.2: Observaciones venta-retorno de SKU 2, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t$ .




Figura 3.3: Observaciones venta-retorno de SKU 3, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 4$ .




Figura 3.4: Observaciones venta-retorno de SKU 4, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 8$ .




Figura 3.5: Observaciones venta-retorno de SKU 5, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 7$ .




Figura 3.6: Observaciones venta-retorno de SKU 6, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t$ .




Figura 3.7: Observaciones venta-retorno de SKU 7, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 5$ .




Figura 3.8: Observaciones venta-retorno de SKU 8, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 6$ .




Figura 3.9: Observaciones venta-retorno de SKU 9, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t$ .




Figura 3.10: Observaciones venta-retorno de SKU 10, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 4$ .




Figura 3.12: Observaciones venta-retorno de SKU 12, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 6$ .






Figura 3.11: Observaciones venta-retorno de SKU 11, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 3$ .




Figura 3.13: Observaciones venta-retorno de SKU 13, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 2$ .




Figura 3.15: Observaciones venta-retorno de SKU 15, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t$ .

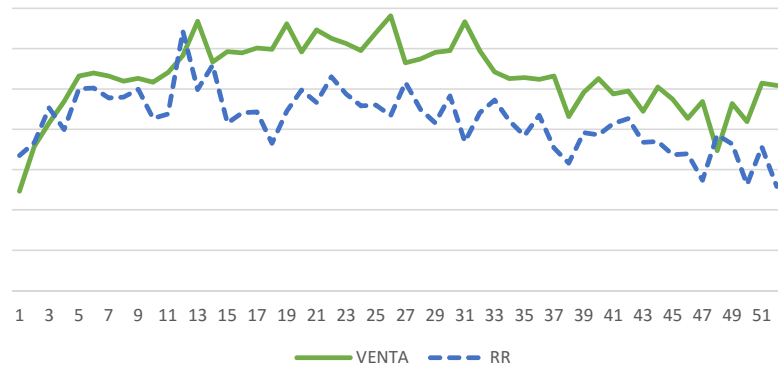


Figura 3.14: Observaciones venta-retorno de SKU 14, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t$ .




Figura 3.16: Observaciones venta-retorno de SKU 16, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 2$ .




Figura 3.17: Observaciones venta-retorno de SKU 17, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 5$ .




Figura 3.18: Observaciones venta-retorno de SKU 18, el retorno en la semana  $t$  se relaciona con la venta de la semana  $t - 2$ .

## CAPÍTULO 4

# PRONÓSTICO DE RETORNO CON RNAs

---

En este capítulo se presenta un análisis de las series de tiempo de los principales SKUs que se manejan en la cervecera local. Actualmente en la empresa se realiza la estimación del retorno de productos retornables usando promedios móviles. Sin embargo, se desconoce si este es el mejor método para la elaboración del pronóstico de este tipo de series. Por esta razón, en este trabajo se decidió estudiar el desempeño que tendrían las RNAs para la realización del pronóstico de retorno de cada SKU. Los resultados obtenidos con las RNAs se comparan con los obtenidos por el método de promedios móviles, el cual es uno de los métodos más tradicionales.

### 4.0.1 MODELOS DE PRONÓSTICO BASADOS EN RNAs

Para llevar a cabo el pronóstico de retorno mediante RNAs, se consideró una arquitectura de RNAs multicapa, con una capa de entrada, una capa oculta y una de salida. Para cada SKU se llevaron a cabo una serie de pruebas en las que se varió la cantidad de datos de entrada (de 2 a 8), así como el número de neuronas en la capa oculta (de 1 a 8).

Los datos se normalizaron en una escala de 0 a 1 y para la etapa de entrenamiento se usaron 70 % de los datos disponibles y el otro 30 % fue usado para

validación. Es decir, si se tuviesen 100 observaciones, las primeras 70 se tomarían para entrenamiento y las restantes para validación.

La empresa nos proporcionó el volumen del retorno semanal registrado desde el año 2012 hasta el año 2015 y con la ayuda del software estadístico R, versión 3.2.2 se utilizó la función *nnet* para la creación de las RNAs.

