



**UNIVERSIDAD ESTATAL DE MILAGRO**

**VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO**

**PROYECTO PREVIO A LA OBTENCIÓN DEL TÍTULO DE:**

**MAGISTER EN MATEMÁTICAS CON MENCIÓN EN MODELACIÓN  
MATEMÁTICA**

**TÍTULO DEL PROYECTO**

**PROPUESTA DE UN MODELO MATEMÁTICO APLICADO AL PRONÓSTICO  
DE PRODUCCIÓN EN UNA FÁBRICA DE GALLETA DE CHOCOLATE DE  
21\*700 g UTILIZANDO REDES NEURONALES ARTIFICIALES.**

**AUTOR**

**LCDO. JUAN CARLOS GRANIZO ARIAS**

**TUTOR**

**ZORAIDA M. SIVOLI BARRIOS**

**MILAGRO, JULIO DEL 2022**

**ECUADOR**

## ACEPTACIÓN DEL TUTOR

Por la presente, yo **Zoraida Margarita Sivoli Barrios**, hago constar que he analizado el proyecto de grado presentado por **el Sr. Juan Carlos Granizo Arias**, para optar al título de **Magister en Ciencias Matemáticas** y que acepto tutoriar al estudiante, durante la etapa del desarrollo del trabajo hasta su presentación, evaluación y sustentación.

Milagro, a los 19 días del mes de julio del 2022

1757442338 ZORAIDA  
MARGARITA SIVOLI  
BARRIOS

Firmado digitalmente por  
1757442338 ZORAIDA  
MARGARITA SIVOLI BARRIOS  
Fecha: 2022.10.25 00:23:04  
-05'00'



---

**MSc. Zoraida Margarita Sivoli Barrios.PHD**

**(C.I: 1757442338)**

## DECLARACIÓN DE AUTORÍA DE LA INVESTIGACIÓN

El autor de esta investigación declara ante el Consejo Directivo del Instituto de Postgrado y Educación Continua de la Universidad Estatal de Milagro, que el trabajo presentado es de mi propia autoría, no contiene material escrito por otra persona, salvo el que está referenciado debidamente en el texto; parte del presente documento o en su totalidad no ha sido aceptado para el otorgamiento de cualquier otro Título o Grado de una institución nacional o extranjera.

Milagro, a los 28 días del mes de Septiembre del 2022



---

**Lcdo. Juan Carlos Granizo Arias**

**C.I. 1203642580**

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO CERTIFICACIÓN  
DE LA DEFENSA

El TRIBUNAL CALIFICADOR previo a la obtención del título de **MAGÍSTER EN MATEMÁTICA CON MENCIÓN MODELACIÓN MATEMÁTICA**, otorga al presente proyecto de investigación en las siguientes calificaciones:

TRABAJO DE TITULACION	54.00
DEFENSA ORAL	36.00
PROMEDIO	90.00
EQUIVALENTE	<b>Muy Bueno</b>



Firma digitalizada por:  
**ARISTIDES REYES**

**Mgtr. REYES BACARDI ARISTIDES**  
**PRESIDENTE/A DEL TRIBUNAL**



Firma digitalizada por:  
**BYRON RAMIRO ROMERO ROMERO**

**Msc. ROMERO ROMERO BYRON RAMIRO**  
**VOCAL**



Firma digitalizada por:  
**LUIS HENRY TORRES ORDONEZ**

**Mee TORRES ORDOÑEZ LUIS HENRY**  
**SECRETARIO/A DEL TRIBUNAL**

## **DEDICATORIA**

Especialmente dedico este trabajo de investigación a la persona que siempre a estado impulsándome para no desmayar en la culminación del proyecto que hace 3 años comenzamos y que al terminar la tesis se convierte en el penúltimo peldaño para alcanzar el sueño de lograr un título de 4to nivel.

También dedico este trabajo a las cuatro razones que me mueven todos los días a intentar ser una mejor persona y un mejor profesional. Tengo claro que todavía no he logrado nada, pero también sé que voy por el camino seguro.

También dedico esta tesis a mi mama pasando por unos momentos críticos de su enfermedad espero lograr en ella un orgullo y empuje para luchar contra su enfermedad.

## **AGRADECIMIENTO**

Reconozco en primer lugar a la UNEMI por habernos dado la apertura de realizar un estudio de 4to nivel en Matemáticas, a mi tutora Zoraida por ser muy paciente y una excelente guía durante este proceso de culminación de la tesis, y a todos mis compañeros de la maestría por su ayuda desinteresada en estos 3 largos años que nos ha tocado compartir.

Agradezco a mi familia por su paciencia durante estos años al suspender muchas actividades en el hogar, y ser partícipes en la mejora continua y en la superación como profesional.

## CESIÓN DE DERECHOS DE AUTOR

**Señor Doctor**

**Fabricio Guevara Viejó**

**Rector de la Universidad Estatal de Milagro**

Presente.

Mediante el presente documento, libre y voluntariamente procedo a hacer entrega de la Cesión de Derecho del Autor del Trabajo realizado como requisito previo para la obtención de mi Título de Cuarto Nivel, cuyo tema fue **“PROPUESTA DE UN MODELO MATEMÁTICO APLICADO AL PRONÓSTICO DE PRODUCCIÓN EN UNA FÁBRICA DE GALLETA DE CHOCOLATE DE 21\*700 g UTILIZANDO REDES NEURONALES ARTIFICIALES.** y que corresponde al Vicerrectorado de Investigación y Posgrado.

Milagro, a los 19 días del mes de Julio del 2022



Firmado electrónicamente por:  
**JUAN CARLOS  
GRANIZO**

---

**Lcdo. Juan Carlos Granizo Arias.**

**C.I. 0919870162**

## INDICE GENERAL

<b>CAPITULO I</b> .....	<b>3</b>
<b>1.1 Planteamiento del problema</b> .....	<b>3</b>
<b>1.2 Delimitación del problema</b> .....	<b>5</b>
<b>1.3 Formulación del problema</b> .....	<b>6</b>
<b>1.4 Sistematización del problema</b> .....	<b>6</b>
<b>1.5 Objetivos</b> .....	<b>6</b>
<b>1.5.1 Objetivo general</b> .....	<b>6</b>
<b>1.5.2 Objetivos específicos</b> .....	<b>6</b>
<b>1.6 Justificación e importancia</b> .....	<b>7</b>
<b>1.6.1 Justificación Teórica</b> .....	<b>8</b>
<b>1.6.2 Justificación metodológica</b> .....	<b>8</b>
<b>1.6.3 Justificación práctica</b> .....	<b>8</b>
<b>1.7 Hipótesis</b> .....	<b>9</b>
<b>1.7.1 Hipótesis General</b> .....	<b>9</b>
<b>1.7.2 Hipótesis Particular</b> .....	<b>9</b>
<b>1.7.3 Conceptualización y operacionalización de variables</b> .....	<b>9</b>
<b>CAPÍTULO II</b> .....	<b>11</b>
<b>2.1 Marco Teórico</b> .....	<b>11</b>
<b>2.1.1 Modelo matemático</b> .....	<b>11</b>
<b>2.1.2 Pronóstico de producción</b> .....	<b>13</b>
<b>2.1.3 Redes Neuronales Artificiales</b> .....	<b>14</b>
<b>2.2 Marco Conceptual</b> .....	<b>20</b>
<b>2.3 Marco Referencial</b> .....	<b>22</b>
<b>CAPÍTULO III</b> .....	<b>24</b>
<b>MARCO METODOLÓGICO</b> .....	<b>24</b>
<b>3.1 Tipo de Investigación</b> .....	<b>24</b>
<b>3.2 Diseño de la Investigación</b> .....	<b>25</b>
<b>3.3 Población y Muestra</b> .....	<b>25</b>
<b>3.4 Variables de investigación</b> .....	<b>26</b>
<b>3.4.1 Variable dependiente</b> :.....	<b>26</b>
<b>3.4.2 Variable independiente</b> .....	<b>26</b>
<b>3.5 Método, Técnica y Uso de Software de Tratamiento y Análisis de Datos</b> ....	<b>27</b>

3.5.1	Métodos de pronósticos.....	27
3.5.2	Técnica .....	28
3.5.3	Herramienta.....	28
3.5.4	Fuente .....	28
3.6	Metodología.....	28
CAPITULO IV.....		29
PROPUESTA.....		29
4.1	Selección de la Variable.....	29
4.2	Recopilación de Información .....	29
4.4	Preprocesamiento de Datos .....	30
4.4	Enunciación de Conjunto de Entrenamiento, Validación y Prueba.....	30
4.5	Selección de la Arquitectura de Redes Neuronales .....	31
4.6	Topología de la Red.....	35
4.7	Criterios de Evaluación.....	36
4.8	Entrenamiento de la Red Neuronal.....	37
4.9	Pesos sinápticos.....	37
4.10	Gráfico de pronosticados por observados.....	38
4.11	Gráfico de residuos por pronosticado .....	40
4.12	Importancia del predictor.....	40
4.13	Validación de la red con conjunto de prueba.....	43
CONCLUSIONES.....		45
RECOMENDACIONES .....		46
BIBLIOGRAFÍA.....		47
ANEXOS.....		51

## ÍNDICE DE TABLAS

Tabla 1. ....	10
Tabla 2.....	26
Tabla 3.....	26
Tabla 4.....	27
Tabla 5.....	27
Tabla 6.....	27
Tabla 7.....	31
Tabla 8.....	32
Tabla 9.....	38
Tabla 10 .....	41
Tabla 11 .....	43

## ÍNDICE DE GRÁFICOS

Figura 1.....	16
Figura 2.....	17
Figura 3.....	18
Figura 4.....	34
Figura 5.....	35
Figura 6.....	36
Figura 7.....	39
Figura 8.....	40
Figura 9.....	42
Figura 10.....	44

## RESUMEN

En esta investigación se desarrolla un modelo matemático utilizando redes neuronales que permita pronosticar eficientemente la producción en una pequeña empresa dedicada a la fabricación de galleta de chocolate en presentación de 21\*700 g. Para ello, se identificaron las variables independientes que se considera pueden afectar el proceso de producción, todo esto teniendo en cuenta la información y los datos suministrados por la pequeña empresa. El tipo de método utilizado es cuantitativo y la recopilación de los datos fue directa. Posteriormente se construyó el modelo de la red neuronal artificial, para ello se seleccionó el perceptrón multicapa y se manejó el programa Statistical Package for Social Sciences (SPSS). Para la construcción de la red neurona artificial los datos se clasificaron en tres grupos: 65,0% para el entrenamiento, 26,3% para la prueba y finalmente al 8,8% para la reserva. La validación del modelo se efectuó mediante los errores relativos que se obtuvieron: 0,197 para el entrenamiento, 0,181 para la prueba y finalmente el 0,143 para la reserva; adicionalmente la presentación de los valores de cuantía de producción real y de producción pronosticada por la red, cuyo resultado fue un valor de  $R^2$  de 0,812. Finalmente se muestra el aporte que cada una de las variables independientes hace al modelo, se observa que la mayor contribución lo realiza la cantidad de producción pronosticada, seguida de las horas laborales reales, y finalmente las paradas no programadas. En conclusión a partir de su implementación se puede elaborar una guía de predicción de rendimiento en una fábrica de galletas a través del entrenamiento de la red neuronal artificial siendo aceptable porque se ajusta en buena medida a los datos reales.

### **Palabras Claves:**

Modelo matemático, Pronósticos, Redes neuronales artificiales, Proceso, Productividad.

## ABSTRACT

This research shows the development of a mathematical model with the use of artificial neural networks, applied to a small company dedicated to the manufacture of chocolate biscuits in presentation of 21\*700 g, which allows to forecast its production more accurately. For this, the independent variables that are considered to be able to affect the production process were identified, all this taking into account the information and data provided by the small company. The type of method used is quantitative and data collection was direct. Subsequently, the model of the artificial neural network was built, for which the multilayer perceptron was selected and the Statistical Package for Social Sciences (SPSS) program was used. For the construction of the artificial neural network, the data were classified into three groups: 65.0% for the training, 26.3% for the test and finally 8.8% for the reserve. The validation of the model was carried out through the relative errors that were obtained: 0.197 for the training, 0.181 for the test and finally 0.143 for the reserve; additionally, the presentation of the values of the amount of real production and production forecast by the network, whose result was an R2 value of 0.812. Finally, the contribution that each of the independent variables makes to the model is shown, it is observed that the greatest contribution is made by the amount of forecasted production, followed by actual working hours, and finally unscheduled stops. The conclusion of this work is that there is a performance prediction guide in a biscuit factory through the training of the artificial neural network, being acceptable because it adjusts to a good extent to the real data.

Keywords:

Mathematical model, Forecasts, Artificial neural networks, Process, Productivity.

## INTRODUCCIÓN

Las pequeñas empresas generalmente cuando comienzan a operar utilizan métodos o técnicas de pronósticos insuficientes que les ayuden a pronosticar cuanto deben de producir en un período determinado. Si los métodos de pronóstico no son buenos debido a diferentes factores, conduce a pérdidas económicas en pequeñas empresas.

