

**UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN**

**Facultad de Ingeniería**

Escuela Profesional de Ingeniería Química

**MODELAMIENTO DE UN SECADOR ROTATORIO  
DIRECTO CONTINUO CON AIRE CALIENTE  
PARA LA PLANTA PESQUERA COPEINCA  
S.A.C. SEDE ILO USANDO LAS  
REDES NEURALES  
ARTIFICIALES**

**TESIS**

Presentada por:

Bach. César Abel Flores Tuso

Para optar el Título Profesional de:

**INGENIERO QUÍMICO**

Tacna – Perú

2022

# UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN

## Facultad de Ingeniería

Escuela Profesional de Ingeniería Química

### MODELAMIENTO DE UN SECADOR ROTATORIO DIRECTO CONTINUO CON AIRE CALIENTE PARA LA PLANTA PESQUERA COPEINCA S.A.C. SEDE ILO USANDO LAS REDES NEURALES ARTIFICIALES

Tesis sustentada y aprobada el 25 de Marzo del 2022; estando el jurado calificador integrado por:

PRESIDENTE : .....  
Mag. Manuel de Jesús Sánchez Rosales

SECRETARIO : .....  
Mtro. Pedro Nolazco Cornejo del Carpio.

VOCAL : .....  
Mtro. Hubert Orlando Oporto Siles

ASESOR : .....  
Dr. Edgardo Oscar Avendaño Cáceres

## **DEDICATORIA**

A mis padres y hermanos que estuvieron siempre apoyándome y animándome para completar este proyecto, y así demostrarles que su sacrificio desde pequeño por mis estudios tuvo éxito.

## **AGRADECIMIENTO**

En primer lugar, quiero agradecer a Dios, quien me da la vida y salud para lograr mis metas. A Dariela, quien me motivó a luchar y alcanzar mis sueños.

## CONTENIDO

DEDICATORIA .....	iii
AGRADECIMIENTO .....	iv
RESUMEN .....	x
ABSTRACT .....	xi
INTRODUCCIÓN .....	1
<b>CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA .....</b>	<b>2</b>
1.1. DESCRIPCIÓN DEL PROBLEMA .....	2
1.1.1. Antecedentes del problema .....	2
1.1.2. Problemática de la investigación .....	5
1.2. FORMULACIÓN DEL PROBLEMA .....	6
1.3. JUSTIFICACIÓN E IMPORTANCIA .....	6
1.4. ALCANCES Y LIMITACIONES .....	7
1.5. OBJETIVOS .....	7
1.5.1. Objetivo general .....	7
1.5.2. Objetivos específicos .....	8
1.6. HIPÓTESIS .....	8
<b>CAPÍTULO II: MARCO TEÓRICO .....</b>	<b>9</b>
2.1. ANTECEDENTES DEL ESTUDIO .....	9
2.2. BASES TEÓRICAS .....	10
2.2.1. Secador Planta Pesquera COPEINCA S.A.C. sede Ilo .....	10
2.2.2. Operación de secado en la industria pesquera .....	10
2.2.3. Secador HLT .....	11
2.2.4. Modelo Híbrido Neural o modelo de caja gris .....	12

2.2.5.	Redes Neuronales Artificiales (RNAs)	12
2.2.6.	Modelos de RNA	15
2.2.7.	Perceptrón	15
2.2.8.	Aprendizaje o entrenamiento	15
2.2.9.	Tipos de entrada	16
2.2.10.	Validación	17
2.2.11.	Aplicaciones de las RNAs	17
2.3.	DEFINICIÓN DE TÉRMINOS	18
<b>CAPÍTULO III: MARCO METODOLÓGICO</b>		20
3.1.	TIPO Y DISEÑO DE LA INVESTIGACIÓN	20
3.2.	POBLACIÓN Y MUESTRA	20
3.2.1.	Población	20
3.2.2.	Muestra	20
3.3.	OPERACIONALIZACIÓN DE VARIABLES	20
3.4.	TÉCNICAS E INSTRUMENTOS PARA RECOLECCIÓN DE DATOS	23
3.5.	PROCESAMIENTO Y ANÁLISIS DE DATOS	23
3.5.1.	Balance de materia y energía para el secador rotatorio	23
3.5.2.	Parámetros	27
3.5.3.	Ecuaciones fenomenológicas	27
<b>CAPÍTULO IV: RESULTADOS Y DISCUSIÓN</b>		36
4.1.	RESULTADOS	36
4.1.1.	Set de ecuaciones de conservación de materia y energía	36
4.1.2.	Modelo de proceso de secado usando Microsoft Excel	36

4.1.3. Parámetros .....	40
4.1.4. Validación de resultados .....	42
4.2. DISCUSIÓN .....	45
CONCLUSIONES .....	48
RECOMENDACIONES .....	49
REFERENCIAS BIBLIOGRÁFICAS .....	50
ANEXOS .....	57

## ÍNDICE DE TABLAS

Tabla 1. Operacionalización de variables	21
Tabla 2. Pesos o bias de las RNA para la variable $X$	41
Tabla 3. Pesos o bias de las RNA para la variable $T_g$	41
Tabla 4. Constantes físicas finales	41
Tabla 5. Parámetros objetivo	42
Tabla 6. Validación de resultados con errores ECM, EPM y EAM	44
Tabla 7. Comparación con otras investigaciones	44

## ÍNDICE DE FIGURAS

Figura 1.	Diagrama simplificado del secador y quemador en el proceso de secado	12
Figura 2.	Tipos de neuronas artificiales	13
Figura 3.	Modelo genérico de neurona artificial	14
Figura 4.	Diagrama de secador rotatorio	24
Figura 5.	Diagrama Redes Neuronales	30
Figura 6.	Predicción de la RNA para la variable $X$	37
Figura 7.	Predicción de la RNA para la variable $T_g$	38
Figura 8.	Predicción mediante ecuaciones fenomenológicas para la variable $X$	39
Figura 9.	Predicción mediante ecuaciones fenomenológicas para la variable $T_g$	40
Figura 10.	Modelo Híbrido Neural para la variable $X$	42
Figura 11.	Modelo Híbrido Neural para la variable $T_g$	43

## RESUMEN

El presente trabajo de investigación tiene por objetivo mejorar el proceso de secado de una planta pesquera de harina de pescado. Esto es porque se ha observado que el proceso tradicional industrial de secado puede aumentar su eficacia adaptándose a los nuevos procesos tecnológicos. Para ello se propone un modelo de predicción para que un futuro pueda ser usado en sistemas de automatización y control. El modelo que se propone consiste en predecir los datos de salida con respecto a las variables de humedad de la harina de pescado y la temperatura del aire del secador rotatorio, con el propósito de adelantarnos al resultado de la muestra futura y así tomar las correcciones debidas en los equipos a operar. El método innovador a usarse será el método híbrido neural, el cual consiste en la combinación de las redes neuronales artificiales con las ecuaciones fenomenológicas obtenidas a base de balances de materia y energía. Para facilitar el desarrollo del modelo se realizará en una hoja de cálculo de Microsoft Excel. Se trabajó con datos reales de planta muestreados en los años 2013 y 2014 obtenidos con autorización de la planta pesquera COPEINCA S.A.C. sede Ilo. Algunos datos y constantes físicas del proceso de secado fueron obtenidos a través de bibliografía. Los parámetros a calcular son la velocidad de secado ( $N_s$ ) y el coeficiente volumétrico de transferencia de calor ( $U_a$ ) haciendo uso de las redes neuronales artificiales. Luego la estimación manual mediante las ecuaciones fenomenológicas usando los parámetros  $N_s$  y  $U_a$  ya calculados.