La medida de error que se utilizó fue el error cuadrático medio (ECM):

$$ECM = \frac{1}{n} \sum_{i=1} (\bar{Y}_i - Y_i)^2$$

donde  $\bar{Y}_i$  es el valor de la predicción y  $Y_i$  es el valor real.

Posteriormente, para cada SKU se identificó la RNA con menor valor de error y el pronóstico estimado por esta RNA se comparó con el obtenido mediante promedios móviles.

## 4.1 RNA VS PROMEDIOS MÓVILES

En la Tabla 4.1 se muestra el error de estimación (ECM) obtenido mediante la mejor arquitectura de RNAs probada y el método de promedios móviles. En la primera columna se muestra el Id del SKU analizado, en la segunda columna se presenta el número de neuronas en la capa de entrada de la RNA, en la tercera columna se muestra el ECM calculado con las estimaciones realizadas por la RNA, mientras que en la cuarta columna, se presenta el ECM de las estimaciones realizadas con promedios móviles; finalmente, el porcentaje de reducción de ECM (RNAs vs promedios móviles) se muestra en la quinta columna. Nótese que se probaron diferentes configuraciones de las RNAs y en todos los casos analizados, las mejores aproximaciones se obtuvieron con 8 neuronas en la capa oculta.

SKU	Datos de Entrada	ECM de RNA	ECM de Promedio Móvil	(%) de Reducción de ECM
1	2	0.00038705	0.00850034	-95 %
2	5	0.004352703	0.007893516	-45 %
3	5	0.000808171	0.009596042	-92 %
4	2	0.001532489	0.034560183	-96 %
5	3	0.003734287	0.013788503	-73 %
6	2	0.004819405	0.009169985	-47 %
7	3	0.004421912	0.019317813	-77 %
8	2	0.001497128	0.015607902	-90 %
9	5	0.006552682	0.009566198	-32 %
10	2	0.001653222	0.026827954	-94 %
11	3	0.002639301	0.022978996	-89 %
12	3	0.001988511	0.032268632	-94 %
13	4	0.002153379	0.038604583	-94 %
14	8	0.00509125	0.008452973	-40 %
15	4	0.000705735	0.008797032	-92 %
16	2	0.003790446	0.013501917	-72 %
17	2	0.004961289	0.026583564	-81 %
18	2	0.006966097	0.040651531	-83 %

Tabla 4.1: Comparación de ECM para cada SKU: RNAs vs Promedios Móviles

La fórmula utilizada en el modelo de promedios móviles es la siguiente:

$$PM_t = \frac{X_t + X_{t-1} + X_{t-2} + \dots + X_{t-n+1}}{n}$$

donde  $n$  es el número de observaciones pasadas que se utilizan para pronosticar el periodo  $t$ ; en el caso práctico la empresa considera  $n = 4$ .

Con estos resultados y al calculo del porcentaje de mejora para cada SKU que se realizo en la experimentación podemos concluir que un modelo de RNAs se ajusta

---

mejor que el método de promedios móviles para la estimación del retorno de envases retornables en la empresa cervecera.

A continuación se presentan las gráficas comparativas de la serie de tiempo real para cada SKU, la estimación realizada mediante RNAs y la obtenida mediante promedios móviles.

## 4.2 ESTIMACIONES DE RETORNO POR SKU

Para apreciar mejor los resultados que se describieron en la sesión anterior, se elaboró una gráfica por cada SKU, en la que se muestra la serie de datos históricos y las estimaciones realizadas mediante RNAs y promedios móviles.




Figura 4.1: Pronóstico de retorno SKU 1






Figura 4.2: Pronóstico de retorno SKU 2




Figura 4.3: Pronóstico de retorno SKU 3




Figura 4.4: Pronóstico de retorno SKU 4




Figura 4.5: Pronóstico de retorno SKU 5




Figura 4.6: Pronóstico de retorno SKU 6




Figura 4.7: Pronóstico de retorno SKU 7




Figura 4.8: Pronóstico de retorno SKU 8




Figura 4.9: Pronóstico de retorno SKU 9






Figura 4.10: Pronóstico de retornoSKU 10




Figura 4.11: Pronóstico de retorno SKU 11




Figura 4.12: Pronóstico de retorno SKU 12




Figura 4.13: Pronóstico de retorno SKU 13




Figura 4.14: Pronóstico de retorno SKU 14




Figura 4.15: Pronóstico de retorno SKU 15




Figura 4.16: Pronóstico de retorno SKU 16




Figura 4.17: Pronóstico de retorno SKU 17






Figura 4.18: Pronóstico de retorno SKU 18

Empíricamente podemos demostrar que para los casos analizados, las RNAs son una mejor alternativa que los promedios móviles para pronosticar el retorno de productos. Además, su implementación se facilita ampliamente con el software de estadística R.