Resulta necesario generar una herramienta que permita a cada pequeña empresa pronosticar la producción de sus servicios que sea lo más cercano a su realidad. Este instrumento de investigación debe tener en cuenta la mayor cantidad de variables independientes que influyen en el sistema de producción.

El objetivo del presente trabajo es elaborar un modelo que utilice redes neuronales artificiales para pronosticar la producción acoplando adecuadamente las variables independientes que inciden en el proceso de fabricación de galleta de chocolate de presentación 21\*700 g

En el capítulo 1 se analizan las causas y consecuencias que generan la problemática; se presenta el planteamiento, definición, y formulación del problema, se plantea objetivo general y objetivos específicos del estudio, se explica el fundamento e importancia del problema a investigar, finalmente se presenta la conceptualización y operacionalización de las variables.

El capítulo 2 consta de tres partes: marco teórico, marco conceptual y marco de referencia. En este se presentan los documentos que son utilizados como fuente de investigación; adicionalmente se identifican las fuentes bibliográficas de importancia que son apoyo del trabajo y delineación del estudio. Finalmente se incorporan algunas definiciones o conceptos sobre temática puntual utilizada en esta investigación para lograr un enfoque claro del trabajo.

El capítulo 3 del estudio se secciona en seis partes: tipo y bosquejo de la investigación, demografía y muestra, se describe cada una de las variables intervinientes en la investigación, variables independientes y variable dependiente; se presenta el método, técnica y uso del software empleado para el tratamiento de los datos, y la metodología.

Y en la sección 4 se expone un modelo basado en el uso de la red neuronal artificial, se plantea una secuencia de pasos a seguir: selección de la variable, recolección de la información, enunciar el conjunto de entrenamiento, confirmación y prueba, elección del diseño de redes neuronales, topología de la red, normas de valoración, adiestramiento de la red neuronal, ponderaciones sinápticas, gráfico de pronósticos por observados, gráfico de residuos por pronosticado, importancia del predictor, confirmación de la red con grupo de prueba.

## CAPITULO I

### 1.1 Planteamiento del problema.

En la actualidad, las industrias alimenticias han evolucionado sus procesos industriales enfocados a perfeccionar el tratamiento, transformación, conservación y envasado de sus productos. Esto ha permitido desarrollar un rol importante en la economía a nivel mundial, logrando representar el 30% de crecimiento en la economía originado en países industrializados. La mayor parte de este incremento se debe a la demanda de productos como bebidas y alimentos elaborados (Berkowitz, 1998).

La Organización de las Naciones Unidas para la Alimentación o Food and Agriculture Organization (FAO) y la Organización para la Cooperación y el Desarrollo Económicos (OCDE), presentaron las perspectivas que se dan en diversos escenarios del comercio alimenticio a nivel nacional, regional y mundial durante el 2020-2029, en donde, el problema refiere a los pronósticos de producción en cuanto a la oferta y la demanda, cabe recalcar que, si se da un mal pronóstico de producción no se podrá cumplir la demanda existente (FAO, 2021).

Si bien es cierto, las perspectivas de los pronósticos son inconstantes, nombrados por la FAO Y OCDE, basándose en factores políticos y económicos. Sin embargo, la mayor fluctuación presente en la actualidad se debe a la inestabilidad de gobiernos consecuencia de la pandemia por Covid 19, debido a que esta afecta directamente la fabricación, la demanda, el consumo y los precios, adicional a esto, otro factor que afecta la demanda se da por las cambiantes preferencias de los consumidores y los futuros acuerdos comerciales entre varios actores del mercado mundial (Nations, 2020).

Hoy en día el sector empresarial tiene un gran reto al momento de predecir el volumen de producción que debe tener periódicamente para así poder satisfacer la demanda existente del mercado, por ello, se debe hacer una planificación, en donde, se tome en cuenta la cantidad de trabajadores que deben tener y cuantas

horas estos deben de laborar para producir lo planificado (Superintendencia de Compañías, Valores y Seguros, 2018).

Estos modelos matemáticos al elaborarlos se convierten en un instrumento utilizado actualmente para el estudio de problemas en distintas áreas del conocimiento (Montes Albarracin, 2016); su objetivo primordial es poder describir, explicar y predecir fenómenos y procesos; por lo tanto, el modelamiento permite analizar el comportamiento de numerosos fenómenos en forma aproximada (Ramos y otros, 2010). Se ve restringido su empleo con frecuencia por poca preparación de las personas involucradas, y la carencia de información acerca de los manuales básicos del modelo matemático (Montesinos-López & Hernández-Suárez, 2007).

Al momento de pronosticar se debe tomar en cuenta el asertividad del método empleado y esto depende de cuál sea la tendencia de los datos históricos y como eso influye en su comportamiento (ARAVENA y otros, 2008). "Comúnmente existen fallas al momento de pronosticar, por ello, se debe tener en cuenta los errores comunes como son: no administrar el margen de error, desconocer el período de vida, no relacionar la historia con la información de mercado, usar solo una técnica de pronóstico de demanda, escoger una data insuficiente y no discurrir que la demanda puede ser elástica" (Zafra Mejía & Gutiérrez Gil, 2015), (López Rodríguez & Zapata Zuluaga, 2018).

Es importante que las empresas al momento de pronosticar sigan 7 pasos: determinar el uso de la predicción, escoger los factores que se deben pronosticar, establecer el horizonte del pronóstico, elegir los métodos de predicción, agrupar la información necesaria para obtener el pronóstico, lograr el pronóstico, validar y constituir los efectos (Méndez Giraldu & Lopez Santana, 2014).

Resulta vital para las empresas realizar el proceso de pronóstico de manera fácil y oportuna, en la menor cantidad de tiempo posible. Para poder pronosticar se

deben considerar diversos factores que puede tener incidentes en la producción como el tiempo de paradas proyectadas de los artefactos, el histórico de la elaboración, el tiempo de paradas no programadas, entre otros (Render & Heizer, 2007).

Los modelos de predicción implican que el error sea mínimo. (Cabrera González & De León Arias, 2019), por ello, se emplea el error medio absoluto (MAE), la desviación media absoluta (MAD), error cuadrático medio (RMSE), etc. (Sánchez Sánchez, 2018), (Damián Llatas & Sandoval Santamaría, 2018).

La relevancia del uso de las redes neuronales es que permiten identificar nexos de diversos grados de linealidad entre las variables consideradas de entrada y de salida, el trabajo es considerado mejor cuando se trata de variables múltiples, sin tomar en cuenta las constantes iniciales. (Villada y otros, 2012); (Villada y otros, 2016)

Es por ello que, nace la pregunta al problema ¿Podemos conseguir crear un modelo matemático que logre pronosticar la elaboración de galletas de chocolate en presentación 21\*700 g, utilizando redes neuronales artificiales?

## **1.2 Delimitación del problema.**

### **Espacio**

Nuestra investigación es realizada en la ciudad de Guayaquil, región costa, provincia del Guayas, en una microempresa que labora en producción de galletas de chocolate en presentación 21\*700 g.

### **Tiempo**

La información plasmada en la presente tiene un periodo de los dos últimos años, por lo tanto, se encuentra dentro del rango previsto en la validez de una investigación científica.

### **Universo**

Para el estudio de esta propuesta se utilizará un modelo matemático orientado a la producción, por ello, se usará una data historia de los dos últimos años.

### **1.3 Formulación del problema.**

¿Será posible que un modelo matemático por redes neuronales artificiales permita predecir de manera rápida y eficiente la producción de galletas de chocolate de presentación 21\*700 g para cubrir la demanda requerida?

### **1.4 Sistematización del problema**

- ¿Existirá la posibilidad de realizar un estudio de la variación de los componentes que inciden en la elaboración de galletas de chocolate de presentación 21\*700 g?
- ¿Será posible elaborar una guía matemática que pueda pronosticar de manera ágil la demanda de rendimiento requerido, a una fábrica de galletas de chocolate de presentación 21\*700 g utilizando Redes Neuronales Artificiales?

### **1.5 Objetivos**

#### **1.5.1 Objetivo general**

Formular un modelo matemático que pronostique acertadamente en una empresa la elaboración de galletas de chocolate de presentación 21\*700 g utilizando Redes Neuronales Artificiales, con el fin de ajustar las variables para alcanzar la producción establecida.

#### **1.5.2 Objetivos específicos**

- Reconocer las variables que afectan la elaboración de galletas de chocolate de presentación 21\*700 g
- Realizar un ajuste de la variabilidad de cada uno de los factores que inciden en la producción de galletas de chocolate de presentación 21\*700 g.

- Entrenar la red neuronal artificial para acoplar adecuadamente las variables independientes que inciden en el proceso de producción de galleta de chocolate de presentación 21\*700 g.

## **1.6 Justificación e importancia**

La principal fuente de ingresos que corresponde a la economía del Ecuador pertenece a la industria manufacturera, en donde, los principales productos de estas industrias son: las bebidas y los alimentos, que llegan al 6.3% de importaciones y representan un valor mayor al Producto Interno Bruto PIB (FAO y CEPAL, 2020). Este sector ha permitido generar plazas de empleo, investigación y desarrollo a través de la implementación de nuevas tecnologías (Banco Central del Ecuador, 2017).

Las matemáticas aplicadas en el sector industrial se enfocan en poder desarrollar soluciones que empleen en áreas productivas, tanto de capitales como de mercados. La aplicación de modelos matemáticos adecuados, permite comprender y resolver situaciones problemáticas que se presentan dentro de cada una de las industrias y en algunos casos permite pronosticar sobre la toma de mostrando cuál puede ser el resultado logrado en caso de seguir la predicción. (Villada, Muñoz, & García, 2012)

El actual trabajo de investigación tiene como fin contribuir con un modelo matemático que permita a la empresa poder predecir la producción con exactitud, disminuyendo la incertidumbre.

Además, debido a la rigurosidad del trabajo de investigación, este podrá servir como base para futuros trabajos de otras empresas que deseen replicarlo

Finalmente se presenta una estrategia que permita la construcción de un modelo aplicado a la realidad de la industria, no volviéndose una camisa de fuerza, sino

que permite su cambio o actualización según los cambios en la demanda del mercado

### **1.6.1 Justificación Teórica**

Debido a las múltiples variaciones en las necesidades de los clientes y su deseo de ahorro en costo de producción por parte de las empresas, hoy resulta más que necesario el interés de entender cómo se elabora y desarrolla un modelo matemático adaptado a la producción, y con el análisis de la big data de la empresa resulta importante aplicar el uso de las redes neuronales artificiales.

### **1.6.2 Justificación metodológica**

La investigación se basa en el estudio metodológico de las diferentes causas que inciden en la elaboración del producto como son: horas reales trabajadas, horas de paradas no programadas, horas de paradas programadas, horas hombres trabajadas (HH), horas extras (kg). Con estos factores se determina los elementos importantes en la elaboración del modelo matemático.

El empleo de las redes neuronales nos ayudará a establecer la tipología de la red neuronal artificial a utilizar, es decir la cuantía de capas ocultas, el dígito de neuronas en la capa oculta, la función de activación o de transmisión, adicionalmente de definirá el número de períodos de la red.

### **1.6.3 Justificación práctica**

Esta investigación justifica como el modelo matemático, puede lograr en una empresa realizar una predicción de su producción, identificando exactamente cuáles son las variables que afectan la producción, logrando producción eficiente a su empresa.

Este modelo matemático se adaptará a la demanda real de producción y puede ser ajustado a cualquier otro producto que la empresa elabore; al mismo tiempo podría servir a cualquier tipo de entidad.

## **1.7 Hipótesis**

### **1.7.1 Hipótesis General**

Si se entrena una red neuronal artificial será posible crear un modelo matemático que ajuste adecuadamente las variables independientes que inciden en el proceso de producción de galleta de chocolate de presentación 21x700 g.

### **1.7.2 Hipótesis Particular**

Se puede determinar los principales elementos que afecten la elaboración de galletas de chocolate de presentación 21\*700 g.

Es viable estudiar los componentes que influyen en la variabilidad que afecten un modelo de pronósticos de producción de galleta de chocolate de presentación 21\*700 g

Es posible entrenar la red neuronal artificial de manera que permita acoplar adecuadamente las variables independientes que inciden en el proceso de producción de galleta de chocolate de presentación 21x700 g.

### **1.7.3 Conceptualización y operacionalización de variables**

Variable independiente: cantidad de producción real, horas laborables planificadas, paradas no programadas.