**Palabras clave:** secador rotatorio, redes neuronales artificiales, ecuaciones fenomenológicas, Microsoft Excel.

## ABSTRACT

The present research aims to improve the drying process of a fishmeal fishing plant. This is because it has been observed that the traditional industrial drying process can increase its efficiency by adapting to new technological processes. For this, a prediction model is proposed so that a future can be used in automation and control systems. The proposed model consists of predicting the output data with respect to the moisture variables of the fishmeal and the air temperature of the rotary dryer, to anticipate the result of the future sample and thus take the appropriate corrections in the equipment to operate. The innovative method to be used will be the neural hybrid method, which consists of the combination of artificial neural networks with phenomenological equations obtained from mass and energy balances. To facilitate the development of the model, it will be done in a Microsoft Excel spreadsheet. We worked with real plant data sampled in 2013 and 2014 obtained with authorization from the COPEINCA S.A.C. Ilo. Some data and physical constants of the drying process were obtained through bibliography. The parameters to be calculated are the drying speed parameters ( $N_s$ ) and the volumetric heat transfer coefficient ( $U_a$ ) using artificial neural networks. Then the manual estimation through the phenomenological equations using the parameters  $N_s$  and  $U_a$  already calculated.

**Keywords:** rotary dryer, artificial neural networks, phenomenological equations, Microsoft Excel.

## INTRODUCCIÓN

La presente investigación se desarrolló en medio de la problemática industrial en el Perú con respecto a la calidad de harina de pescado y su gran dependencia de la humedad como factor determinante del precio final.

El proceso de secado de harina de pescado es de suma importancia dentro de la industria pesquera, especialmente en el Perú sabiendo que es el principal productor de harina de pescado del mundo, seguido de Tailandia, China, Chile y Estados Unidos, según el Anuario Estadístico de IFFO (Organización Mundial de Ingredientes Marinos). Por ello, las empresas de harina de pescado trabajan con distintos equipos de secado o secadores, entre los más usuales son los secadores rotatorios los cuales usan aire caliente para el proceso.

Las industrias pesqueras del Perú van implementando poco a poco las nuevas tecnologías en equipos industriales de proceso, mientras tanto los resultados obtenidos en planta conllevan mejoras por hacer.

Ante esta situación, la presente investigación está determinada en aportar una mejora en el proceso de secado de harina de pescado, proponiendo un modelo predictivo de la humedad del sólido y temperatura del aire del secador usando la metodología de las redes neuronales artificiales combinada con ecuaciones fenomenológicas de transferencia de materia y calor. Para ello es necesario obtener un grupo de datos históricos reales del proceso para que el método pueda aprender y mejorar su precisión en su predicción. Los datos fueron obtenidos gracias a la planta pesquera COPEINCA S.A.C. sede Ilo. Esto será de utilidad para obtener el modelo predictivo, que será capaz de dar valores futuros, los cuales serán usados para operar anticipadamente el equipo de secado obteniendo así un valor de humedad y temperatura adecuados.

# **CAPÍTULO I**

## **PLANTEAMIENTO DEL PROBLEMA**

### **1.1. DESCRIPCIÓN DEL PROBLEMA**

#### **1.1.1. Antecedentes del problema**

Se han realizado numerosos estudios con respecto a los secadores rotatorios para la industria alimentaria; de estos son pocos para la industria de harina de pescado, y menos aún específicamente en cuanto a secadores rotatorios por aire caliente HLT. Entre estos, existen también estudios de modelamiento, simulación, optimización y control de dicho secador con distintos métodos matemáticos.

En Chile, en la Universidad de Santiago de Chile se realizó un trabajo en donde se desarrolla el modelamiento híbrido neural para la humedad del scrap y la temperatura de salida del aire, tanto para un secador rotatorio como para un secador de lecho fluidizado batch. Se utilizaron datos históricos de una planta de harina de pescado para el caso del secador rotatorio, en ambos casos se obtuvieron resultados realmente satisfactorios (Cubillos y col., 1995).

Otro desarrollo de tesis fue el realizado en Piura, Perú en la Universidad de Piura sobre la modelación, simulación y control PID de un secador rotadisco en la industria pesquera, el proyecto muestra el modelo matemático de un secador rotadisco basado en las leyes de conservación de masa y energía, este modelo se valida con datos reales obtenidos de plantas pesqueras peruanas (Vallejos, 2013).

En Chile, en la Universidad de Andrés Bello se desarrolló una propuesta metodológica para la creación, entrenamiento y simulación de modelos neuronales de caja gris utilizando Matlab, para este trabajo se realizó la simulación de la reacción exotérmica en un reactor CSTR, en donde los resultados finales fueron muy satisfactorios (Cruz y col., 2011).

Se desarrolló otro trabajo de modelo neural de caja gris en la Universidad de Santiago de Chile con los mismos autores del antecedente anterior, se trata del uso del modelo neural de caja gris para el control predictivo de un reactor de polimerización de flujo pistón. Concluyen en que las formulaciones estudiadas son adecuadas para el control de sistemas no lineales variables en el tiempo, como los procesos de polimerización, donde la alta interferencia y variaciones en los parámetros justifican el uso de este tipo de control (Cubillos y col., 2001).

También existe un trabajo basado en redes neuronales artificiales (RNA) en el proceso de secado del tabaco, en el cual se calculan los parámetros ambientales, además informan que se utilizó este método para predecir datos de temperatura y humedad relativa dentro del secador de tabaco. El modelo propuesto fue validado con datos de temperatura y humedad relativa obtenidos de un secador real. Los resultados se mostraron con gran satisfacción con errores pequeños utilizando este tipo de modelos (Martínez y col., 2013).

Se trabajó en Colombia, en la Universidad Tecnológica de Pereira el diseño y simulación de la automatización de un secador electromecánico de café, en el cual se trabajó con un secador rotatorio. Los componentes fueron integrados en un CAE (Ingeniería Asistida por Ordenador) para la simulación de la operación del secador (Echeverry, 2010).

Se realizó una tesis en Lima, Perú en la Universidad Nacional de Ingeniería sobre la optimización de un secador rotatubos de 40 tm/h para la industrialización pesquera, esta tesis habla de un diseño para un aumento de la capacidad de materia prima para satisfacer la demanda del sector pesquero nacional, además de que se innoven los componentes del sistema de suministro de vapor y recuperación de condensado (Aceijas, 2011).

También tenemos la investigación realizada en Irán en la Universidad de Irán de Ciencia y Tecnología (IUST) sobre la simulación dinámica de un secador industrial rotatorio, en esta investigación se trabajó con un secador rotatorio industrial de gránulo. En cada experimento una de las variables de movimiento sólido se modificó y midió el cambio dinámico resultante en el proceso. Los datos se utilizaron para estimar los parámetros de un modelo dinámico de parámetros distribuidos del sistema utilizando el método de optimización dinámica (Shahhosseini y col., 2010). En la misma Universidad IUST de Irán se trabajó en el modelamiento matemático y simulación computarizada de secadores rotatorios continuos, en el trabajo se toma en cuenta la variación de las propiedades de la partícula a lo largo del secador y las partículas son consideradas del mismo tamaño y forma. Para la solución numérica de las ecuaciones gobernantes se usa el método de Runge-Kutta de 4° orden, además de trabajarse en el software Visual C++ (Kasiri y col., 2004).