## CAPÍTULO 5

# PLANIFICACIÓN DE LA RECOLECCIÓN DE ENVASES RETORNABLES

---

En este capítulo se presenta un modelo de optimización lineal entera mixta, el cual funciona bajo el supuesto de que se conoce con certeza la cantidad de producto retornable (de cada uno de los SKUs) en los centros de distribución, así como el inventario inicial y la demanda a cubrir en cada una de las plantas. Además, se considera el costo de compra de producto nuevo, en caso de que la cantidad de producto retornable no sea suficiente para satisfacer la demanda. El modelo propuesto se evalúa sobre una instancia real y los resultados obtenidos mediante CPLEX 12.6 se comparan con los obtenidos mediante un procedimiento basado en la experiencia del tomador de decisiones.

Nótese que los pronósticos de retorno estimados mediante promedios móviles o RNAs pueden ser utilizados para alimentar el modelo de optimización, ya que estas estimaciones representan la cantidad de producto que se espera tener en los centros de distribución.

## 5.1 DESCRIPCIÓN DEL MODELO DE OPTIMIZACIÓN

En este problema se tiene como objetivo minimizar una función de costos que incluye: costos de transporte entre centros de distribución y plantas, costos de transporte entre plantas, así como el costo de compra de producto nuevo.

### 5.1.1 FORMULACIÓN

#### **Conjuntos:**

$I$ : Conjunto de plantas.

$J$ : Conjunto de centro de distribución.

$B$ : Conjunto de botellas.

#### **Parámetros:**

$D_i^b$ : Demanda de producto  $b$  en planta  $i$

$CW$ : Costo de transporte por kilómetro.

$CT$ : Cantidad de tarimas que se pueden transportar por viaje.

$I_i^b$ : Inventario inicial de producto  $b$ , existente en planta  $i$ .

$O_j^b$ : Inventario de producto  $b$  en centro de distribución  $j$ .

$U^b$ : Cantidad de cajas por tarima del tipo de botella  $b$ .

$C_i$ : Costo de compra por caja de producto (es igual para cualquier tipo de producto y para cualquier planta  $i$ ).

$F_{ij}$ : Distancia que hay entre el centro de distribución  $j$  y la planta  $i$ .

$F'_{il}$ : Distancia existente entre plantas  $i$  y  $l$ .

#### **Variables de decisión:**

$Y_i^b$ : Cantidad de cajas de producto  $b$  que debe adquirir la planta  $i$ .

$If_i^b$ : Inventario final de producto  $b$  disponible en la planta  $i$ .

$X_{ji}^b$ : Cantidad de cajas de producto  $b$  enviadas del centro de distribución  $j$  a la planta  $i$ .

$Xp_{ki}^b$ : Cantidad de cajas de producto  $b$  enviadas de la planta  $k$  a la planta  $i$  (ayuda entre plantas).

$T_{ji}^b$ : Cantidad de tarimas de producto  $b$  que se envían del CD  $j$  a la planta  $i$ .

$Tp_{ki}^b$ : Cantidad de tarimas de producto  $b$  que se envían de la planta  $k$  a la planta  $i$ .

$R_{ji}$ : Cantidad de viajes realizados desde CD  $j$  hacia planta  $i$ .

$Re_{ki}$ : Cantidad de viajes realizados desde planta  $k$  hacia planta  $i$ .