Variable dependiente: cantidad de producción pronosticada

**Tabla 1.****Operacionalización de variable**

<b>Variable</b>	<b>Definición conceptual</b>	<b>Indicadores</b>	<b>Técnica</b>
Cantidad de producción real	La producción real se refiere a la producción eficiente. La producción real se logra por la demanda agregada, puede que concuerde o no con la producción potencial.	Kilogramos producidos por semana	Registro histórico de datos
Horas laborables planificadas	Se refiere al valor típico de las horas planificadas trabajadas en un empleo por un período de tiempo que comprende el período corto de medición de referencia utilizado	Horas planificadas	Registro histórico de datos
Paradas no programadas	Periodo durante el cual la planta no labora, se aprovecha el tiempo con mantenimiento, reparaciones y rediseños de máquina.	Horas paradas	Registro histórico de datos
Cantidad de producción pronosticada	El pronóstico es la cuantía de productos que la microempresa desea generar con base en ciertos indicadores	Kilogramos producidos por semana	Registro histórico de datos

## CAPÍTULO II

### 2.1 Marco Teórico

#### 2.1.1 Modelo matemático

Ciertas circunstancias actuales presentan dificultades que requieren resolución y disposiciones. Algunas dificultades tienen un aspecto matemático relativamente simple, otros se enfocan en un área determinada del conocimiento, requiriendo un análisis más preciso de los problemas. (Salett Biembengut & Hein, 1999)

La formulación de modelos matemáticos son herramientas que analizan problemas de diferentes campos de discernimiento; "la finalidad de las guías matemáticas es manifestar, reconocer y pronosticar fenómenos y métodos en diversas zonas del entendimiento". (Montesinos-López & Hernández-Suárez, 2007)

Un modelo matemático es una forma de representar el fenómeno objeto de estudio mediante el lenguaje matemático que representa su dirección que simbolizan sus interacciones. Al estudiar el modelo matemático parte de identificar aspectos claves o definir aspectos de un sistema y caracterizarlos con expresiones matemáticas. (Salett Biembengut & Hein, 1999)

Las matemáticas facilitan el desarrollo de modelos que permitan comprimir, simular y predecir mejor el fenómeno en estudio. Un modelo se puede construir en términos como: expresiones o fórmulas numéricas, gráficos, ecuaciones algebraicas, programas de computadora, etc. (Salett Biembengut & Hein, 1999)

Varias características atractivas de los modelos matemáticos son la distinción de las fórmulas, su simplicidad y la máxima aplicación posible al sistema en desarrollo, teniendo en cuenta los objetivos y la extensión del problema (De Torres Curth, 2015).

Un modelo matemático comienza identificando elementos originarios o deterministas del sistema y describiéndolos usando cálculos. La iniciativa en acción es descubrir un equilibrio entre la claridad y la duplicación de la conducta que permita entender, experimentar y pronosticar, ajustar el costo del cambio (s) que representan, reaccionar al resultado del sistema en su grupo. (Bocco, 2010)

Los modelos reproducen el funcionamiento de un sistema y producen los datos de las variables de salida, es decir, los efectos obtenidos por el modelo. Esta adaptación se refiere a que estos valores generados por el modelo deben ser similares (aunque estarán sujetos a error) a los valores observados en la práctica. (De Torres Curth, 2015)

Por lo general, hay dos técnicas en la creación de un modelo matemático:

1. Elección de componentes, variables y;
2. Relaciones que existen en el sistema modelado.

Estas relaciones pueden describirse mediante una ecuación simple (como el modelo exitoso de Einstein) o una red compleja de ecuaciones relacionadas. El lenguaje simbólico de las matemáticas permite la expresión de ideas muy complejas y es una herramienta ideal para este propósito. (De Torres Curth, 2015)

El modelado mediante el uso de redes neuronales en los últimos años se considera valioso y estudiado, como por ejemplo identificar el incumplimiento del mercado proporcionado a su registro de clientes. En la indagación del modelo de predicción del incumplimiento, la red neuronal eligió las variables cupo asignado, vencimiento, jurisdicción, personal a cargo, sexo, ocupación, escolaridad, estado civil e ingreso (Támara-Ayús y otros, 2019).

Los tipos de redes neuronales pueden ser usadas para encasillar la historia de datos, por lo que la mayoría de la información es cualitativa; por ejemplo, la

correspondencia de los estudiantes con sus padres, entretenimientos, si fuman, su escuela de origen, sexo, entre otros (Miranda García y otros, 2020).

### **2.1.2 Pronóstico de producción**

“Los pronósticos de venta se han convertido ahora en la principal fuente de información para estimar la demanda lo más cerca posible de los hechos del mercado. La aleatoriedad inherente a la mayoría de los mercados se puede reproducir con modelos probabilísticos más intensivos en computadoras que en el pasado. El carácter integral de las resoluciones que tienen en cuenta el problema de la previsión de la demanda para calcular las piezas necesarias es fundamental para diseñar modelos fiables y eficientes”. (Sánchez López, Barreras Serrano, Pérez Linares, Figueroa Saavedra, & Olivas Valdez, 2013)

El aumento de demanda de una gran variedad de mercados obliga a las empresas a implementar programas de producción exactos y maleables que permitan aumentar el ahorro de recursos, trabajo y cumplir con los términos de contrato de los clientes (Moreno Castro, 2019).

La visión, el discernimiento y los datos disponibles son importantes para establecer predicciones de atenuación de cambios. Evaluar las ventas expectantes es trabajo complejo que puede reducirse usando información de mercado, tendencias de inventario o recibos de ventas anteriores como fuentes de datos. (Moreno Castro, 2019)

Los métodos de pronóstico generalmente pueden segmentarse en cinco categorías:

- Evaluación ejecutiva.
- Investigación.
- Análisis de series temporales.
- Estudio de retrocesión.

➤ Ensayos de clientes.

Al elegir el modelo pronóstico influye algunos elementos, incluye el precio involucrado, los objetivos de predicción, la seguridad y estabilidad de las cifras históricas de negocios, el periodo libre para el pronóstico, el ejemplo de producto, las características del cliente, el tiempo, etc. (Moreno Castro, 2019)

La previsión se utiliza en las empresas para determinar si hay suficiente demanda para ingresar al mercado, determinar la capacidad esencial para diseñar instalaciones, identificar fluctuaciones de demanda a mediano y corto plazo para la planificación de la producción, planificación del trabajo manual, etc. (Rubio Guerrero, 2017).

Las decisiones sobre la capacidad y la ubicación, así como la selección de los procesos y equipos de producción, son el primer paso para tratar de conseguir una medida entre la venta y el rendimiento de gran alcance. Sin embargo, en poca duración, la variabilidad de la demanda es mucho mayor y es necesario tomar medidas adicionales para abordar el problema. Eso es exactamente lo que son las tareas de planificación y programación de la producción. (EscobarGómez, Díaz-Núñez, & Taracena-Sanz, 2010)

### **2.1.3 Redes Neuronales Artificiales.**

Una parte del desarrollo científico se direcciona a observar las habilidades de los seres vivos en particular de hombres y mujeres, para incorporar esta información cuando se diseñan de nuevos prototipos de máquinas. Es por eso que la IA (Inteligencia Artificial) intenta descubrir y revelar aspectos de la inteligencia humana que las máquinas pueden igualar. Estos aspectos han evolucionado significativamente en los últimos años con aplicaciones en sitios específicas como visión por computadora, pruebas teóricas y procesamiento de información expresada en lenguaje humano. (Matich, 2001)

Las redes neuronales artificiales (RNA) son objetos de programación que simulan la función de las neuronas biológicas. Estas redes están diseñadas en paralelo por las conexiones de las redes y tienen una organización jerárquica que les permite interactuar con el mundo. (Rivas Asanza & Mazón Olivo, 2018)

Las redes neuronales se utilizan en varios campos, como el modelado, la observación de lapsos de tiempo, examinar patrones, el desarrollo de señales y el control de estas. Esto se debe a que tiene una propiedad importante: la capacidad de aprender de los datos de entrada, con o sin un maestro. (Rivas Asanza & Mazón Olivo, 2018)

Las redes neuronales están formadas por un grupo de unidades PE (elemento de procesamiento) elementales relacionadas de una manera peculiar. La importancia de la ANN (Artificial Neural Networks) reside no solo en el tipo del elemento PE sino además en la forma como estos elementos se encuentran conectados. Una red característica tiene una sucesión de capas con enlaces entre ellas contiguas sucesivas. (Basogain Olabe, 2019)

Las diversas configuraciones y algoritmos diseñados para la red neuronal artificial están inspirados en la forma como el cerebro humano interactúa con su sistema neuronal. Sin embargo, esto no significa que las ANN actúen idénticamente como lo hace el cerebro humano, ya que existen restricciones del conocimiento del funcionamiento y comportamiento del cerebro que es bastante complejo. Incluso, los proyectistas de redes artificiales están profundizando en la información biológica existente y probando novedosas organizaciones que exhiben un comportamiento apropiado y útil. (Basogain Olabe, 2019)

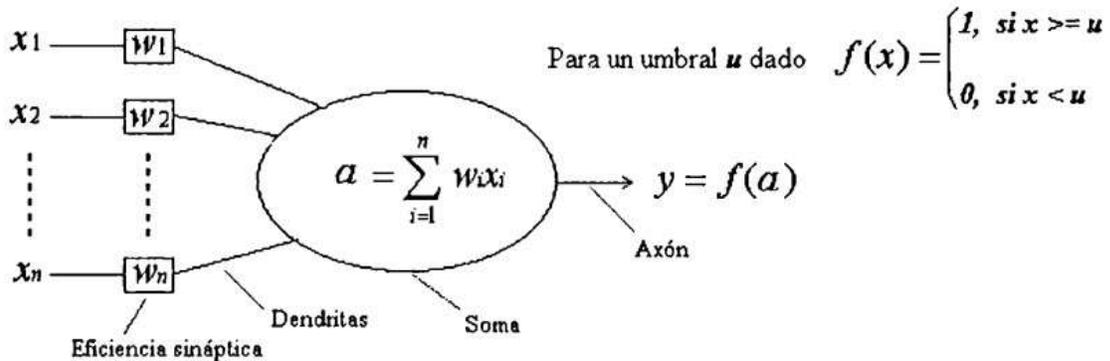
### **Neurona Artificial**

Warren McCulloch y Walter Pitts en 1943 realizaron observaciones biológicas, presentando el inicio de un tipo de una neurona artificial. Según (Freeman Castro

& Skapura González, 1993), los componentes de cálculo que conforman la mayor parte de tipos de RNA no suelen llamarse neuronas artificiales, lo usual es darles el nombre de nodos, unidades o componentes de procesamiento o PE por sus siglas en inglés.

**Figura 1**

**Modelo de neurona artificial de McCulloch y Pitts**



Nota. La imagen representa el modelo básico de una neurona artificial, los valores de entradas, sus pesos y su interacción. Tomado de "Las Redes Neuronales Artificiales – Fundamentos teóricos y aplicaciones prácticas, Flores y Fernández", 2008, Netbiblo

Podemos observar en la figura 1, que una red neuronal artificial tiene un número finito de uniones de entrada -para este hecho llamado n- que corresponden a las dendritas para el modelo biológico, en la que ingresa cada uno de los n elementos de información o portador de entrada. Cada conexión de entrada tiene inscrita una dimensión mencionada peso o intensidad -eficiencia sináptica- determinada por los elementos del vector de pesos. Estos pesos de enlace  $w_i$  alcanzan ser positivos -excitatorios- o negativos -inhibitorios-.

Regularmente se agrega al grupo de pesos de la neurona una medida añadida,  $\theta_i$ , que llamaremos *umbral*, la cual se sustrae del potencial postsináptico, obteniendo la siguiente expresión para la función de activación:

$$\sum_j w_{ij} x_j - \theta_i$$

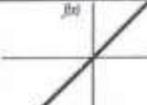
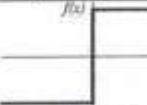
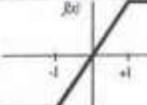
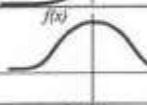
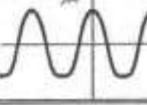
Análogamente, iniciando  $i$  y  $j$  en cero  $w_{ij} = \theta_i$  y  $x_0 = -1$  (constante) obtenemos la siguiente expresión que modela el funcionamiento de la neurona.

$$y_j(t) = f_i \left( \sum_{j=0}^n w_{ij} * x_j \right)$$

Resta instaurar que función de activación tiene la neurona, con el fin de completar su definición, como se aprecia en la figura 2.

**Figura 2**

**Funciones de activación más usuales**

	Función	Rango	Gráfica
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a tramos</b>	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
<b>Sigmoidea</b>	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-bx^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

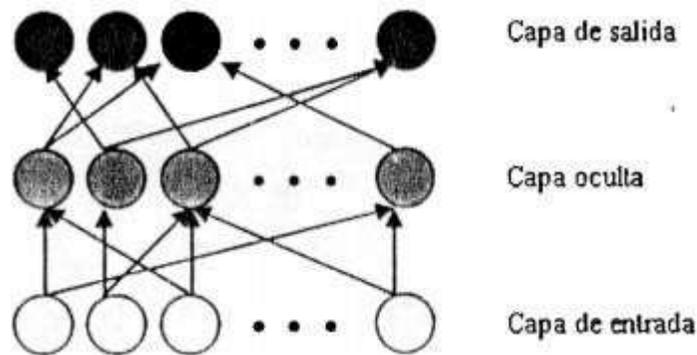
Nota. La imagen representa las Funciones de activación más usuales. Tomado de "Redes Neuronales: Guía Sencilla de Redes Neuronales Artificiales", Rudolph Russell, 2018, CreateSpace Independent Publishing Platform

### Arquitectura de una red neuronal artificial

Las redes feedforward, tienen una organización igual mostrada en la Figura 3. Observamos este género de grafo dirigido se fragmenta en capas, es decir conjuntos de nodos en un mismo nivel de acuerdo a sus enlaces.