Una investigación realizada en el control basado en optimización de un secador rotatorio directo en la Universidad Andrés Bello de Chile presenta el control basado en optimización no lineal. La metodología usada permite autosintonizar dinámicamente un controlador PI o PID, mejorando el control del proceso. Este control es realizado por medio de simulación en

computadoras a través del software Matlab y su corroboración por medio de un proceso piloto (Valdés-González y col., 2011).

En la Universidad James Cook de Australia se trabajó en el transporte de sólidos en secadores rotatorios de azúcar, este trabajo presenta un modelo dinámico de transporte de sólidos, el modelo se desarrolla asumiendo unos tanques en serie y en paralelo, similar a los sistemas de ingeniería de reacción química. Este enfoque permite la predicción de la fase del aire y de la retención del azúcar en el secador, y la distribución de tiempo de residencia dentro del secador. Las correlaciones sirven para la sobrecarga de los secadores y el impacto del flujo de aire (Lee y col., 2004).

### **1.1.2. Problemática de la investigación**

Puesto que el secado se realiza a través de procesos de transferencia de calor, haciendo posible que a ciertas temperaturas pueda ocurrir degradación de materia orgánica; esto incide directamente sobre la calidad de la harina de pescado. Además, se ha observado variación en los datos de humedad y temperatura de harina a la salida del secador, lo cual ocasiona el reproceso (que es la acción de volver a procesar el producto no conforme, es decir, que no cumpla con los parámetros establecidos) de la harina con exceso de humedad el cual ocasiona pérdida de energía. Ello ocurre puesto que este proceso no cuenta con automatización ni instrumentación para poder corregir los problemas durante la producción. Por lo que requiere un modelo para poder simular el secador rotatorio con aire caliente, y el uso de ésta para su posterior control y optimización del mismo.

Ante este problema se propone aplicar un método innovador de predicción, el modelo híbrido neural, que no es otra cosa que el uso de las leyes de conservación fundamentales asociadas con una red neuronal artificial (RNA) la cual es utilizada para modelar los parámetros inciertos. Este modelo obtenido será aplicado para el equipo de secado con el fin de predecir la humedad de la harina de pescado y la temperatura del aire ubicados a la salida del secador usando balances de materia y energía, así como los fundamentos de las redes neuronales respectivamente.

## **1.2. FORMULACIÓN DEL PROBLEMA**

¿Se podrá implementar el modelo neural como una herramienta de predicción de un secador rotatorio con aire caliente para harina de pescado para la planta pesquera COPEINCA S.A.C. sede Ilo teniendo en cuenta las ecuaciones de conservación de materia y energía, así como el fundamento de las redes neuronales artificiales?

## **1.3. JUSTIFICACIÓN E IMPORTANCIA**

En el proceso de secado de harina de pescado uno de los mayores factores que influyen en la calidad de la harina es la humedad. El producto húmedo constituye un medio ideal para el crecimiento de microorganismos que deterioran al producto y su aspecto, incluso en humedades bajas se origina el deterioro de las proteínas, las cuales junto con la humedad determinan la calidad de la harina de pescado y por tanto su valor económico. La presente tesis propondrá y evaluará un modelo para la predicción del proceso de secado de harina de pescado, específicamente para el secador rotatorio con aire caliente de forma que se pueda prevenir los problemas que ocasionan la incertidumbre de saber la humedad de la

harina de pescado en dicho proceso; además de poder introducir un nuevo e innovador modelo de predicción al sector de secado de harina de pescado como es el uso del modelo neural en Perú, donde el modelo presenta confianza tras haber tenido excelentes resultados en distintos equipos industriales además de usarse también en otros campos como indiscutible método de predicción, dicho modelo es usado con datos que varían constantemente cuyo comportamiento es de difícil predicción, por lo que se ajustaría adecuadamente a nuestro problema. Existe la posibilidad de elaborar un modelo híbrido neural para el secador haciendo uso de los distintos fenómenos de transporte que gobiernan el proceso.

#### **1.4. ALCANCES Y LIMITACIONES**

Las limitaciones que se pueden presentar son la recolección de los datos históricos del equipo de planta ubicados en la ciudad de Ilo, además de conseguir el permiso y/o autorización respectiva.

#### **1.5. OBJETIVOS**

##### **1.5.1. Objetivo general**

Modelar el proceso de secado en un secador rotatorio con aire caliente para el proceso productivo de harina de pescado, aprovechando la versatilidad de las redes neuronales artificiales.

### **1.5.2. Objetivos específicos**

- a) Proponer el set de ecuaciones de conservación de materia y energía correctas para su posterior adecuación al método híbrido neural.
  
- b) Elaborar el modelo del proceso de secado con el secador rotatorio con aire caliente, utilizando como herramienta el software Microsoft Excel.
  
- c) Validar los resultados predichos con datos reales de producción en planta.

### **1.6. HIPÓTESIS**

El método de redes neuronales artificiales con las ecuaciones fundamentales de conservación de materia y energía puede usarse como una innovadora herramienta para el modelamiento de un secador rotatorio con aire caliente para la planta pesquera COPEINCA S.A.C. sede Ilo.

## **CAPÍTULO II**

### **MARCO TEÓRICO**

#### **2.1. ANTECEDENTES DEL ESTUDIO**

En España, en la Universidad de Sevilla, se desarrolló un proyecto cuyo objetivo fue de proporcionar los pasos para la utilización del software Microsoft Excel para implementar una RNA que nos permita ajustar los parámetros en una serie de tiempo y que permita al alumno entender su funcionamiento (García y col., 2001).

Otra investigación es la que se realizó en Cuba, en la planta de cemento Cienfuegos S.A., en donde se trabaja el tema de modelo neural de caja gris para el secador rotatorio, es decir se utiliza el conocimiento de los balances de momento, masa y energía que se tiene del proceso industrial, además de los datos de entrada y salida, esto permite validar la metodología propuesta a través de un proceso real (Fernández y col., 2011).

En Finlandia, en la Universidad de Oulu se estudió el control avanzado de un secador rotatorio, donde indican que el secador rotatorio presenta un tiempo de retraso bastante grande, lo que significa que las variaciones accidentales en las variables de entrada pueden perturbar el proceso durante largos períodos de tiempo antes de que se reflejen en las variables de salida. Para eliminar estas perturbaciones en una etapa anterior, se ha puesto más interés en los sistemas de control más sofisticados, como las construcciones basadas en modelos, lógica difusa y redes neuronales en los últimos años. Aunque ha resultado difícil y requiere mucho tiempo para desarrollar sistemas de control basados en modelos,

debido a la complejidad del proceso, los métodos de control inteligente basado en la lógica difusa y redes neuronales ofrecen soluciones atractivas para mejorar el control del secador. Estos métodos hacen posible utilizar la experiencia, el conocimiento y los datos históricos (Yliniemi, 1999).

Se desarrolló otro trabajo en el Instituto Tecnológico de Veracruz en México acerca del control y simulación del proceso de secado sobre un secador rotatorio utilizando un modelo híbrido neuro – diferencial, en donde se concluyó que tal modelo puede representar las no linealidades de un proceso de secado sobre secador rotatorio, además de ser utilizado para probar diferentes estrategias de control por simulación (Estrada y col., 2001).

## **2.2. BASES TEÓRICAS**

### **2.2.1. Secador Planta Pesquera COPEINCA S.A.C. sede Ilo**

Esta planta pesquera cuenta con un secador HLT con aire caliente que funciona en paralelo con respecto al flujo del aire con el flujo de la harina húmeda.