#### 5.1.1.1 MODELO MATEMÁTICO

$$\text{Min} \quad \sum_{i \in I} \sum_{b \in B} C_i Y_i^b + CW \sum_{i \in I} \sum_{j \in J} F_{ij} R_{ji} + CW \sum_{i \in I} \sum_{k \in K} F'_{ik} Re_{ik} \quad (5.1)$$

Sujeto a:

$$I_i^b + \sum_{j \in J} X_{ji}^b + \sum_{k \in K} Xp_{ki}^b + Y_i^b - D_i^b - \sum_{k \in K} Xp_{ik}^b \leq I f_i^b \quad \forall i \in I \quad b \in B \quad (5.2)$$

$$\sum_{i \in I} X_{ji}^b \leq O_j^b \quad \forall j \in J \quad b \in B \quad (5.3)$$

$$\frac{X_{ji}^b}{U^b} \leq T_{ji}^b \quad \forall i \in I \quad j \in J \quad b \in B \quad (5.4)$$

$$\frac{\sum_{b \in B} T_{ji}^b}{CT} \leq R_{ji} \quad \forall i \in I \quad j \in J \quad (5.5)$$

$$\frac{Xp_{ki}^b}{U^b} \leq Tp_{ki}^b \quad \forall i \in I \quad j \in J \quad b \in B \quad (5.6)$$

$$\frac{\sum_{b \in B} Tp_{ki}^b}{CT} \leq Re_{ki} \quad \forall i \in I \quad k \in K \quad (5.7)$$

**Función objetivo** La función objetivo consiste en minimizar costos. El primer componente está relacionado con el costo de adquisición de botellas nuevas, el segundo es el costo de los viajes realizados desde centros de distribución a plantas y el último

es el costo de los viajes realizados entre plantas.

$$\text{Min} \quad \sum_{i \in I} \sum_{b \in B} C_i Y_i^b + CW \sum_{i \in I} \sum_{j \in J} F_{ij} R_{ji} + CW \sum_{i \in I} \sum_{k \in K} F'_{ik} R_{e_{ik}}$$

### Restricciones

La primera restricción garantiza la satisfacción de la demanda existente en cada una de las plantas. Es decir, para cada planta y para cada tipo de producto, la cantidad de producto existente en inventario inicial más la cantidad que la planta recibe desde centros de distribución o desde otras plantas, debe ser mayor o igual a la demanda más el inventario final:

$$I_i^b + \sum_{j \in J} X_{ji}^b + \sum_{k \in K} X_{p_{ki}}^b + Y_i^b - D_i^b - \sum_{k \in K} X_{p_{ik}}^b \leq I f_i^b \quad i \in I \quad j \in J \quad b \in B.$$

La segunda restricción asegura que lo que se envía desde cada centro de distribución sea menor o igual a la cantidad de inventario existente:

$$\sum_{i \in I} X_{ji}^b \leq O_j^b \quad j \in J \quad b \in B.$$

La tercera restricción se utiliza para calcular la cantidad de tarimas, por cada tipo de producto, que se enviarán desde cada centro de distribución a cada planta:

$$\frac{X_{ji}^b}{U^b} \leq T_{ji}^b \quad i \in I \quad j \in J \quad b \in B.$$

En la cuarta restricción se calcula la cantidad de viajes (recorridos) que se necesitan para transportar los productos desde cada centro de distribución a cada planta.

$$\frac{\sum_{b \in B} T_{ji}^b}{CT} \leq R_{ji} \quad i \in I \quad j \in J.$$

La quinta restricción se utiliza para calcular la cantidad de tarimas, por cada tipo de producto, que se enviarán entre plantas:

$$\frac{Xp_{ki}^b}{U^b} \leq Tp_{ki}^b \quad i \in I \quad k \in K \quad b \in B$$

En la sexta restricción se calcula la cantidad de viajes (recorridos) que se necesitan para transportar los productos entre plantas.

$$\frac{\sum_{b \in B} Tp_{ki}^b}{CT} \leq Re_{ki} \quad i \in I \quad k \in K$$

### 5.1.2 EJEMPLO DE SOLUCIÓN

En la Figura 5.1 se muestra un ejemplo de solución para una instancia pequeña del problema. Nótese que la solución es similar a la de un problema de transporte con ayuda entre plantas.