**Figura 3**

**Distribución de las distintas capas de nodos en una red neuronal de ejemplo**



Nota. La gráfica simboliza la colocación de las distintas capas y nodos en una red neurona artificial, se observan los enlaces entre neuronas de distintas capas. Tomado de "Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva", (Pino Díez, Gómez Gómez, Abajo Martínez), 2001, Universidad de Oviedo.

- Capa de entrada: dispuesta por nervios que recogen cifras o señales procedentes del ambiente.
- Capa de salida: Son las neuronas que suministran la réplica de la red neuronal.
- Capa oculta: nos presentan ninguna conexión directa con el medio.

Las conexiones neuronales son reactores o inhibitorios, según la señal del peso sináptico asociado al enlace, depende de la conexión será positivo (excitada) y negativo (inhibida). No es frecuente esta definición porque el peso y la dimensión son establecidos por el *cálculo de entrenamiento*.

Los enlaces pueden dividirse en *enlaces intracapa* y *conexiones intercapa*. Los enlaces intracapa se describen como los enlaces entre las neuronas de una misma capa y, los segundos pertenecen a las uniones entre neuronas de diferentes capas.

### **Modo de operación**

Al mencionar el modo de operación se hace referencia al modo en que la red neuronal genera las señales externas y reacciones de salida. Se debe observar la división de las redes neuronales en dos niveles:

- Redes estáticas. Este nivel de red produce una cuantía de las entradas, y las salidas consiguen un valor permanente libremente de las entradas en la situación preliminar, en un periodo bajo determinada medida. Estas redes se organizan por supuestas ondas de retroalimentación y elementos de retraso en los variados PE que las constituyen. De acuerdo a su forma de funcionar, las tramas poseen una competencia establecida para reducir oficios anexos al lapso paralelo con las que describiremos en el siguiente párrafo.

### **Entrenamiento de las redes neuronales artificiales**

El fin del entrenamiento de una RNA es obtener un resultado concluyente, para que los datos suministrados inicialmente arrojen un resultado cercano los datos de prueba. La evolución del aprendizaje consiste en el estudio sucesivo de varios grupos o vectores de entrada para que se acuerden los pesos de abarcar según un procedimiento predeterminado. En la fase de entrenamiento los pesos se aproximan poco a poco hacia los valores que permitan que los datos iniciales produzcan el resultado esperado.

Los datos del algoritmo de entrenamiento de las conexiones de las RNA se clasifican en: Supervisado y No Supervisado.

**Entrenamiento Supervisado:** Los algoritmos de este entrenamiento necesitan unir los vectores de entrada con su vector de salida.

El entrenamiento nos señala un vector de ingreso a la red, medición de la red de salida, compara la salida esperada, y el error en la respuesta se empleará para retroalimentar la red y cambiar los pesos que calculan la disminución del mismo.

Los pares de vectores de entrenamiento son usados de manera continua y constante. Se calcula el error para el conjunto de entrenamiento sea de poco valor y aceptable.

## 2.2 Marco Conceptual

Los siguientes conceptos son tomados del libro “Modelos matemáticos en las ciencias” (De Torres Curth, 2015) y “Redes Neuronales: Conceptos Básicos y Aplicaciones (Matich, 2001):

- **Algoritmo:** es un grupo de lineamientos establecidos que permite corregir un problema, de una manera precisa, mediante operaciones metódicas (no necesariamente ordenadas) y limitadas. Estos conocimientos concretos y ordenados en función de los datos, solucionan la tarea.
- **Aprendizaje supervisado:** método para derivar una función con los datos de entrenamiento. Las cifras de entrenamiento radican en par de objetos: un elemento son los datos de entrada y segundo, la respuesta esperada.
- **Propagación hacia atrás:** es un tipo de red de entrenamiento supervisado, usa un lapso de difusión – ajuste de dos etapas. Una vez estudiado el patrón de entrada de la red como señal, se amplía de la capa primaria a las siguientes capas de la red, hasta estructurar una salida.
- **Capa de entrada:** dispuesta por neuronas que captan los datos originarios del ambiente.

- **Capa de salida:** son neuronas que proveen el resultado de la red neuronal.
- **Capa oculta:** es una capa interior, sin conexión directa con el ambiente.
- **Función de activación:** la capacidad de transmitir valores producidos por conjugación directa de pesos y entradas, una forma de generar datos de conexiones de salida.
- **Modelo matemático:** la importancia resumida de la realidad usa funciones o fórmulas que representan sus interacciones
- **Neurona excitada:** La excitabilidad neuronal, el impulso o la neurogénesis es la capacidad de las neuronas para cambiar su potencial eléctrico y transmitir ese cambio a través de sus axones.
- **Neurona:** es la unidad básica del sistema nervioso y principal del cerebro. Una neurona artificial busca igualar el comportamiento de una neurona biológica. Las neuronas artificiales se emplean para constituir una red neuronal artificial alcanzando el modelo de una actividad cerebral humana.
- **Peso sináptico:** define la fuerza de un enlace sináptico entre dos nervios, la neurona cerca a la sinapsis  $i$  y la neurona lejana a la sinapsis  $j$ . Logran valores positivos, negativos o cero.
- **Pronóstico de producción:** ayuda a predecir eventos futuros relacionados a las prestaciones dadas. Se planea cuanto se va a ofrecer, lo que establece objetivos de ventas.
- **Pronóstico:** es una evaluación de la conducta de variables estadísticas en eventos esperados.
- **Red neuronal:** es un modelo sencillo que se iguala cómo el cerebro humano procesa la información.
- **Redes neuronales artificiales:** son redes relacionadas ampliamente con sus semejanzas en los componentes simples y de forma ordenada, las cuales intentan interactuar con los objetos del mundo actual de igual forma que lo hace el sistema nervioso biológico.

### **2.3 Marco Referencial**

Los trabajos de investigación de varios autores han sido estudiados y revisados como antecedentes para este proyecto de investigación. Estos trabajos contienen información importante y muestran similitudes con los temas investigados.

Zapata (2019) en su proyecto de investigación denominado “Aplicación de las redes neuronales para establecer las predicciones mensuales de desvalorización en el año 2018” su principal función fue construir una red neuronal, que establece las predicciones mensuales de la inflación para el año 2018 empleando los datos de enero 2008 a diciembre 2017. La edificación y diseño del modelo o de la red neuronal se elaboró con apoyo de un programa matemático, MATLAB y de los programas estadísticos SPSS y EVIEWS; estos últimos se manejaron para el pre procesamiento de la información, que incluyó el estudio de la no estacionariedad de la serie y de su innovación a serie estacionaria; exigencia importante para aumentar la velocidad de correlación del algoritmo de aprendizaje de la red. En este argumento, se muestran las redes neuronales infundidas en los sistemas biológicos para solucionar conflictos, en aquellos en donde la sistemática habitual tiene ciertos problemas, como son aquellos sistemas altamente no lineales. Uno de estos inconvenientes en estos instrumentos está indicando gran desempeño, es la evaluación de funciones, incluso para la realización de predicciones. (Zapata Laureano, 2019)

Malaver (2015) en su trabajo “Aplicación de redes neuronales para determinar la predicción de los negocios en la empresa CATERING & BUFFETS MyS situada en la ciudad de Piura” comprueba un pronóstico de ventas de prestaciones que ofrece Catering & Buffets MyS con el mínimo de error al emplear las redes neuronales. Se usó la técnica que planteó Kaastra y Boyd, empleando una secuencia de caminos para establecer desde cero la RNA. La red neuronal empleada fueron múltiples capas, ya que al tener una capa oculta donde se logra el proceso de la información que se originan de la capa de entrada la respuesta es enviada a la capa de salida. Establecieron tres formas de organización de la RNA

logrando el más pequeño error, como respuesta la tercera red neuronal fue útil por mínimo porcentaje de error (1%), se evidenció la Hipótesis planteada.

Al concluir este estudio, las redes multicapas son válidas para predecir las ventas, y la red neuronal es un instrumento útil para estos estudios. (Malaver Elera, 2015)

Gil & Rodríguez (2010) en su trabajo de investigación “Sistema de pronóstico de la venta de productos farmacéuticos basado en redes neuronales” para su análisis empleo una RNA multicapa para el pronóstico de la venta de artículos medicamentosos, usando algoritmo de backpropagation una tasa de error de 3.57%, uso metodología MATLAB para la construcción de la red neuronal.

“La demanda de negocios actualmente establece una percepción exacta para programar planes de producción, catálogo, comercialización y adquisición de productos en las entidades.; en el sector farmacéutico, los efectos de los tiempos, ofertas, modificación de valores, difusión, productos vendidos o no y datos atípicos de manera total afectan el orden. Este estudio nos define que por arriba de la oferta tiene entre sus efectos el excesivo inventario de fármacos, expiración, en cambio, predecir por debajo de la demanda tiene como resultado el deterioro de las ventas y un aumento en los precios. ” (Gil Zavaleta & Rodríguez Collas, 2010)

Benites (2021) en su trabajo “Implementación de un sistema de pronósticos de negocios aplicando redes neuronales artificiales para la empresa cerámicos LAMBAYEQUE SAC” empleo un modelo de predicción de ventas con RNA. Al ejecutar este proceso de pronóstico se empleó la Red Neuronal Perceptrón Multicapa y Regresión de Serie Temporal con variables de entrada, recogida y regulación de la información. El resultado de la venta mensual diaria pronosticada manipulando la red neuronal con ratio de entrenamiento de 0.01 osciló como límite de venta diaria mensual siendo una venta eficiente. (Benites Sernaqué, 2021)

## **CAPÍTULO III**

### **MARCO METODOLÓGICO**

#### **3.1 Tipo de Investigación**

##### **Investigación Exploratoria. -**

Nuestro estudio es de tipo exploratorio, la investigación es aplicada en fenómenos que no se han examinado previamente y se tiene el interés de explorar sus características, de forma que mediante la recolección de datos se pueda descubrir patrones lo cual nos brindará una explicación. La información teórica y práctica permitirá crear un modelo matemático, consiguiendo así el objetivo de este estudio.

##### **Investigación Documental. -**

Este proyecto documental nos sirve para su desarrollo utilizando diverso material bibliográfico, tales como textos, tesis, capítulos académicos y temas de apoyo a los diferentes argumentos tratados en este estudio.

##### **Investigación de Campo. -**

En este análisis de campo la información en el sitio, nos permite una información veraz para el estudio.

##### **Investigación Aplicada. -**

La investigación es aplicable porque pretende generar conocimiento que pueda ser aplicado directamente a un problema del sector manufacturero. Se pretende crear un modelo matemático que contribuya al pronóstico de producción. Se

conjetura predecir la producción en base a la atribución de distintas variables independientes.

### **Investigación Cuantitativa. -**

La investigación es cuantitativa porque se seleccionan y examinan cifras numéricas, las cifras de fabricación semanales. Esta técnica identifica tendencias o comportamientos de producción, lo que permite realizar pronósticos, comprobar conexiones y determinar efectos generales de producción. Con su implementación se espera que sean efectivos los niveles de producción, empleando este estudio para futuros acuerdos.

### **3.2 Diseño de la Investigación**

Se propone un modelo matemático para predecir la producción utilizando redes neuronales artificiales aplicadas a una microempresa de galletas de chocolate de presentación 21\*700 g.

El objetivo de esta investigación será obtener un modelo matemático adecuado que permita una predicción rápida de la producción en una microempresa de galletas de chocolate de presentación 21\*700 g. utilizando una Redes Neuronales Artificiales.

Este trabajo es de tipo longitudinal, porque toman datos en un intervalo de tiempo prolongado, para analizarlos utilizando medidas continuas

### **3.3 Población y Muestra**

Se trabajará con todos los datos, es decir, el 100 % de las cifras recogidas de la producción de la microempresa en su producto de galletas de chocolate de presentación 21\*700 g, de los últimos dos años; Los datos recopilados son consistentes con la producción semanal, y cabe señalar que hay semanas en las que las pequeñas empresas no elaboran este producto debido a la disminución de ventas a los clientes.

### 3.4 Variables de investigación

#### 3.4.1 Variable dependiente:

La variable a estudiar es Cantidad de Producción Real CPR (kg), la información se recopila de la suministrada por la empresa, corresponde a los kilogramos reales producidos de la microempresa en su producto de galletas de chocolate de presentación 21\*700 g.

**Tabla 2**

#### **Variable dependiente CPR**

Variable dependiente	Unidad de medida
Cantidad de Producción Real	Kilogramos

Elaborado por: El autor.

#### 3.4.2 Variable independiente:

Inicialmente se consideran tres variables independientes y luego se desarrolla el análisis de la variable excluida, se espera ver la extensión, peso o contribución de cada variable al modelo matemático, y lo que contribuya mínimamente al modelo de la red neuronal artificial pueda ser excluida en un siguiente modelo de red.

a) Cantidad de Producción Programada CPP (kg).