### **2.2.2. Operación de secado en la industria pesquera**

El objetivo de la operación de secado en la industria pesquera es deshidratar el material húmedo como la torta de prensa, torta de separadoras y el concentrado de agua de cola, es decir, reducir la humedad del material no acuoso a niveles mínimos en que no se permita el crecimiento de microorganismos. Este nivel debe ser lo suficientemente bajo para detener reacciones consecuentes y degraden el producto, además de permitir el almacenamiento de la harina por periodos largos a

condiciones ambientales, disminuyendo las pérdidas de sus propiedades nutricionales (Aceijas, 2011).

La exposición del producto a temperaturas altas influye directamente en la calidad nutricional de la harina (Aceijas, 2011).

Las temperaturas de secado son parámetros fundamentales de controlar, especialmente porque tienen efecto en las vitaminas, proteínas y grasas del producto, también en la digestibilidad de la lisina que es influenciada por el secado y la oxidación de la grasa (Aceijas, 2011).

### **2.2.3. Secador HLT**

El secador HLT es equipo de secado con aire por corriente en paralelo y con tambor rotativo. Se compone de dos sistemas de circulación separados, haciendo que no haya contacto entre el material a secar y los gases de combustión (Haarslev Industries, 2000).

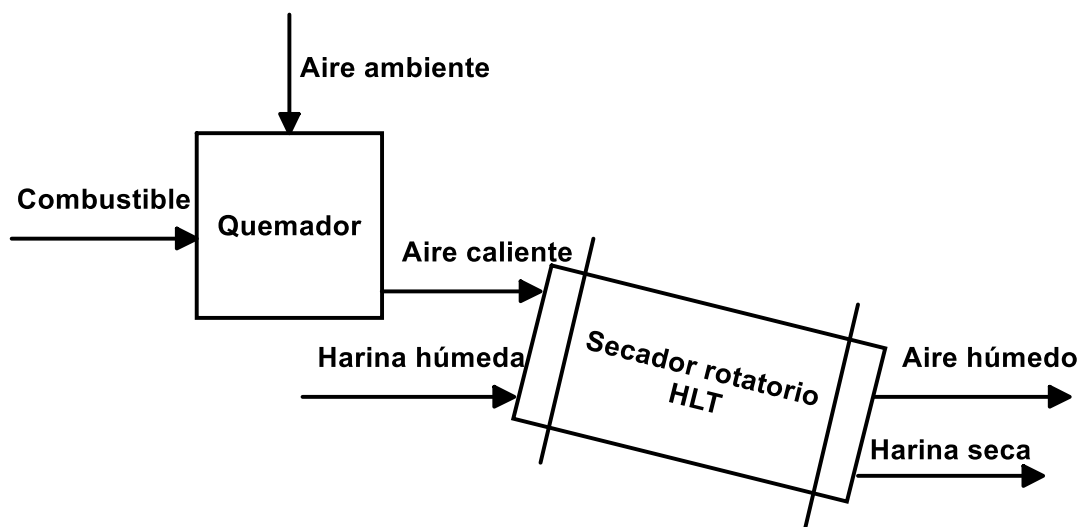
El sistema de aire consta de un almacén de descarga donde se almacena el producto, ciclones para la eliminación del polvo, un ventilador de secado y un depurador para la condensación de vapor de agua. El secador HLT funciona análogamente a bucles de secado, lo que permite la reducción de hedores (Haarslev Industries, 2000).

Este sistema de secado por lo general termina de secar la harina correspondiente a los secadores de vapor indirectamente como los secadores rotatubos y rotadisk (Haarslev Industries, 2000).

Un diagrama del sistema de secado HLT podemos ver en la figura 1.

**Figura 1**

*Diagrama simplificado del secador y quemador en el proceso de secado*



#### **2.2.4. Modelo Neural o modelo de caja gris**

Los modelos de caja gris son los métodos que combinan ecuaciones diferenciales y redes neuronales. Los modelos neuronales de caja gris son utilizados para sistemas donde se conocen algunas leyes físicas, sin embargo, algunos parámetros deben determinarse a partir de datos experimentales (Cruz & Acuña, 2011).

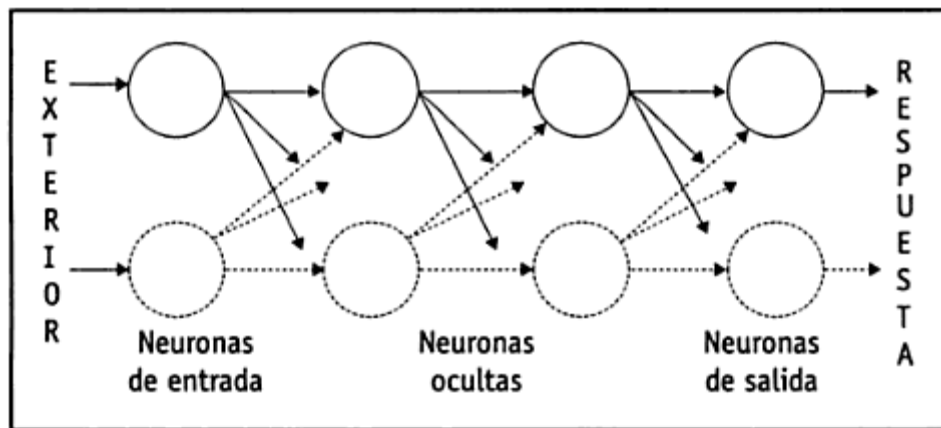
#### **2.2.5. Redes Neuronales Artificiales (RNAs)**

Las RNAs están constituidas por una serie de procesadores elementales denominados neuronas artificiales, éstas forman partículas elementales de cálculo que a partir de un vector procedente de datos externos (entrada) y de estímulos recibidos de otras neuronas,

proporcionan una única respuesta (salida). Podemos resumir en tres partes las que componen las neuronas artificiales: unidades de entrada, de salida y unidades ocultas (Figura 2) (Flórez & Fernández, 2008).

## Figura 2

*Tipos de neuronas artificiales (Flórez & Fernández, 2008)*



En síntesis, se aplica un conjunto de entradas a la neurona, las cuales tienen respectivamente su conjunto de salida.

Cada dato de entrada es multiplicado por su "bais", también llamado "peso", que es la ponderación correspondiente al grado de conexión de la sinapsis.

Las entradas ponderadas se suman, luego se establece el nivel de activación de la neurona. El funcionamiento básico de una neurona artificial puede ser representado vectorialmente según la siguiente expresión [1].


$$Y = \mathbf{X} \times \mathbf{W} \quad [1]$$

donde  $\mathbf{X}$  sería el vector de entradas,  $\mathbf{W}$  el vector de pesos y  $\mathbf{Y}$  el resultado o salida (Basogain, 2002).

Gráficamente, una neurona artificial presenta las siguientes características:

**Figura 3**

*Modelo genérico de neurona artificial (Flórez & Fernández, 2008)*



A diferencia de los algoritmos que son instrucciones previamente programadas, las RNA son previamente entrenadas. Esto implica que se introducen datos en la capa de entrada que las RNA ajustan en función de alguna regla de aprendizaje (Wikipedia: Red Neuronal Artificial, 2015).

El conjunto de datos de entrada debe ser significativo, de esta manera se conseguirá que la red aprenda automáticamente a manejar el sistema deseado. En este sentido, el diseño tendrá que seleccionar el modelo de red, las variables a incorporar y el pre-procesamiento de la

información que formará el conjunto de datos de entrenamiento. Este proceso en el cual los parámetros de la RNA se ajustan a la resolución de cada caso se denomina entrenamiento neuronal (Wikipedia: Red Neuronal Artificial, 2015).