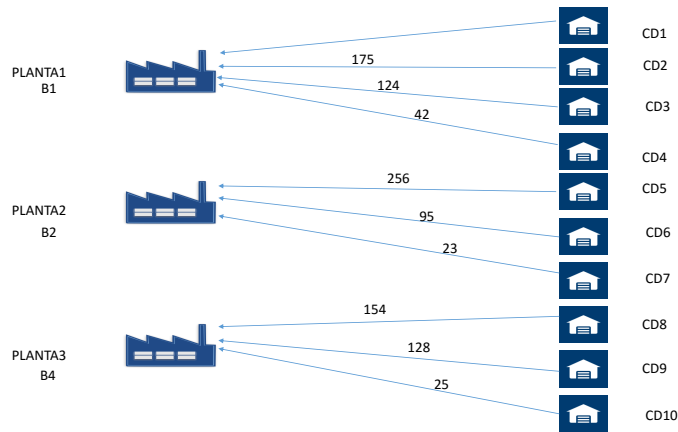


Figura 5.1: Ejemplo de una solución para el problema de planificación.

## 5.2 METODOLOGÍA BASADA EN LA EXPERIENCIA

El problema descrito anteriormente se resuelve típicamente cada dos semanas por el departamento de logística inversa y su solución se basa en la experiencia

del tomador de decisiones. A continuación se presenta una heurística simple para resolver este problema de decisión.

- 1. Para cada planta, recolectar todo lo existente en los centros de distribución que están asociados con esa planta.
- 2. Actualizar la demanda que falta por cubrir en cada planta.
- 3. Si hay demanda por cubrir en alguna planta  $i$ , se revisa si existe una planta  $j$  que tenga excedente de envase y ésta le envía producto a la planta  $i$ . Si no, Ir a paso 5.
- 4. Actualizar la demanda que falta por cubrir en cada planta. Ir a paso 3.
- 5. Si hay demanda por cubrir en alguna planta  $i$ , enviar orden de compra al proveedor y solicitar ajustes necesarios al área de producción.
- Terminar.

En el paso 5, cuando se le solicita ajustes al área de producción, es principalmente para realizar el cambio en la fecha que se tiene planeada la producción de algún producto, esto con el fin de tener el tiempo suficiente para disponer de la cantidad de envases necesarios para realizar la producción.

Como se comentó anteriormente, el problema de planeación de la recolección y compra de envase, se realiza con una anticipación de dos semanas a la fecha en que se planea realizar la producción de algún producto. De esta manera, se intenta evitar contra tiempos durante la ejecución del plan de producción.

### 5.2.1 CASO DE ESTUDIO

Con el fin de validar el modelo de optimización propuesto, se solicitó a la empresa la información de un caso real, el cual consta de 6 plantas, 200 centros

de distribución y 25 diferentes tipos de envases retornables. El modelo se escribió usando el modelador algebraico GAMS y se resolvió el problema con el optimizador CPLEX 12.6, en una computadora personal con procesador i3, con 6GB de RAM y sistema operativo Windows 10.

Con el fin de comparar la solución obtenida mediante la metodología que sigue la empresa y la que encontramos al usar el modelo matemático, se resolvió el mismo caso real, usando ambos procedimientos. La solución óptima que reportó CPLEX representa un ahorro de aproximadamente 2.8 % con respecto a lo que se obtuvo al aplicar la metodología basada en la experiencia. Hablando en porcentaje este número parece bastante pequeño, sin embargo, en dinero, este representa una cantidad bastante considerable debido a los volúmenes de producto que se manejan en la empresa.

El modelo de optimización propuesto es muy sencillo y puede ser resuelto en pocos segundos. De ahí que representa una buena alternativa para cualquier empresa que se enfrenta al problema de planear la recolección de envases retornables.



## CAPÍTULO 6

# CONCLUSIONES

---

En esta tesis se estudiaron tres problemáticas presentes en el área de logística inversa de una compañía cervecera. Las técnicas usadas en este trabajo pueden ser implementadas en diversas empresas que requieran estimar ciclos de retorno, pronosticar volumen de retorno, así como planear la recolección de productos retornables.