Se refiere a la cuantía en kilogramos de galletas de chocolate de presentación 21\*700 g que la empresa quiere o planea producir.

**Tabla 3**

#### **Variable independiente CPP**

Variable independiente	Unidad de medida
Cantidad de Producción Programada	Kilogramos

Elaborado por el autor.

b) Horas Laborales Planificadas HLP (hr).

Las horas laborables programadas corresponden a las horas de trabajo hipotéticas que debe ocuparse a lo largo de la semana para cumplir la fabricación planificada. Esto en algunas empresas se llama Horas Hombre.

**Tabla 4**

**Variable independiente HLP**

Variable independiente	Unidad de medida
Horas Laborales Planificadas	Hora

Elaborado por: El autor.

c) Paradas No Programadas PNP (hr).

El período de Paradas No Planificadas, es el tiempo desaprovechado por la duración de la inactividad de la máquina por avería, es decir, la máquina entra en reparación y abandona la línea de fabricación.

**Tabla 5**

**Variable independiente PNP**

Variable independiente	Unidad de medida
Paradas No Programadas	Hora

Elaborado por: El autor.

### 3.5 Método, Técnica y Uso de Software de Tratamiento y Análisis de Datos

#### 3.5.1 Métodos de pronósticos

Método general de diseño predictivo.

**Tabla 6**

**Método general de diseño de pronóstico**

Ítem	Pasos	Explicación
1	Describir el plazo del diseño	Corto, mediano y largo plazo
2	Examinar los orígenes	Describir las variables a pronosticar y sus dependencias

3	Escoger un método	Elegir la técnica que más se ajusta al tipo de conflicto expuesto
4	Utilizar tecnologías seleccionadas	Aplicar el pronóstico con la tecnología seleccionada

Fuente: Elaborado por el autor.

### **3.5.2 Técnica**

Redes Neuronales artificiales (RNA)

### **3.5.3 Herramienta**

Software IBM SPSS Statistics Versión 24

### **3.5.4 Fuente**

La información obtenida de la microempresa, nos proporciona un archivo histórico de los datos reales útil para crear un modelo matemático que mejore los pronósticos de producción.

## **3.6 Metodología**

En esta investigación se manejará el método presentado por Kaastra y Boyd (1996), titulado “Designing a neural network for forecasting financial and economic time series”. El objetivo es presentar una guía práctica introductoria en el bosquejo de una red neuronal empleada para predecir información. Plantea un procedimiento de ocho pasos para diseñar un modelo de pronóstico empleando redes neuronales que incluye una discusión de las compensaciones en la selección de parámetros (Kaastra & Boyd, 1996).

Esta metodología consta de 8 puntos:

1. Elección de la variable
2. Recopilación de datos
3. Preprocesamiento de cifras
4. Enunciación de grupo de aprendizaje, confirmación y ensayo

- 4.1 Conjunto de aprendizaje
- 4.2 Conjunto de confirmación
- 4.3 Conjunto de ensayo
- 5. Elección de la construcción
  - 5.1 Dígitos de neuronas de entradas
  - 5.2 Cuantía de capas ocultas
  - 5.3 Cantidad neuronas en la capa oculta
  - 5.4 Número de neuronas en la capa de salida
  - 5.5 Función de transmisión
- 6. Juicio de valoración
- 7. Aprendizaje de la red neuronal
- 8. Aplicación del modelo de redes neuronales artificiales

## **CAPITULO IV**

### **PROPUESTA**

#### **4.1 Selección de la Variable**

Establecer cuáles son las variables de entrada y de salida de la red neuronal que resultan importantes para el pronóstico de producción. Se emplea como entradas datos técnicos fundamentales por las características propias de la investigación.

- Variable a Pronosticar. Cantidad de producción real de la demanda de galletas de chocolate de 21\*700 g.
- Tipo de Variable. Cuantitativa.
- Unidad de medida: gramo [g].

#### **4.2 Recopilación de Información.**

Los datos que se identifican en la investigación fueron otorgados por la empresa, y consisten en mediciones semanales de: cantidad de fabricación planificada, horas trabajadas programadas, paradas no planificadas, y cuantía de producción real. Por lo tanto, los datos temporales de la producción de galletas de chocolate de

21\*700 g, que se presenta a la red, corresponde a los datos del periodo comprendido entre enero de 2020 hasta diciembre de 2021, lo que hace un total de 104 semanas, hay que recalcar que no todas las semanas la empresa producía el producto por lo que se tiene datos de 80 semanas

Los datos fueron ordenados y clasificados en una hoja de cálculo en Excel, de forma tal que fuera fácil su exportación hasta el software seleccionado para el diseño de la implementación de la red neuronal, el software seleccionado para la aplicación de la red neuronal artificial es el SPSS

#### **4.4 Preprocesamiento de Datos**

El preprocesamiento de datos analizará la información que nos indica cuales son las variables de entrada y de salida para la red neuronal artificial, se debe de tener en cuenta que no existan valores atípicos que puedan influenciar de forma negativa en el adiestramiento de la red neuronal.

Se debe recordar que la red neuronal artificial en su aprendizaje, buscará patrones para lograr su entrenamiento. En nuestro proyecto, no fue necesario la etapa de preprocesamiento de datos ya que se encuentran libres de ruidos (datos sin sentido por demasiadas variaciones).

#### **4.4 Enunciación de Conjunto de Entrenamiento, Validación y Prueba**

##### **A1. Agrupación de Entrenamiento.**

Son una serie de cifras que son usadas para que la red neuronal artificial aprenda los patrones presentes en los datos, con ello la red puede extraer resultados de los pesos sinápticos (es el impulso de señales sinápticas entre dos neuronas) Como se muestra en la tabla 6, para el presente trabajo se utilizó 52 datos de entrenamiento, lo que corresponde al 65,0% de los datos totales

##### **A2. Conjunto de Prueba o validación.**

Este grupo de datos serán utilizados para evaluar o validar los hiperparámetros de nuestro modelo, aquí se ajustan los hiperparámetros, como, por ejemplo: la tasa de aprendizaje, número de capas, número de neurona por capas, etc.

Como se muestra en la tabla 6, en el presente estudio se utilizaron 21 datos de prueba, lo que corresponde al 26,3% de los datos totales.

### **A3. Conjunto de Reserva o test.**

Este grupo de datos interesa para validar la generalización del modelo de aprendizaje; es decir queremos saber que tan bien funciona nuestro modelo con datos que nunca ha visto o utilizado, es decir, resulta una evaluación independiente que ayuda a entender que tan bien puede funcionar nuestro modelo en la realidad. Como se muestra en la tabla 6, en el actual documento se empleó 7 datos de reserva, lo que corresponde al 8,8% de los datos totales

**Tabla 7**

#### **Resumen de procesamiento de casos**

		<b>N</b>	<b>Porcentaje</b>
	Entrenamiento	52	65,0%
Muestra	Pruebas	21	26,3%
	Reserva	7	8,8%
Válido		80	100,0%
Excluido		0	
Total		80	

Fuente: elaborado por el autor

### **4.5 Selección de la Arquitectura de Redes Neuronales**

El esquema de la red neuronal hace mención a la cantidad de capas neuronales, a la cantidad de capas ocultas en una red, cantidad de neuronas en cada una de

ellas, el enlace entre neuronas o capas, al modelo de neuronas presentes, y en el modo en que son entrenadas.

Este estudio se encargó que una red neuronal de tipo "feed forward": es organizada en capas, todos los nervios de una capa se unen con todas las neuronas de la cubierta próxima, la información es pasada desde la capa de entrada hasta la capa de salida, y para el entrenamiento de la red se utilizó el algoritmo de back-propagation.

**Tabla 8**

**Resumen del modelo**

Entrenamiento	Error de suma de cuadrados	5,021
	Error relativo	0,197
	Regla de parada utilizada	1 paso(s) consecutivo(s) sin disminución del error <sup>a</sup>
	Tiempo de entrenamiento	0:00:00,00
Pruebas	Error de suma de cuadrados	1,509
	Error relativo	0,181
Reserva	Error relativo	0,143

Variable dependiente: CPR

Fuente: Elaborado por el autor.

**B.1. Número de neuronas en la capa de entrada**

Conciérne a las variables empleadas en la planificación de la producción: cantidad de producción planificada, horas laborales planificadas, paras no programadas; por lo tanto, tenemos 3 neuronas de entrada, además como se puede observar en la tabla 8 son 3: CPP, HLP, PNP

## **B.2. Número de Capas Ocultas.**

Las capas ocultas en una red neuronal artificial contienen unidades no observables como neuronas, pesos de ponderación. Los valores que toman estas unidades ocultas dependen de la selección de función de transferencia que seleccione; la forma exacta de esta función está determinada en parte por tipo de red. Los perceptrones multicapa pueden tener una o dos capas ocultas

En el presente estudio como se puede examinar en la tabla 8, se ha decidido por una sola capa oculta, dado que para este tipo de caso resulta ser suficiente para lograr una buena generalización de la red neuronal artificial.

## **B.3. Número de Neuronas Ocultas.**

Este estudio logró que de forma automática el software calcule el número de neuronas; esta opción permite que se construya una red con una capa oculta y que se calcule la cantidad de nervios que posee. Como se puede mostrar en la tabla 8, la cantidad de neuronas en la capa oculta determinada por el software es de 1.

## **B.4. Número de Neuronas de Salida.**

La cuantía de nervios de capa de salida depende del número de variables dependiente del modelo o por lo que se quiere predecir. Para el presente trabajo como se muestra en la tabla 8, posee una sola neurona en la capa de salida, que corresponde a la cantidad de producción real de galletas de chocolate en presentación de 21\*700 g.

## **B.5. Función de activación.**

La función de activación establece un dato de salida a partir de un valor de entrada, generalmente el grupo de valores de salida está en un rango establecido como (0,1) o (-1,1). Se trabaja con funciones cuyas derivadas sean simples, de forma tal que se minimice el coste computacional.

Se usará una función de activación no lineal; dado que está permite un acotamiento de los datos de salida.

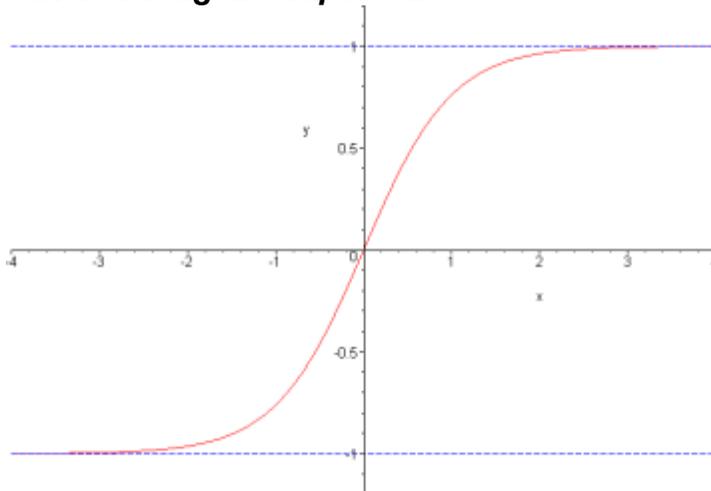
### **B.6. Función de activación en la capa oculta**

Se observa en este estudio en la tabla 8 la función de activación empleada en la capa oculta pertenece a la tangente hiperbólica.

La función tangente hiperbólica es aplicada para transformar los valores de la capa de entrada a un grado de  $(-1,1)$ , las cifras mayores tienden de manera asintótica a 1 y las cifras menores tienden de manera asintótica a -1.

**Figura 4**

#### **Función Tangente Hiperbólica**



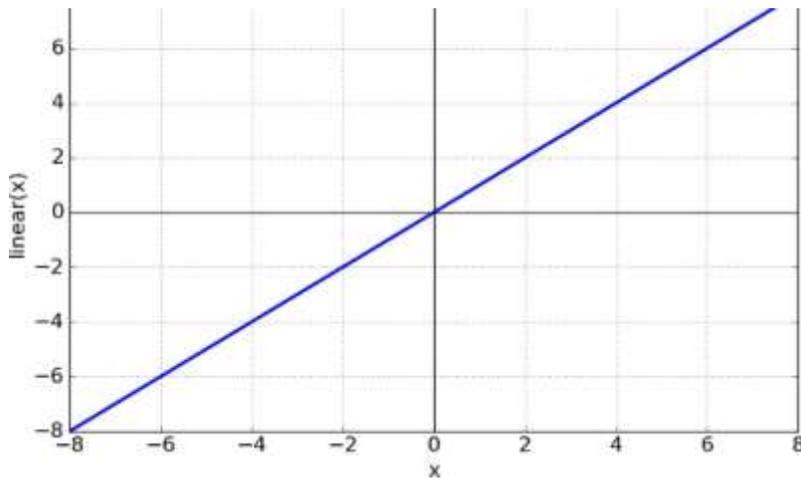
### **B.7. Función de activación en la capa de salida**

Para el presente trabajo como se muestra en la tabla 8 la función de activación que se usó en la capa de salida fue la identidad.