#### **2.2.6. Modelos de RNA**

Existe una serie de modelos de redes neuronales, entre ellos tenemos: Perceptrón Simple, Adaline, Perceptrón Multicapa, Máquina de Boltzmann, Memorias Asociativas, etc. (Wikipedia: Red Neuronal Artificial, 2015).

#### **2.2.7. Perceptrón**

El perceptrón es el modelo neuronal más básico asemejado biológicamente a una neurona, que a su vez es el modelo matemático más simple (ver figura 3). La neurona es una célula caracterizada por poseer una cantidad indefinida de datos de entrada llamados dendritas y uno de salida llamado axón. Las dendritas operan de modo similar que los sensores que van recogiendo información de la región en donde se hallan y la derivan hacia el núcleo de la neurona que se activa mediante una sinapsis la cual envía una respuesta hacia el cerebro, esto en el caso de los seres vivos (Wikipedia: Perceptrón, 2014).

#### **2.2.8. Aprendizaje o entrenamiento**

Las RNA son características por su capacidad de aprendizaje a partir de ciertos datos. Una vez se haya elegido la arquitectura de red para un determinado caso, los pesos de las conexiones se deben ajustar para

convertir la información almacenada en datos de entrenamiento. El aprendizaje de las RNA se clasifica en dos categorías conforme a los datos a trabajar (Alegre, 2003).

**Aprendizaje supervisado:** se necesita un conjunto de datos de entrada previamente clasificados. Algunas redes pertenecientes a este tipo de entrenamiento son: el perceptrón simple, el perceptrón multicapa, red backpropagation, la red Adaline, y la memoria asociativa bidireccional (Laqui, 2010).

**Aprendizaje no supervisado:** no necesitan un conjunto de datos previamente clasificados. Algunas redes pertenecientes a este tipo de entrenamiento son: las memorias asociativas, la máquina de Boltzmann y la máquina de Cauchy, las redes de Kohonen o mapas autoorganizados, las redes de Hopfield, las redes de aprendizaje competitivo y las redes de resonancia adaptativa (Laqui, 2010).

### 2.2.9. Tipos de entrada

**Redes analógicas:** procesan datos de entrada con valores continuos. Algunas redes pertenecientes a este tipo de entradas son: Kohonen, Hopfield y las redes de aprendizaje competitivo (Wikipedia: Red Neuronal Artificial, 2015).

**Redes discretas:** procesan datos de entrada de naturaleza discreta; a menudo valores lógicos binarios. Algunas redes pertenecientes a este tipo de entradas son: la red discreta de Hopfield, las máquinas de Boltzmann y Cauchy (Wikipedia: Red Neuronal Artificial, 2015).

### 2.2.10. Validación

Luego de culminado el proceso de aprendizaje y determinado los pesos de la red neuronal, es necesario probar la calidad del modelo resultante. Así, en caso del aprendizaje supervisado, puede darse en términos del error entre los obtenidos por la red neuronal y los datos de salida deseados. Algunas medidas estándar del error son:

El **Error Cuadrático Medio (ECM)**, definido como:

$$ECM = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad [2]$$

El **Error Porcentual Medio (EPM)**, definido como:

$$EPM = \frac{100}{n} \sum_{i=1}^n \frac{(y_i - \bar{y}_i)^2}{y_i} \quad [3]$$

El **Error Absoluto Medio (EAM)**, definido como:

$$EAM = \frac{100}{n} \sum_{i=1}^n (y_i - \bar{y}_i) \quad [4]$$

donde  $n$  es el número de elementos que intervienen en la predicción,  $y_i$  es el valor real y,  $\bar{y}_i$  es la salida predicha (Laqui, 2010).

### 2.2.11. Aplicaciones de las RNAs

En general, el modelo neural de caja gris se usa en procesos de ingeniería, trabaja en los modelos de procesos basados en principios fundamentales asociados con una RNA para estimar los parámetros variables, inciertos y dificultosos del mismo modelo del proceso (Cubillos y col., 1995).

En tanto que las RNA son parecidas a las neuronas del cerebro humano, permiten resolver problemas afines como son el reconocimiento de patrones y la predicción a través del tiempo. Una ventaja de las RNA es la capacidad de no ser afectada por la fatiga, estado emocional, condiciones de trabajo, etc. A continuación, se mencionan cuatro aplicaciones tecnológicas de las RNA:

- Reconocimiento de escritos
- Reconocimiento de voz
- Predicciones de datos probables futuros
- Detección de explosivos

### **2.3. DEFINICIÓN DE TÉRMINOS**

#### **Algoritmo**

Son un conjunto de instrucciones o reglas definidas, que permite solucionar un problema, procesar datos o realizar una programación (RAE, 2021).

#### **Balance de materia y energía**

Son una secuencia de cálculos que permiten llevar la cuenta de las sustancias y ganancias o pérdidas de energía que intervienen en un proceso de transformación, satisfaciendo la ley de la conservación de masa y energía (Londoño, 2015).

#### **Datos históricos**

Es aquella información acumulada a través del tiempo que generalmente almacenan las empresas, plantas industriales, centros de monitoreo, etc.

### **Inteligencia artificial**

Es el estudio de cómo lograr que las computadoras realicen tareas que, por el momento, los humanos hacen mejor (Rich & Knight, 1994).

### **Secado**

Es la eliminación de humedad en un material como madera, tela o papel. El secado puede darse por evaporación de la humedad mediante el flujo de una corriente de gas; sin embargo, generalmente no se considera como secado la eliminación mecánica de esta humedad mediante el exprimido o centrifugado (Treybal, 1980).

### **Modelamiento**

Un sistema matemático o físico, que obedece a ciertas condiciones específicas, cuyo comportamiento se utiliza para comprender un sistema físico, biológico o social al que es análogo de alguna manera (Wayne, 1998).

### **Planta pesquera**

Son las empresas inmersas en la industria pesquera que en su mayoría tienen por objetivo producir harina y aceite de pescado, además de tratar conservas de mariscos.

### **Redes neuronales artificiales**

Son métodos computacionales que tienen como fin la simulación del sistema nervioso central biológico a través de procesadores artificiales, que permitan evitar los fallos o errores humanos (Flórez & Fernández, 2008).

## **CAPÍTULO III**

### **MARCO METODOLÓGICO**

#### **3.1. TIPO Y DISEÑO DE LA INVESTIGACIÓN**

El tipo de investigación es correlacional, y estará basado en datos históricos obtenidos del secador rotatorio por aire caliente durante la producción de dicha planta, para usarlos en el método de modelo neural de caja gris y obtener parámetros del modelo fenomenológico para cada set de datos históricos, con los cuales se calcularán la humedad de harina seca y temperatura del aire, ambos de salida del secador, además se elaborará el modelo será en una hoja de cálculo en computadora.

#### **3.2. POBLACIÓN Y MUESTRA**

##### **3.2.1. Población**

La población del presente trabajo de investigación constituye los datos históricos recopilados del secador rotatorio con aire caliente en época de producción de la pesquera COPEINCA S.A.C.

##### **3.2.2. Muestra**

Se trabajará con toda la población ya que se tienen los datos almacenados digitalmente.