En primer lugar, se realizó un estudio de correlación entre las ventas y el retorno de 18 SKUs manejados por la empresa. El tomador de decisiones en la empresa trabaja bajo el supuesto de que los envases retornables tienen un ciclo de retorno de aproximadamente 8 semanas. Es decir, suponen que la venta realizada en el período  $t$  está correlacionada con el retorno realizado en el periodo  $t + 8$ . En nuestro estudio realizado se observó que cada SKU tiene correlación venta-retorno única. Sólo 5 de los 18 SKUs mostraron un coeficiente de correlación positiva aceptable como para concluir que la venta de la semana  $t$  se relaciona con el retorno registrado en esa misma semana.

En segundo lugar, se realizó una implementación de Redes Neuronales Artificiales para la realización del pronóstico del retorno. Se probaron diversas arquitecturas de una red de 3 capas, variando la cantidad de datos de entrada y de neuronas en la capa oculta. Se observó que las mejores aproximaciones se encuentran con RNAs de 8 neuronas en la capa oculta. Los resultados obtenidos se compararon

con los que se obtienen al aplicar el método de promedios móviles (considerando las últimas 4 observaciones). Esta comparación se realizó dado que éste es uno de los métodos más tradicionales para la realización de pronósticos. Observamos que las RNAs propuestas son capaces de generar estimaciones con menor error cuadrático medio, por lo cual, son una buena alternativa para realizar las estimaciones del retorno de productos.

Finalmente, se propuso un modelo de programación lineal entera mixta para resolver el problema de recolección de envases desde centros de distribución, ayuda entre plantas y adquisición de producto nuevo, con el fin de satisfacer la demanda en cada una de las plantas. Se probó la efectividad del modelo en un caso real, en el que se tienen 6 centros de distribución, 200 plantas y 25 productos. Los resultados obtenidos de esta parte del trabajo se compararon con los que se obtendrían al seguir un procedimiento simple basado en la experiencia del tomador de decisiones. Se observó que al usar el modelo propuesto en lugar del procedimiento basado en experiencia, se tiene un ahorro de más del 2.8%, lo que genera una disminución considerable en los costos.

Nótese que la relación principal entre los pronósticos y el modelo de optimización se debe a que la planeación de las recolecciones y compra se realizan con dos semanas de anticipación, por lo cual no se conoce con certeza la cantidad de producto retornable que se tendrá en los centros de distribución, así que se recurre a la estimación de pronósticos para poder tomar decisiones anticipadas.

Como trabajo futuro, se espera realizar más pruebas con casos reales, para tener una mejor estimación del ahorro que podría traer el uso de modelos matemáticos para la optimización de la recolección de envases retornables. Además, se espera contar con el apoyo de la empresa para que en algún momento, los resultados derivados de este trabajo puedan ser aplicados en la práctica.

# BIBLIOGRAFÍA

---

- J Trujillano Cabello, M Badía Castelló, J March Llanes, Á Rodríguez Pozo, L Serviá Goixart, and A Sorribas Tello. Redes neuronales artificiales en medicina intensiva. ejemplo de aplicación con las variables del mpm ii. *Medicina intensiva*, 29(1):13–20, 2005.
- Dale S Rogers, Ronald S Tibben-Lembke, and Reverse Logistics Executive Council. *Going backwards: reverse logistics trends and practices*, volume 2. Reverse Logistics Executive Council Pittsburgh, PA, 1999.
- José de Jesús Casas, Katherine Cerón, Carlos Julio Vidal, Claudia Cecilia Peña, and Juan Carlos Osorio. Priorización multicriterio de un residuo de aparato eléctrico y electrónico. *Ingeniería y Desarrollo*, 33(2):172–197, 2015.
- Arnulfo Arturo García Olivares. *Programa de logística inversa*. Juan Carlos Martínez Coll, 2006.
- Eduin Dionisio Contreras Castañeda, Ana Mercedes Fraile Benítez, and Julián David Silva Rodríguez. Diseño de un sistema de logística inversa para la recolección de envases y empaques vacíos de plaguicidas. *Revista Ingeniería Industrial*, 12(2), 2014.
- Rosa María Martínez Ortega, Leonel C Tuya Pendás, Mercedes Martínez Ortega, Alberto Pérez Abreu, and Ana María Cánovas. El coeficiente de correlación de los rangos de spearman caracterización. *Revista Habanera de Ciencias Médicas*, 8 (2):0–0, 2009.