La función de identidad, nos indica que la variable dependiente tiene un nexo directo y conveniente con la variable independiente.

**Figura 5**

**Función lineal o Identidad**



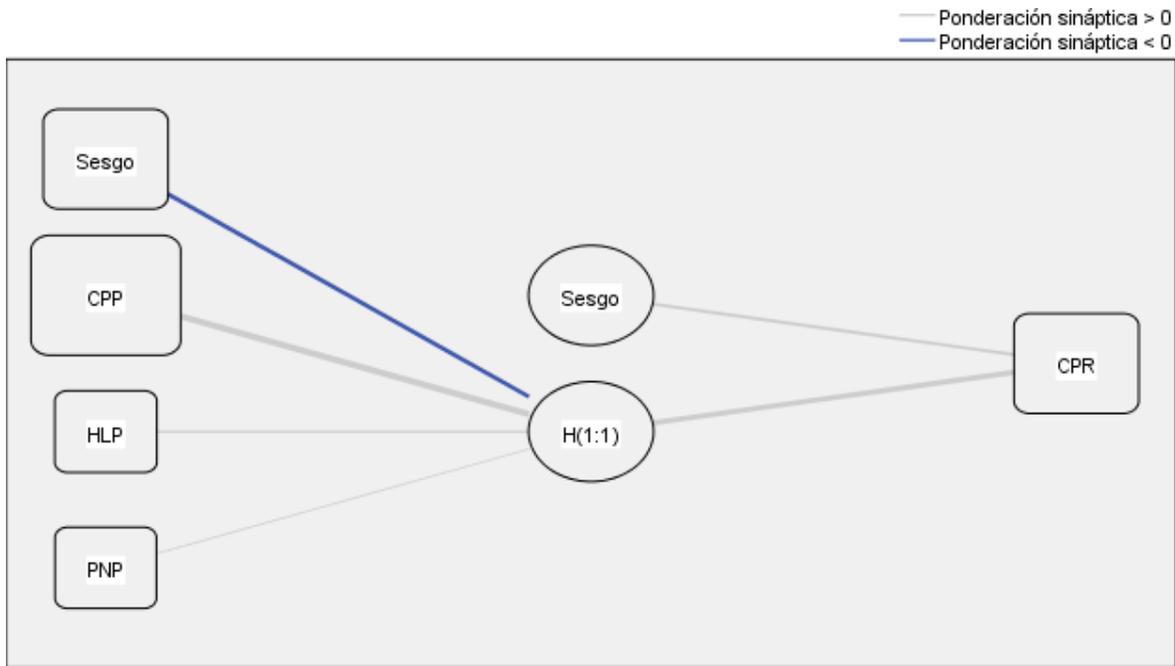
Fuente: elaborado por el autor.

**4.6 Topología de la Red**

La topología de la red neuronal artificial es la ordenación y colocación de las neuronas constituyendo capas. Las medidas principales de la red son: número de capas, cantidad de neuronas por capa, valor de conectividad y tipo de enlace entre neuronas.

**Figura 6**

**Topología de la red**



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de salida: Identidad

Fuente: elaborado por el autor.

La gráfica 6 muestra el diagrama o topología de la red neuronal utilizada,

- Indica que la función de activación en la capa oculta es la tangente hiperbólica.
- La función de activación lineal, en la capa de salida con una neurona.
- 3 neuronas corresponden a una capa de entrada
- Red multicapa, tipo de conexión feedforward (conexión hacia adelante), tipo de aprendizaje supervisado.

#### 4.7 Criterios de Evaluación

Esta perspectiva dirigida para calcular la validez de la red, es la suma de cuadrado de los errores o residuos SCE, este tipo de función de error lo que hace es calcular la suma de los errores al cuadrado de la función de predicción.

Otro criterio utilizado es el error relativo, este se evalúa fraccionando el error absoluto entre el valor exacto.

Al observar en la tabla 8, en la etapa de entrenamiento de la red: la suma de cuadrado de los errores es de 5,021; y en la etapa de pruebas de la red la suma de cuadrado de los errores es de 1,509. Como se puede mostrar la tabla 8, en la etapa de entrenamiento de la red el error relativo es de 0,197; en la en la etapa de pruebas de la red el error relativo es de 0,181. Siendo, además, en la etapa de reserva de la red el error relativo de 0,143.

#### **4.8 Entrenamiento de la Red Neuronal**

##### **Tipo de entrenamiento.**

El entrenamiento por Lote es aprovechado dado que la cantidad de datos es relativamente pequeña, se utiliza este porque minimiza directamente el error total; además actualiza las ponderaciones de los pesos sinápticos para transferir toda la información de cifras de entrenamiento; por lo tanto, se puede decir que, el entrenamiento por lotes usa las investigaciones del grupo de cifras de entrenamiento.

##### **Algoritmo de optimización.**

Esta técnica es usada para establecer las ponderaciones de los pesos sinápticos. En este estudio se manejó el Gradiente conjugado escalado; las hipótesis que justifican el uso de esta técnica se emplean exclusivamente a los tipos de entrenamiento por lotes.

#### **4.9 Pesos sinápticos.**

La ponderación o pesos sinápticos esquematizan la intensidad de conexión entre cada neurona presináptica y la neurona postsináptica, es decir presenta estimaciones de coeficiente de un modelo de correlación entre las unidades de

una capa establecida con las unidades de la capa siguiente. Esta aprobación se basa en la muestra de entrenamiento incluso si el grupo de datos activo se clasifica en datos de entrenamiento, comprobación y reservados.

**Tabla 9**

**Estimaciones de Parámetro**

Predictor		Pronosticado	
		Capa oculta 1	Capa de salida
		H (1:1)	CPR
Capa de entrada	(Sesgo)	-0,080	
	CPP	1,398	
	HLP	0,047	
	PNP	0,019	
Capa oculta 1	(Sesgo)		0,051
	H (1:1)		1,058

Fuente: elaborado por el autor

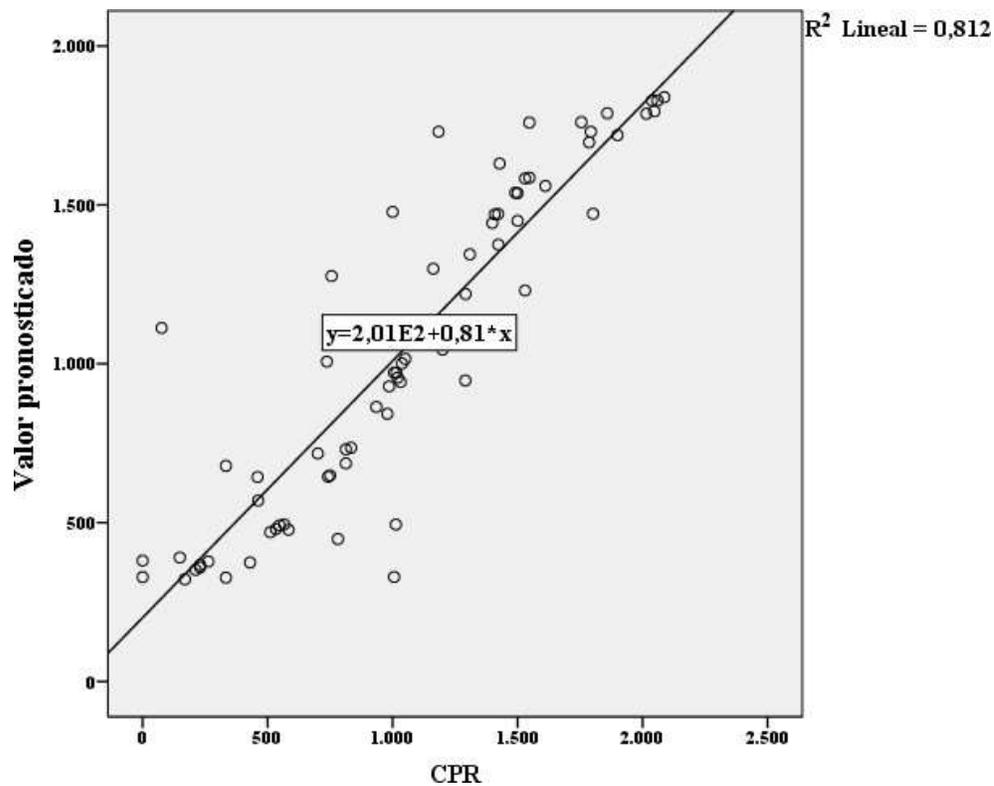
En la tabla 9 se estudia el resumen de los valores de los distintos pesos sinápticos, el valor de sesgo de la capa de entrada a cada una de las neuronas de la capa oculta, el valor de los pesos sinápticos entre las neuronas ambas capas; el sesgo de la capa oculta a la capa de salida, el peso sináptico de cada una de las neuronas de la capa oculta a la capa de salida.

**4.10 Gráfico de pronosticados por observados**

Para objetivos continuos, evidenciamos un gráfico de dispersión entre los valores observados y los valores pronosticados en el eje horizontal.

**Figura 7**

**Pronosticados por observados**



Fuente: elaborado por el autor.

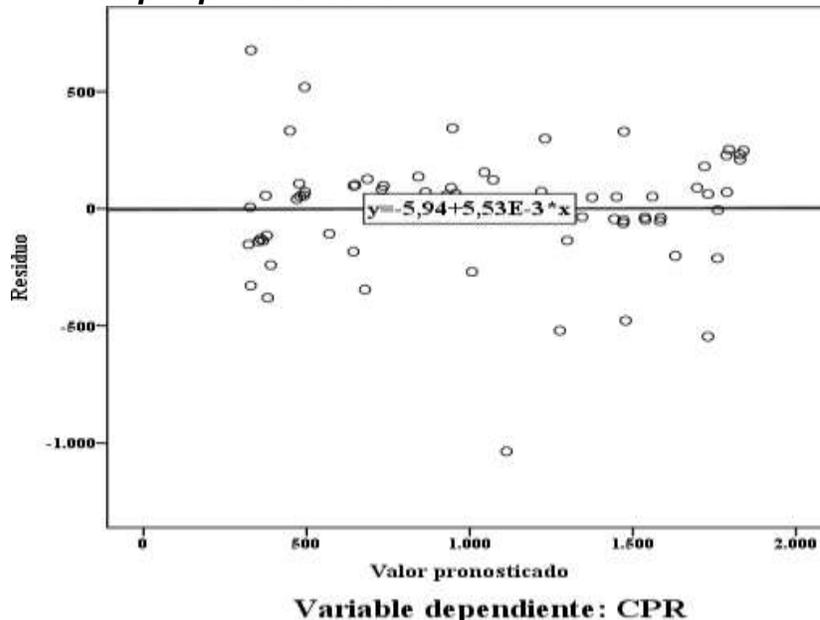
En la figura 7 se puede apreciar, la correlación que coexiste entre la Cantidad de Producción Real CPR en el eje horizontal y los valores pronosticados por la red neuronal artificial en el eje vertical; la precisión o ajuste de la red se demuestran mientras los puntos estén más aglomerados o sobre la recta, al contrario, mientras los puntos están dispersos o alejados de la recta menor será la precisión o el ajuste de la red neuronal, el coeficiente de correlación es bastante elevado ( $R^2=0,812$ ) y muy cercano a 1, lo cual indica que existe una muy alta correlación entre los valores reales y los pronósticos.

#### 4.11 Gráfico de residuos por pronosticado

Se utiliza el esquema de residuos por pronósticos para comprobar la Hipótesis que señala la aleatoriedad de los residuos que poseen una varianza persistente. Por lo tanto, se espera la distribución aleatoria y sin patrón conocido alrededor de cero.

**Figura 8**

#### **Residuos por pronosticado**



Fuente: elaborado por el autor.

En la figura 8, muestra el grafico de residuos por pronosticado, se comprueba que los puntos residuos están distribuidos razonablemente bien por lo que se puede decir que no existe relación sistemática entre los residuos y los valores pronosticados de la cantidad de producto a producir.

#### 4.12 Importancia del predictor

Es estándar concentrar la energía de modelado en las variables independientes o campos predictores más importantes, con la finalidad de valorar la omisión de aquellos con menor relevancia o que aporten muy poco a la red.

La gráfica de importancia de las variables independientes o predictores ayuda a identificar nuestro enfoque sobre la ligera importancia de cada uno de los predictores en la estimación del modelo. Siendo las cifras de los predictores relativos, la adición de los valores de los predictores representada es de 1.0. La relevancia del predictor no se relaciona con la precisión del modelo. Es coherente con la calidad de cada predictor a la hora de realizar un pronóstico, siendo o no precisa la predicción.