#### **3.3. OPERACIONALIZACIÓN DE VARIABLES**

Se realiza una esquematización de las variables para romper el concepto difuso que ella engloba y así darle sentido concreto dentro de la investigación, luego en función de ello se procede a realizar la definición

operacional de la misma para identificar los indicadores que permitirán realizar su medición de forma cuantitativa.

La operacionalización de variables está descrita en la tabla 1 junto con la caracterización de las mismas.

**Tabla 1**

*Operacionalización de variables*

<b>Variable</b>	<b>Factor</b>	<b>Indicador</b>	<b>Unidad</b>	<b>Rango</b>
Independiente	Tiempo de proceso	Tiempo	s	0 – 43 200
	Temperatura del aire a la entrada del secador	Temperatura	°C	200 – 300
	Humedad de harina a la entrada del secador	Humedad base seca	kg agua/kg sólido seco	0,25 – 0,30
Dependiente	Velocidad de secado	Velocidad de transferencia	kg agua / kg s	A determinar
	Coeficiente de transferencia volumétrico de calor	Coeficiente de transferencia	J/s m <sup>3</sup> °C	A determinar
	Temperatura del aire a la salida del secador	Temperatura	°C	60 – 100
	Humedad de harina a la salida del secador	Humedad base seca	kg agua/kg sólido seco	0,05 – 0,10

Parámetros	Diámetro medio de partícula de harina de pescado	Longitud	m	A determinar
	Densidad media de partículas de harina de pescado	Densidad	kg/m <sup>3</sup>	A determinar
	Tiempo de retención	Tiempo	s	A determinar
	Flujo másico de harina a la entrada del secador	Flujo másico	kg harina húmeda/s	5,20
	Flujo másico de harina a la salida del secador	Flujo másico	kg harina húmeda/s	4,38
	Flujo másico de aire a la entrada del secador	Flujo másico	kg aire húmedo/s	10,97
	Flujo másico de aire a la salida del secador	Flujo másico	kg aire húmedo/s	10,97
	Temperatura del sólido a la entrada del secador	Temperatura	°C	90,0
	Humedad del aire a la entrada del secador	Humedad base seca	kg agua/kg aire seco	0,018

### **3.4. TÉCNICAS E INSTRUMENTOS PARA RECOLECCIÓN DE DATOS**

El presente trabajo de investigación está basado en datos históricos obtenidos del secador rotatorio por aire caliente durante la producción de dicha planta, para usarlos en el método de modelo neural de caja gris y obtener parámetros del modelo fenomenológico para cada set de datos históricos, con los cuales se calcularon la humedad de harina seca y temperatura del aire, ambos de salida del secador, además se elaboró la simulación en una hoja de cálculo en una computadora.

Los datos fueron recopilados de la pesquera COPEINCA – sede Ilo con previo permiso de la empresa. Se obtuvieron datos reales para el propósito de la investigación.

### **3.5. PROCESAMIENTO Y ANÁLISIS DE DATOS**

#### **3.5.1. Balance de materia y energía para el secador rotatorio**


Para obtener el modelo fenomenológico adecuado para el desarrollo del método de predicción planteado, recurrimos a los balances de materia y energía dinámicos con gradiente máximo para la humedad y la temperatura en ambas fases (sólido y gaseoso), para ello tenemos en cuenta las siguientes suposiciones:

- Secador adiabático
- Gradientes radiales y angulares despreciables
- Tiempo de residencia del sólido a través del secador constante
- Efectos de radiación, difusión y conducción despreciables
- Remanente del aire en el secador constante
- Propiedades físicas constantes

El proceso de secado es el siguiente:

**Figura 4**

*Diagrama de secador rotatorio*



**a) Balance de materia**

*(considerar el apartado **h** para identificar las variables y constantes)*

- Para humedad del sólido (base seca):

Tenemos en cuenta la ecuación de continuidad para la humedad en el sólido [B.11-2] (Bird, 2006):

$$\rho \left( \frac{\partial \omega_A}{\partial t} + v_r \frac{\partial \omega_A}{\partial r} + \frac{v_\theta}{r} \frac{\partial \omega_A}{\partial \theta} + v_z \frac{\partial \omega_A}{\partial z} \right) = \rho D_{AB} \left[ \frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial \omega_A}{\partial r} \right) + \frac{1}{r^2} \frac{\partial^2 \omega_A}{\partial \theta^2} + \frac{\partial^2 \omega_A}{\partial z^2} \right] + r_A$$

...[B.11-2]

Adequando variables para la humedad del sólido:

$$\rho \left( \frac{\partial X}{\partial t} + V_r \frac{\partial X}{\partial r} + \frac{V_\theta}{r} \frac{\partial X}{\partial \theta} + V_s \frac{\partial X}{\partial z} \right) = \rho D_{xy} \left[ \frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial X}{\partial r} \right) + \frac{1}{r^2} \frac{\partial^2 X}{\partial \theta^2} + \frac{\partial^2 X}{\partial z^2} \right] + r_A \quad [5]$$

Simplificamos la ecuación:

$$\rho \left( \frac{\partial X}{\partial t} + \cancel{V_r} \frac{\partial X}{\partial r} + \frac{V_\theta}{r} \cancel{\frac{\partial X}{\partial \theta}} + V_s \frac{\partial X}{\partial z} \right) = \rho D_{xy} \left[ \cancel{\frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial X}{\partial r} \right)} + \cancel{\frac{1}{r^2} \frac{\partial^2 X}{\partial \theta^2}} + \frac{\partial^2 X}{\partial z^2} \right] + r_A$$

$$\rho \left( \frac{\partial X}{\partial t} + V_s \frac{\partial X}{\partial z} \right) = 0 + r_A$$

$$\frac{\partial X}{\partial t} + V_s \frac{\partial X}{\partial z} = \frac{r_A}{\rho} = -N_s$$

$$\frac{\partial X}{\partial t} = -V_s \frac{\partial X}{\partial z} - N_s \quad [6]$$

El Anexo 7 para contiene el análisis dimensional respectivo.

## b) Balance de energía

(considerar el apartado **h** para identificar las variables y constantes)

Tenemos en cuenta la ecuación de continuidad [B.9-2] [Bird, 2006] con la transferencia de calor del aire al sólido:

$$\rho \hat{C}_p \left( \frac{\partial T}{\partial t} + v_r \frac{\partial T}{\partial r} + \frac{v_\theta}{r} \frac{\partial T}{\partial \theta} + v_z \frac{\partial T}{\partial z} \right) = k \left[ \frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial T}{\partial r} \right) + \frac{1}{r^2} \frac{\partial^2 T}{\partial \theta^2} + \frac{\partial^2 T}{\partial z^2} \right] + \mu \Phi_v$$

...[B.9-2]

Adequando la ecuación con nuestras variables a trabajar:

$$\rho C_s \left( \frac{\partial T_s}{\partial t} + V_r \frac{\partial T_s}{\partial r} + \frac{V_\theta}{r} \frac{\partial T_s}{\partial \theta} + V_s \frac{\partial T_s}{\partial z} \right) = k \left[ \frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial T_s}{\partial r} \right) + \frac{1}{r^2} \frac{\partial^2 T_s}{\partial \theta^2} + \frac{\partial^2 T_s}{\partial z^2} \right] + \mu \Phi_v$$