- Daniel Peña. *Fundamentos de estadística*. Alianza editorial, 2014.
- Jan van Dalen, Jo AEE van Nunen, and Cyril M Wilens. The chip in crate: the heineken case. In *Managing closed-loop supply chains*, pages 43–55. Springer, 2005.
- Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- Simon S Haykin. *Neural networks: a comprehensive foundation*. Tsinghua University Press, 2001.
- Sun-Chong Wang. Artificial neural network. In *Interdisciplinary Computing in Java Programming*, pages 81–100. Springer, 2003.
- Fernando Tanco. Introducción a las redes neuronales artificiales. *Grupo de Inteligencia Artificial*, 2003.
- Raquel Florez López and José Miguel Fernandez Fernandez. *Las redes neuronales artificiales*. Netbiblo, 2008.
- JM Marín. Introducción a las redes neuronales aplicadas. *Curso de Expertos de UCM (consultado 6 de febrero de, 2013)*.
- Marie Cottrell, Bernard Girard, Yvonne Girard, Morgan Mangeas, and Corinne Muller. Neural modeling for time series: a statistical stepwise method for weight elimination. *Neural Networks, IEEE Transactions on*, 6(6):1355–1364, 1995.
- WR Foster, F Collopy, and LH Ungar. Neural network forecasting of short, noisy time series. *Computers & chemical engineering*, 16(4):293–297, 1992.
- Wilpen L Gorr, Daniel Nagin, and Janusz Szczypula. Comparative study of artificial neural network and statistical models for predicting student grade point averages. *International Journal of Forecasting*, 10(1):17–34, 1994.
- Chung-Ming Kuan and Tung Liu. Forecasting exchange rates using feedforward and recurrent neural networks. *Journal of Applied Econometrics*, 10(4):347–364, 1995.

- Ignacio García, Alonso Marbán, Yenisse M Tenorio, and José G Rodríguez. Pronóstico de la concentración de ozono en guadalajara-méxico usando redes neuronales artificiales. *Información tecnológica*, 19(3):89–96, 2008.
- MA Mattar, AA Alazba, and TK Zin El-Abedin. Forecasting furrow irrigation infiltration using artificial neural networks. *Agricultural Water Management*, 148: 63–71, 2015.
- Celso Correia de Souza, José Francisco dos Reis Neto, Daniel Massen Frainer, Francisco de Assis Rolim Pereira, and Rafael Gabriel. Forecast of prices for horticultural products with the use of artificial neural networks. *African Journal of Agricultural Research*, 10(30):2919–2927, 2015.
- Alexander K White and Samir K Safi. The efficiency of artificial neural networks for forecasting in the presence of autocorrelated disturbances. *International Journal of Statistics and Probability*, 5(2):51, 2016.
- Kanad Chakraborty, Kishan Mehrotra, Chilukuri K Mohan, and Sanjay Ranka. Forecasting the behavior of multivariate time series using neural networks. *Neural networks*, 5(6):961–970, 1992.
- Gerson Lachtermacher and J David Fuller. Back propagation in time-series forecasting. *Journal of forecasting*, 14(4):381–393, 1995.
- Gary Grudnitski and Larry Osburn. Forecasting s&p and gold futures prices: An application of neural networks. *Journal of Futures Markets*, 13(6):631–643, 1993.
- Nowrouz Kohzadi, Milton S Boyd, Bahman Kermanshahi, and Iebeling Kaastra. A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing*, 10(2):169–181, 1996.
- Guoqiang Zhang, B Eddy Patuwo, and Michael Y Hu. Forecasting with artificial neural networks:: The state of the art. *International journal of forecasting*, 14(1): 35–62, 1998.