**Tabla 10**

***Importancia de las variables independientes***

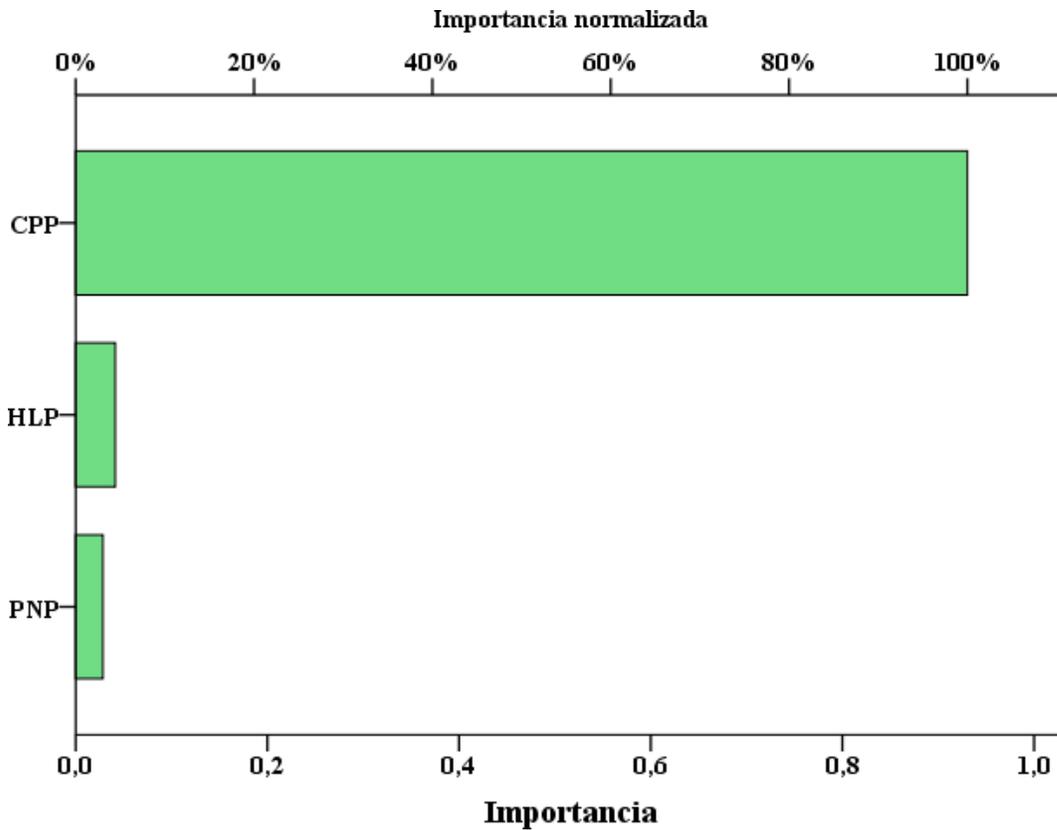
	Importancia	Importancia normalizada
CPP	0,930	100,0%
HLP	0,041	4,4%
PNP	0,028	3,0%

Fuente: elaborada por el autor.

La tabla 11 muestra de forma numérica, el valor de las variables independientes en el modelo de red neuronal artificial.

**Figura 9**

**Gráfico de importancia de variable independiente**



Fuente: elaborado por el autor.

La figura 9 muestra de forma gráfica la relevancia de las variables independientes en el tipo de red neuronal artificial.

Juntas muestran en tabla 10 y figura 9, que la variable independiente que más aporta al modelo es la cantidad de producción programada.

En segundo y tercer lugar de importancia están horas laborales planificadas y paradas no programadas respectivamente.

Las paradas no programadas tienen el menor aporte al modelo de la red neuronal, lo que nos influye en eliminarlas del modelo, pero se consideró incluirlas ya que en

las micro empresa debe ser importante un programa de mantenimiento preventivo que ayude a eliminar o reducir las paras no programadas.

#### 4.13 Validación de la red con conjunto de prueba

La evaluación de la red neuronal se logra comparando los datos reales: la cantidad de producción real CPR con los datos arrojados por la red neuronal: cantidad de producción real dado por la red CPR\_RNA.

**Tabla 11**

#### ***Cantidad de Producción real CPR y Cantidad de Producción Real dado por la red neuronal CPR\_RNA***

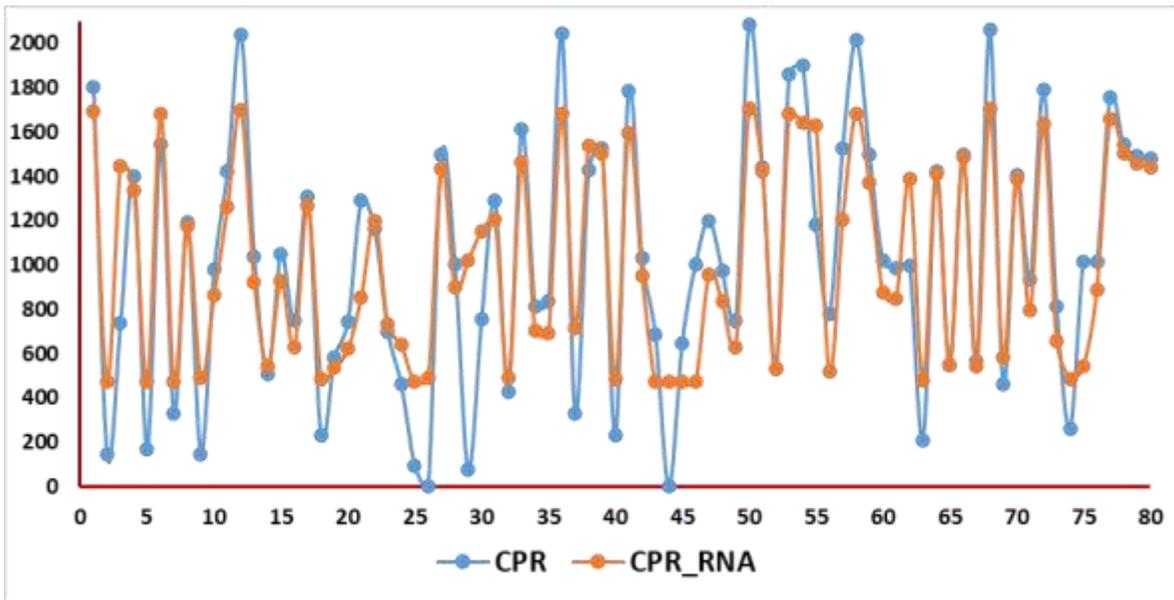
Item	CPR	CPR_RNA	Item	CPR	CPR_RNA	Item	CPR	CPR_RNA
1	1802	1695,17	21	1291	855,92	41	1786	1595,54
2	146	473,23	22	1163	1197,23	42	1032	950,74
3	737	1449,37	23	701	733,02	43	685	472,94
4	1399	1335,08	24	460	638,45	44	0	472,5
5	169	473,13	25	97	472,7	45	646	472,53
6	1547	1682,31	26	0	490,21	46	1006	472,9
7	333	471,97	27	1497	1434,94	47	1200	956,5
8	1195	1176,99	28	1006	899,32	48	976	834,42
9	149	493,82	29	76	1021,12	49	749	632,31
10	979	864,81	30	756	1154,33	50	2087	1707,21
11	1423	1261,96	31	1292	1203,51	51	1441	1424,3
12	2038	1702,14	32	430	489,65	52	533	534
13	1038	922,86	33	1611	1461,68	53	1859	1680,29
14	511	545,14	34	813	703,53	54	1900	1639,6
15	1051	927,94	35	834	694,27	55	1184	1632,89
16	750	629,52	36	2047	1681,73	56	781	520,63
17	1309	1268,96	37	333	716,55	57	1530	1205,1
18	230	486,75	38	1428	1540,21	58	2015	1681,07
19	584	537,71	39	1530	1503,09	59	1500	1370,62

20	742	623,23	40	230	487,75	60	1020	879,15
----	-----	--------	----	-----	--------	----	------	--------

En la tabla 12 se muestran 60 datos para la Cantidad de Producción real CPR y Cantidad de Producción Real dado por la red neuronal CPR\_RNA. Al escoger un dato al azar el ítem 20 muestra que Cantidad de Producción real CPR es de 742 y siendo la Cantidad de Producción Real facilitado por red neuronal CPR\_RNA de 623,23 observamos una buena proximidad del modelo para pronosticar la producción de una empresa.

**Figura 10**

**Comparación entre CPR\_RNA - CPR**



Fuente: Elaborado por el autor.

Al mostrar la figura 10, se analiza la semejanza entre los datos existentes de la planta de producción es decir Capacidad de Producción Real CPR, con los datos alcanzados utilizando el modelo matemático diseñado por medio de la retrocesión multivariado CPR\_RNA.

Observamos que el modelo matemático alcanza un muy buen acercamiento a los datos reales, concluyendo que el modelo propuesto sirve para predecir.

## CONCLUSIONES

Establecimos cuales componentes influyen en el proceso de producción de galleta de chocolate de presentación 21\*700 g. Para nuestro caso de estudio fueron las variables de entrada: cantidad de producción planificada CPP, horas laborales planificada HLP, paradas no programadas PNP; la variable de salida: cantidad de producción real.

Se realizó un análisis acerca de la importancia de las variables independientes que incide en la producción de galleta de chocolate de presentación 21\*700 g. En el modelo de la red neuronal obtenido, esto se muestra en la tabla 11 y figura 9 “Importancia de las variables independientes”, donde se puede observar que la variable de mayor incidencia es la cantidad de producción planificada CPP.

Se elabora el modelo a través de la red neuronal artificial para la predicción de la producción, para ello se debe tener en cuenta los valores de los pesos o estimaciones de parámetros mostrados en la Tabla 10 “Estimaciones de parámetro”, teniendo en cuenta la topología de la red explicada en la Tabla 8, “Información de red”.

Mediante la tabla 12 y la figura 10 “Comparación entre CPR\_RNA – CPR” se puede concluir que la red neuronal artificial es un muy buen aproximador para la predicción del pronóstico de producción de la microempresa, como se observa en la figura 7 “Pronósticos por observados”, las redes neuronales artificiales permiten predecir la producción con una relación significativa  $R^2$  de 0,812.

## **RECOMENDACIONES**

Se recomienda la implementación de la red neuronal artificial obtenida, con el objetivo de que sirva de insumo, para que pueda predecir la cantidad de producción de producto que se debe de realizar en el período determinado; con base a los diversos aspectos que inciden en el proceso de producción.

Se recomienda profundizar la investigación para definir nuevas variables independientes y aumentar el conjunto de datos históricos, de forma tal que la red neuronal artificial sea capaz de aprender.

## BIBLIOGRAFÍA

- ARAVENA, M., CAAMANO, C., & GIMENEZ, J. (2008). Modelos matemáticos a través de proyectos. *Revista latinoamericana de investigación en matemática educativa*, 11(1), 49-92. Obtenido de <http://www.scielo.org.mx/pdf/relime/v11n1/v11n1a3.pdf>
- Banco Central del Ecuador. (2017). *Cuentas Nacionales*. Quito: Banco Central del Ecuador.
- Benites Sernaqué, J. (2021). *Implementación de un sistema de pronósticos de ventas utilizando redes neuronales artificiales para la empresa cerámicos LAMBAYEQUE SAC*. Pimentel: Universidad Señor de Sipán. Obtenido de <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/8449/Benites%20Sernaqu%c3%a9%20Jos%c3%a9%20Manuel.pdf?sequence=1&isAllowed=y>
- Berkowitz, D. E. (1998). INDUSTRIA ALIMENTARIA. En *ENCICLOPEDIA DE SALUD Y SEGURIDAD EN EL TRABAJO* (págs. 67 - 67.35). Madrid: Chantal Dufresne, BA. Obtenido de <https://www.insst.es/documents/94886/161971/Cap%C3%ADtulo+67.+Industria+alimentaria>
- Bocco, M. (2010). *Funciones elementales para construir modelos matemáticos* (Primera ed.). Buenos Aires: Instituto Nacional de Educación Tecnológica. Obtenido de <http://www.bnm.me.gov.ar/giga1/documentos/EL001843.pdf>
- Cabrera González, G., & De León Arias, A. (2019). Modelación markoviana para identificar la dinámica y pronóstico del índice de producción industrial en México de 1980 a 2018. *EconoQuantum*, 16(2), 23 - 41. Obtenido de <http://econoquantum.cucea.udg.mx/index.php/EQ/article/view/7120/6215>
- Damián Llatas, M. R., & Sandoval Santamaría, N. J. (2018). *Modelo óptimo de Pronóstico del índice mensual de Producción de Electricidad"-Perú en el Periodo 2006 – 2015*. Facultad de Ciencias Físicas y Matemáticas. Lambayeque: Universidad Nacional Pedro Ruiz Gallo. Obtenido de <http://repositorio.unprg.edu.pe/handle/UNPRG/2192>
- De Torres Curth, M. (2015). *Los reyes de la pasarela, modelos matemáticos en las ciencias* (Primera ed.). Buenos Aires: Fundación de Historia Natural Félix de Azara. Obtenido de <https://www.fundacionazara.org.ar/img/libros/modelos-matematicos.pdf>
- FAO. (07 de Octubre de 2021). *FAO. (Situación Alimentaria Mundial)* Recuperado el 08 de Octubre de 2021, de <http://www.fao.org/worldfoodsituation/csdb/es/>
- FAO y CEPAL. (2020). *Sistemas alimentarios y COVID-19 en América Latina y el Caribe*. Santiago de Chile: FAO. doi:<https://doi.org/10.4060/ca8677es>
- Freeman Castro, J. A., & Skapura González, D. M. (1993). *Redes neuronales; algoritmos, aplicaciones y técnicas de programación*. España: Addison-Wesley. Obtenido de <https://dialnet.unirioja.es/servlet/libro?codigo=372546>