Aplicando las suposiciones hechas:

$$\rho C_s \left( \frac{\partial T_s}{\partial t} + \cancel{V_r} \frac{\partial T_s}{\partial r} + \frac{V_\theta}{r} \cancel{\frac{\partial T_s}{\partial \theta}} + V_s \frac{\partial T_s}{\partial z} \right) = k \left[ \frac{1}{r} \cancel{\frac{\partial}{\partial r} \left( r \frac{\partial T_s}{\partial r} \right)} + \frac{1}{r^2} \cancel{\frac{\partial^2 T_s}{\partial \theta^2}} + \frac{\partial^2 T_s}{\partial z^2} \right] + \cancel{\mu \Phi_v}$$

$$\rho C_s \frac{\partial T_s}{\partial t} = -V_s \rho C_s \frac{\partial T_s}{\partial z}$$

Incorporamos los términos de calor por conducción y calor en interfase:

$$\rho C_s \frac{\partial T_s}{\partial t} = -V_s \rho C_s \frac{\partial T_s}{\partial z} + U_a (T_g - T_s) - N_s \lambda \rho$$

$$C_s \frac{\partial T_s}{\partial t} = \frac{U_a}{\rho} (T_g - T_s) - V_s C_s \frac{\partial T_s}{\partial z} - N_s \lambda$$

$$C_s \frac{\partial T_s}{\partial t} = \hat{U}_a V (T_g - T_s) - V_s C_s \frac{\partial T_s}{\partial z} - N_s \lambda$$

$$C_s \frac{\partial T_s}{\partial t} = U_a A \frac{V_s}{L_s} (T_g - T_s) - V_s C_s \frac{\partial T_s}{\partial z} - N_s \lambda$$

Multiplicamos a todo por  $L_s / V_s$ :

$$C_s \frac{L_s}{V_s} \frac{\partial T_s}{\partial t} = U_a A (T_g - T_s) - C_s L_s \frac{\partial T_s}{\partial z} - N_s \lambda \frac{L_s}{V_s}$$

Realizamos los cambios para el estado gaseoso (aire):

$$C_g \frac{G_s}{V_g} \frac{\partial T_g}{\partial t} = -U_a A (T_g - T_s) - C_g G_s \frac{\partial T_g}{\partial z} + \frac{L_s}{V_s} N_s \lambda \quad [7]$$

Podemos revisar el Anexo 7 para corroborar el análisis dimensional.

### 3.5.2. Parámetros

Estableceremos 2 parámetros específicos  $N_s$  y  $U_a$ , para calcularlos haciendo uso de las redes neuronales, luego de haber hallado sus valores las usaremos para reemplazar en las ecuaciones fenomenológicas y así obtener los valores predictivos de humedad del sólido y temperatura del gas (aire).

### 3.5.3. Ecuaciones fenomenológicas

Para establecer las ecuaciones fenomenológicas debemos resolver las ecuaciones diferenciales [6] y [7]:

#### a) Ecuación para humedad del sólido

Partimos de la ecuación [6]:

$$\frac{\partial X}{\partial t} = -V_s \frac{\partial X}{\partial z} - N_s$$

Reemplazamos  $\partial X / \partial z$  por la concentración de  $X$  desde la entrada a la salida conforme a la figura 4:

$$\frac{\partial X}{\partial t} = -V_s \frac{X - X_c}{L} - N_s$$

$$\frac{\partial X}{\partial t} = \frac{X_c - X}{\phi} - N_s \quad \rightarrow \quad \frac{L}{V_s} = \phi$$

$$\frac{\partial X}{\partial t} = \frac{X_c - X - \phi N_s}{\phi}$$

Integramos teniendo en cuenta que cada hora la humedad variará de  $X_k$  a  $X_{k+1}$ :

$$\int_{X_k}^{X_{k+1}} \frac{dX}{X_c - X - \phi N_s} = \frac{1}{\phi} \int_0^{3600} dt$$

$$-\left[\ln(X_c - X_{k+1} - \phi N_s) - \ln(X_c - X_k - \phi N_s)\right] = \frac{1}{\phi}(3600 - 0)$$

Sustituyendo valores y aplicando artificios matemáticos obtenemos (ver Anexo 6 para seguir el desarrollo completo y Anexo 7 para el análisis dimensional):

$$X_{k+1} = \frac{(e^6 - 1)(X_c - 600N_s)}{e^6} + \frac{1}{e^6} X_k \quad [8]$$

### b) Ecuación para temperatura del gas

Partimos de la ecuación [7]:

$$C_g \frac{G_s}{V_g} \frac{\partial T_g}{\partial t} = -U_a A (T_g - T_s) - C_g G_s \frac{\partial T_g}{\partial z} + \frac{L_s}{V_s} N_s \lambda$$

Despejamos  $\partial T_g / \partial t$  y reemplazamos  $\partial T_g / \partial z$  por su equivalente:

$$\frac{\partial T_g}{\partial t} = -\frac{U_a A V_g}{G_s C_g} (T_g - T_s) - V_g \frac{T_g - T_c}{z} + \frac{L_s}{V_s} \frac{V_g}{G_s C_g} N_s \lambda$$

Para integrar la ecuación es necesario hacer cambios de variables **a**, **b** y **c**:

$$\frac{\partial T_g}{\partial t} = -\frac{AV_g}{G_s C_g} U_a (T_g - T_s) - \frac{V_g}{z} (T_g - T_c) + \frac{L_s}{V_s} \frac{V_g}{G_s C_g} \lambda N_s$$

$\underbrace{\hspace{10em}}_a$ 
 $\underbrace{\hspace{10em}}_b$ 
 $\underbrace{\hspace{10em}}_c$

Y colocamos el valor de la temperatura del sólido,  $T_s = 70$  °C (ver Anexo 1):

$$\frac{\partial T_g}{\partial t} = -a U_a (T_g - 70) - b (T_g - T_c) + c N_s$$

Luego de desarrollar los paréntesis aplicamos nuevos cambios de variables  $m$  y  $n$ :

$$\frac{\partial T_g}{\partial t} = \underbrace{70aU_a + bT_c + cN_s}_m - \underbrace{(aU_a + b)}_n T_g$$

$$\frac{\partial T_g}{\partial t} = m - nT_g$$

Integramos teniendo en cuenta que cada hora la temperatura del gas variará de  $T_{gk}$  a  $T_{gk+1}$ :

$$\int_{T_{gk}}^{T_{gk+1}} \frac{dT_g}{m - nT_g} = \int_0^{3600} dt$$

$$-\frac{1}{n} \ln \left( \frac{m - nT_{gk+1}}{m - nT_{gk}} \right) = 3600 - 0$$

$$\frac{m - nT_{gk+1}}{m - nT_{gk}} = e^{-3600n}$$

Despejando  $T_{gk+1}$  y adecuando la ecuación tenemos:

$$T_{gk+1} = \frac{m}{n} (1 - e^{-3600n}) + T_{gk} e^{-3600n} \quad [9]$$

Los valores del Anexo 1 contienen los datos obtenidos de referencias bibliográficas debido a que fueron de difícil acceso en planta, y el Anexo 7 contiene el análisis dimensional.

### c) Datos históricos de planta

En el Anexo 2 se encuentran los datos obtenidos de la planta pesquera COPEINCA S.A.C. con los cuales se realizará el modelo híbrido neural. Estos datos son 130 en total, de los cuales 100 son usados para

obtener los parámetros  $N_s$  y  $U_a$  a través de las redes neuronales, mientras que los 30 datos restantes serán usados para la validación de los resultados del modelo obtenido.