- Anónimo. Manual de la asignatura transporte y logística internacional, <https://logiticainternacionalclasec.wordpress.com/2016/02/02/reflexiones-sobre-logistica-inversa-nivel-iniciacion/>, 2016.
- José López Parada. *Incorporación de la Logística Inversa en la Cadena de Suministros y su influencia en la estructura organizativa de las empresas*. Universitat de Barcelona, 2010.
- Enrique Del Castillo and Jeffery K Cochran. Optimal short horizon distribution operations in reusable container systems. *Journal of the Operational Research Society*, 47(1):48–60, 1996.
- Moritz Fleischmann, Roelof Kuik, and Rommert Dekker. Controlling inventories with stochastic item returns: A basic model. *European journal of operational research*, 138(1):63–75, 2002.
- Marisa P de Brito and Rommert Dekker. Modelling product returns in inventory control exploring the validity of general assumptions. *International Journal of Production Economics*, 81:225–241, 2003.
- Sergio Rubio. *El sistema de logística inversa en la empresa: análisis y aplicaciones*. PhD thesis, Universidad de Extremadura, 2003.
- Miguel Angel Ortega Mier. *Utilización de métodos cuantitativos para el análisis de problemas de localización en logística inversa*. PhD thesis, Industriales, 2008.
- Ruth Carrasco-Gallego and Eva Ponce-Cueto. Un modelo para la gestión de artículos reutilizables en sistemas logísticos de bucle cerrado: definición de problemas relevantes. *Dirección y Organización*, 2(42):63–70, 2010.
- Leonardo Gabriel Hernández Landa. *Modelo estocástico por escenarios para una red de logística inversa*. PhD thesis, Universidad Autónoma de Nuevo León, 2011.
- Carmen Ka Man Lee and Jasmine Siu Lee Lam. Managing reverse logistics to enhance sustainability of industrial marketing. *Industrial Marketing Management*, 41(4):589–598, 2012.

- 
- Eduin Contreras Castañeda, Rafael Tordecilla Madera, and Julián Silva Rodríguez. Revisión de estudios de caso de carácter cualitativo y exploratorio en logística inversa. *Revista EIA*, 10(20):153–164, 2013.
- Francisco J García-Rodríguez, Carlos Castilla-Gutiérrez, and Carlos Bustos-Flores. Implementation of reverse logistics as a sustainable tool for raw material purchasing in developing countries: The case of venezuela. *International journal of production economics*, 141(2):582–592, 2013.
- S Saravanan and T Manoj Kumar. Reverse logistic practices on household medicine disposal in india and its impacts on environment. *Indian Journal of Research in Pharmacy and Biotechnology*, 4(1):39, 2016.

# FICHA AUTOBIOGRÁFICA

---

Daniel Alejandro Loera Zermeño

Candidato para el grado de Maestría en Ciencias en  
Ingeniería de Sistemas

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica

Tesis:

ESTIMACIÓN Y PLANIFICACIÓN DE LA  
RECOLECCIÓN DE PRODUCTOS RETORNABLES EN  
UNA EMPRESA CERVECERA

Nací el 25 de Mayo de 1987, en San Nicolás de los Garza, Nuevo León, primogénito de Ignacio Loera Chantaca y Bertha Zermeño Blanco.

En 1992 inicié mi educación en la Escuela Primaria "Lic. Melchor Ocampo", en Guadalupe, Nuevo León. En 1999 inicié mis estudios en la Escuela Secundaria "#16 Carmen Serdán", en Guadalupe, Nuevo León. Estudié mi Bachillerato en el Instituto superior de Computación y obtuve el grado de Técnico en Mantenimiento y Reparación en Micro computadoras. En el año 2007 inicié mis estudios en la carrera de Ingeniería en Sistemas Computacionales obteniendo mi título de Ingeniero en Sistemas Computacionales.



---


Con el paso del tiempo entré al ramo laboral en cablevision Monterrey redes, para mejorar en el área profesional, trabajé en la empresa Sigma alimentos en el área de soporte técnico del sistema que maneja la empresa.

En el año 2014 tuve la dicha de ser seleccionado para ingresar a la Maestría en Ciencias en Ingeniería de sistemas en la Facultad de Ingeniería Mecánica y Eléctrica de la Universidad Autónoma de Nuevo León.

# PATROCINADORES

---

El presente trabajo de tesis "Estimación y planificación de la recolección de productos retornables en una empresa cervecera", fue apoyado con la beca de la Facultad de Ingeniería Mecánica y Eléctrica, de la Universidad Autónoma de Nuevo León, y del CONACYT, así como con el apoyo de mi familia.



**CONACYT**

*Consejo Nacional de Ciencia y Tecnología*