- Gil Zavaleta, E., & Rodríguez Collas, E. (2010). *Sistema de pronóstico de la demanda de productos farmacéuticos basado en redes neuronales*. Lima: Universidad Nacional Mayor de San Marcos. Obtenido de <https://core.ac.uk/download/pdf/323350618.pdf>
- Kaastra, L., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236. doi:[https://doi.org/10.1016/0925-2312\(95\)00039-9](https://doi.org/10.1016/0925-2312(95)00039-9)
- López Rodríguez, S. M., & Zapata Zuluaga, T. (2018). *Técnicas de pronósticos en revisión sistémica de literatura para empresas de confecciones*. Bogotá: Universidad Cooperativa de Colombia. Obtenido de <http://repository.ucc.edu.co/handle/ucc/12151>
- Malaver Elera, M. (2015). *Aplicación de redes neuronales para determinar el pronóstico de las ventas en la empresa CATERING & BUFFETS MyS ubicada en la ciudad de Piura*. Piura: Universidad César Vallejo. Obtenido de [https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/164/malaver\\_em.pdf?sequence=1](https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/164/malaver_em.pdf?sequence=1)
- Martí Perez, P. (2009). *Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego: evapotranspiración de referencia y pérdidas de carga localizadas en emisores integrados*. Valencia: Universidad Politécnica de Valencia. Obtenido de <https://riunet.upv.es/bitstream/handle/10251/64909/-MART%C3%8D%20-%20Aplicaci%C3%B3n%20de%20redes%20neuronales%20artificiales%20para%20predicci%C3%B3n%20de%20variables%20en%20ingenier%C3%ADa%20de...pdf?sequence=1>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Tecnológica Nacional. Obtenido de [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monografias/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/matich-redesneuronales.pdf)
- Méndez Giraldu, G. A., & Lopez Santana, E. R. (2014). Metodología para el pronóstico de la demanda en ambientes multiproducto y de alta variabilidad. *Tecnura: Tecnología y Cultura Afirmando el Conocimiento*, 18(40), 89-102. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=4778508>
- Montes Albarracin, A. I. (2016). *Uso de redes neuronales artificiales para el pronóstico de demanda de hielo industrial en Hielos Santa Lucía S.R.L.* Tacna: Escuela Profesional de Ingeniería en Informática y Sistemas.
- Montesinos-López, O. A., & Hernández-Suárez, C. M. (2007). Modelos matemáticos para enfermedades infecciosas. *Salud Pública de México*, 49(3), 218-226. Obtenido de <http://www.scielo.org.mx/pdf/spm/v49n3/07.pdf>
- Moreno Castro, T. F. (2019). *El pronóstico de ventas en los negocios: Modelos y Aplicaciones*. Santiago de Chile: RIL editores. Obtenido de [https://repositorio.uautonoma.cl/bitstream/handle/20.500.12728/3192/Pronostico\\_de\\_ventas.pdf?sequence=1&isAllowed=y](https://repositorio.uautonoma.cl/bitstream/handle/20.500.12728/3192/Pronostico_de_ventas.pdf?sequence=1&isAllowed=y)

- Nations, O. a. (2020). *OCDE-FAO Perspectivas Agrícolas*. OCDE-FAO.  
doi:<https://doi.org/10.1787/a0848ac0-es>
- Ramos, A., Sánchez, P., Ferrer, J. M., Barquín, J., & Linares, P. (2010). *Modelos matemáticos de optimización*. Madrid: Universidad Pontificia Comillas. Obtenido de [https://d1wqtxts1xzle7.cloudfront.net/34357606/modelado\\_en\\_gams-with-cover-page-v2.pdf?Expires=1633687201&Signature=EzhFiG-skxPtDHclAwclQ08Qgji~w3TqbHmhGJKqaRfyW1SAIdlZH5DDJXiHRLC8v2Tdb-zncNZYV4WfKu0LVXNlkmLiT6NoocHcf21rjOhupk0biXvhHdDbsWtw~Me7oBaSZ0g4ocy](https://d1wqtxts1xzle7.cloudfront.net/34357606/modelado_en_gams-with-cover-page-v2.pdf?Expires=1633687201&Signature=EzhFiG-skxPtDHclAwclQ08Qgji~w3TqbHmhGJKqaRfyW1SAIdlZH5DDJXiHRLC8v2Tdb-zncNZYV4WfKu0LVXNlkmLiT6NoocHcf21rjOhupk0biXvhHdDbsWtw~Me7oBaSZ0g4ocy)
- Render, B., & Heizer, J. (2007). *Administración de la producción*. México: PEARSON EDUCACIÓN.
- Rivas Asanza, W., & Mazón Olivo, B. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones* (Primera ed.). Machala: Ediciones UTMACH. Obtenido de <http://repositorio.utmachala.edu.ec/bitstream/48000/14223/1/Cap.1-Generalidades%20de%20las%20redes%20neuronales%20artificiales.pdf>
- Rubio Guerrero, G. (2017). Perspectiva multivariante de los pronósticos en las PYMES industriales de Ibagué (Colombia). *Revista Facultad de Ciencias Económicas: Investigación y Reflexión*, 25(2), 25-40. Obtenido de <https://www.redalyc.org/pdf/909/90952679003.pdf>
- Salett Biembengut, M., & Hein, N. (1999). Modelación matemática: Estrategia para enseñar y aprenderr matemáticas. *Educación Matemática*, 11(1), 119-134. Obtenido de <http://www.revista-educacion-matematica.org.mx/descargas/Vol11/1/10Salett.pdf>
- Sánchez Sánchez, D. A. (2018). *Modelo ARIMA para el pronóstico de la producción de cacao en el Prú 2012 - 2018*. Facultad de Ciencias Físicas y Matemáticas. Trujillo: Universidad Nacional de Trujillo.  
doi:<http://190.223.54.254/bitstream/handle/UNITRU/11563/SÁNCHEZ%20SÁNCHEZ%2c%20David%20Alexander.pdf?sequence=1&isAllowed=y>
- Superintendencia de Compañías, Valores y Seguros. (2018). *Panorama de las MIPYMES y Grandes Empresas en el Ecuador 2013-2017*. Quito: Superintendencia de Compañías, Valores y Seguros.
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 23(4), 11 - 20. Obtenido de [https://scielo.conicyt.cl/scielo.php?script=sci\\_arttext&pid=S0718-07642012000400003](https://scielo.conicyt.cl/scielo.php?script=sci_arttext&pid=S0718-07642012000400003)
- Villada, F., Muñoz, N., & García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información tecnológica*, 27(5).  
doi:<http://dx.doi.org/10.4067/S0718-07642016000500016>
- Zafra Mejía, C. A., & Gutiérrez Gil, V. H. (2015). Análisis de la producción de lixiviado y biogás bajo condiciones de extracción activa. *Ingenium Revista De La Facultad De ingeniería,,* 16(31), 9-23. doi:<https://doi.org/10.21500/01247492.1365>
- Zapata Laureano, J. (2019). *Aplicación de las redes neuronales para determinar los pronósticos mensuales de la inflación para el año 2018*. Piura: Universidad Nacional de Piura. Obtenido

de <https://repositorio.unp.edu.pe/bitstream/handle/UNP/2014/EST-ZAP-LAU-2019.pdf?sequence=1&isAllowed=y>

# **ANEXOS**

**Valores extraídos de una Fábrica de Chocolate, ubicada en la ciudad de Guayaquil.**

item	Ctd. prod. Plan CPP	Horas laborables reales HLR	paradas no programadas estimadas en horas PNP	Ctd. prod. Real CPR	item	CPR	CPR_RNA
1	2.043	77,60	27,136	1.802	1	1802	1695,17
2	0	20,37	3,976	146	2	146	473,23
3	1.371	58,37	14,416	737	3	737	1449,37
4	1.397	3,65	0,089	1.399	4	1399	1335,08
5	0	21,02	3,041	169	5	169	473,13
6	2.021	39,80	5,677	1.547	6	1547	1682,31
7	0	4,55	0,428	333	7	333	471,97
8	1.191	42,50	4,768	1.195	8	1195	1176,99
9	325	8,25	0,128	149	9	149	493,82
10	974	31,80	2,654	979	10	979	864,81
11	1.335	3,70	0,066	1.423	11	1423	1261,96
12	2.418	23,93	0,055	2.038	12	2038	1702,14
13	1.028	34,77	0,060	1.038	13	1038	922,86
14	505	50,58	0,875	511	14	511	545,14
15	1.046	25,42	0,098	1.051	15	1051	927,94
16	750	12,52	0,054	750	16	750	629,52
17	1.305	26,17	0,532	1.309	17	1309	1268,96
18	235	19,95	1,658	230	18	230	486,75
19	512	32,03	0,105	584	19	584	537,71
20	750	5,65	0,040	742	20	742	623,23
21	1.003	14,32	0,073	1.291	21	1291	855,92
22	1.262	18,17	0,070	1.163	22	1163	1197,23
23	848	33,38	1,895	701	23	701	733,02
24	739	28,65	0,284	460	24	460	638,45
25	0	18,13	1,037	97	25	97	472,7
26	289	11,30	0,080	0	26	0	490,21
27	1.497	2,37	0,001	1.497	27	1497	1434,94
28	1.006	36,60	0,088	1.006	28	1006	899,32
29	1.119	24,70	0,164	76	29	76	1021,12
30	1.254	1,87	0,013	756	30	756	1154,33
31	1.254	20,75	2,311	1.292	31	1292	1203,51
32	253	31,62	0,105	430	32	430	489,65
33	1.515	10,50	0,012	1.611	33	1611	1461,68
34	812	39,42	0,124	813	34	813	703,53
35	830	19,95	0,122	834	35	834	694,27
36	2.066	20,65	0,309	2.047	36	2047	1681,73

37	801	51,93	2,006	333	37	333	716,55
38	1.623	8,58	0,462	1.428	38	1428	1540,21
39	1.530	34,95	0,122	1.530	39	1530	1503,09
40	224	37,68	0,368	230	40	230	487,75
41	1.734	5,62	0,007	1.786	41	1786	1595,54
42	1.026	45,58	2,023	1.032	42	1032	950,74
43	0	25,23	0,063	685	43	685	472,94
44	0	16,75	0,044	0	44	0	472,5
45	0	16,23	0,477	646	45	646	472,53
46	0	24,60	0,064	1.006	46	1006	472,9
47	1.063	29,30	0,032	1.200	47	1200	956,5
48	970	23,82	0,012	976	48	976	834,42
49	746	18,28	0,015	749	49	749	632,31
50	2.874	50,95	0,049	2.087	50	2087	1707,21
51	1.436	35,18	0,037	1.441	51	1441	1424,3
52	528	13,03	0,034	533	52	533	534
53	2.015	45,77	0,426	1.859	53	1859	1680,29
54	1.790	47,67	1,325	1.900	54	1900	1639,6
55	1.800	28,97	0,088	1.184	55	1184	1632,89
56	466	19,15	0,101	781	56	781	520,63
57	1.231	38,87	1,549	1.530	57	1530	1205,1
58	2.014	49,95	0,802	2.015	58	2015	1681,07
59	1.380	36,65	0,064	1.500	59	1500	1370,62
60	1.006	25,10	0,223	1.020	60	1020	879,15
61	981	24,07	0,018	986	61	986	847,28
62	1.417	24,50	0,109	1.000	62	1000	1390,21
63	205	6,80	1,629	212	63	212	482,57
64	1.418	35,40	0,717	1.422	64	1422	1409,98
65	565	14,25	0,784	548	65	548	546,75
66	1.499	37,82	1,232	1.500	66	1500	1486,2
67	560	14,17	0,362	566	67	566	544,53
68	2.404	50,37	0,124	2.060	68	2060	1702,75
69	662	11,37	0,098	462	69	462	581,81
70	1.402	34,45	0,085	1.409	70	1409	1390,1
71	935	22,93	0,128	935	71	935	795,62
72	1.792	43,88	0,152	1.793	72	1793	1637,22
73	783	19,90	0,070	813	73	813	658,62
74	282	6,45	0,036	263	74	263	488,7
75	545	24,80	0,093	1.013	75	1013	544,51
76	1.014	24,83	0,078	1.015	76	1015	887,52
77	1.888	43,02	0,213	1.755	77	1755	1660,01
78	1.530	37,82	0,085	1.547	78	1547	1506,14
79	1.473	36,43	0,067	1.491	79	1491	1459,35
80	1.455	36,10	0,027	1.479	80	1479	1443,01

min	0	471,97
max	2087	1707,21

**Herramienta estadística.**