#### d) Implementación de las Redes Neuronales en Excel

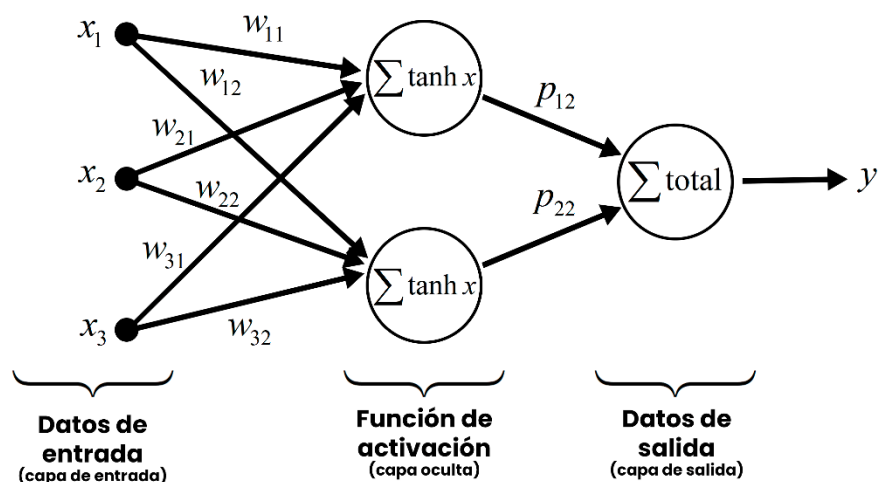
Para este proyecto se usó el perceptrón multicapa con capas de entrada, oculta y de salida.

La capa de entrada consta de 3 neuronas asignando sus respectivos pesos. La capa oculta la constituye 2 neuronas que a su vez contienen las funciones de activación, nosotros usamos la función de activación  $\tanh(x)$ . Estas neuronas reciben los datos de las neuronas de entrada multiplicada por sus respectivos pesos. Luego del proceso se envía a la capa de salida con 1 neurona, la cual recibe los datos de la capa oculta y las suma.

El proceso seguido se grafica en la Figura 5:

**Figura 5**

*Diagrama Redes Neuronales*



### e) Redes Neuronales en Excel para humedad del sólido

- La primera columna de Excel para RNA llamada “Datos de planta, X” contiene los datos históricos de la humedad del sólido (100 datos).
- La segunda columna llamada “STD” contiene la estandarización de los datos de la primera columna para eliminar el ruido y no perjudicar la capacidad de aprendizaje de la RNA. La estandarización de los datos se obtuvo mediante la siguiente fórmula:

$$STD = \frac{y_5 - \frac{\sum_{i=1}^5 y_i}{5}}{S} \quad [10]$$

donde  $S$  es desviación estándar para los 5 valores promediados, la cual calculamos con la siguiente fórmula:

$$= (\$E27 - \text{PROMEDIO}(\$E23:\$E27)) / \text{DESVEST.M}(\$E23:\$E27)$$

Luego se arrastra esta fórmula para toda la columna.

- En las 2 columnas seguidas “IN1A” y “IN2A” colocamos en las primeras filas los pesos supuestos  $w_{11}$ ,  $w_{12}$ ,  $w_{21}$ ,  $w_{22}$ ,  $w_{31}$  y  $w_{32}$ , que en nuestro caso fue 0,5 para cada uno. Este valor se autocorregirá de acuerdo al aprendizaje de la red.

Mas abajo en las mismas columnas colocamos las salidas de la capa de entrada que son sumatorias ponderadas al peso respectivo, por ejemplo:

$$= \$I27 * \$J\$23 + \$I28 * \$J\$24 + \$I29 * \$J\$25$$

Luego se arrastra esta fórmula para toda la columna y la siguiente.

- Las columnas siguientes nombradas como "ON1A" y "ON2A" son las salidas de la capa oculta, estas contienen la función de activación, que para nuestro caso es  $\tanh(x)$ .
- En la siguiente columna colocamos la salida de la capa de salida nombrada como "SUM1", la cual es la sumatoria ponderada con los pesos  $p_1$  y  $p_2$ . Estos pesos fueron 0,5 al iniciar, luego se autocorregirá de acuerdo al aprendizaje de la red.
- La siguiente columna la nombramos como "DIF" la cual contiene la diferencia entre el valor predicho y el valor teórico. Es decir, restamos la columna "STD" con la columna "SUM1".
- A la siguiente columna elevamos al cuadrado para aplicar el ERROR CUADRÁTICO MEDIO. A esta columna llamamos "DIFCUA".
- En la última columna nombrada como "RESU1" efectuamos la operación inversa a la que se hizo en la primera columna nombrada como STD. Para ello escribiremos la siguiente fórmula:

=N29\*DESVEST.M(\$E25:\$E29)+PROMEDIO(\$E25:\$E29)

- Finalmente, para que comience el proceso de aprendizaje de la RNA y se autocorrijan los pesos, es necesario emplear la herramienta SOLVER que también posee Excel. Para ello nos dirigimos a la herramienta SOLVER y elegimos establecemos el objetivo como MÍNIMO, y la celda objetivo será: la sumatoria total de la columna "DIFCUA" dividido el número de datos, la cual es el ERROR CUADRÁTICO MEDIO. Seleccionamos las celdas

que contienen los pesos, las cuales serán las celdas a modificar.  
En método de resolución ponemos GRG NONLINEAR.

- Si por alguna razón no se obtienen resultados adecuados, puede modificarse los pesos manualmente y volver a ejecutar SOLVER.

#### **f) Redes Neuronales en Excel para temperatura del gas**

Se ejecuta la misma operación anterior pero aplicada a los datos históricos de temperatura de gas.

#### **g) Determinación de parámetros**

Para la determinación de parámetros como último paso fue requerido pronosticar los datos de humedad del sólido y temperatura del gas a través de las ecuaciones fenomenológicas. También fue necesario pronosticar los mismos datos, pero a través de las redes neuronales.

Seguidamente es necesario contrastar ambos resultados, aplicando el ERROR CUADRÁTICO MEDIO, para ello restamos las columnas "RESU1" con la columna "X(k+1)" y "RESU2" con la columna "T<sub>g</sub>(k+1)" dividiendo por la cantidad de datos cada uno. Luego se obtiene una sumatoria de todos los datos obtenidos.

Finalmente, se ejecuta SOLVER minimizando la celda objetivo, la cual es la sumatoria obtenida. Como celdas a modificar se coloca a los parámetros  $N_s$  y  $U_a$ . Estas celdas ya estaban llenas con valores supuestos para luego iterar mediante SOLVER, los valores asignados inicialmente fueron 0,1 y 100 respectivamente.

## h) Notación

$\theta$ : ángulo, -

$\lambda$ : calor latente de vaporización, J/kg

$\mu$ : viscosidad, kg/m.s

$\rho$ : densidad de sólido, kg/m<sup>3</sup>

$v_{r,\theta,s,g}$ : velocidad con respecto a:  $r, \theta, s, g$ , m/s

$\phi$ : tiempo de retención en el secador, s

$\omega_A$ : fracción másica, kg soluto / kg solución

$\Phi_v$ : función de disipación viscosa, s<sup>-2</sup>

$A$ : área, m<sup>2</sup>

$C_g$ : capacidad calorífica del aire húmedo, J/kg.°C

$C_s$ : capacidad calorífica del sólido húmedo, J/kg.°C

$D_{XY}$ : difusividad para el sistema X-Y

$g$ : subíndice para indicar gas

$G_s$ : flujo másico del gas (aire), kg/s

$k$ : conductividad térmica, J/m.s.°C

$L_s$ : flujo másico de sólido, kg/s

$N_s$ : velocidad de secado (base seca), kg agua / kg.s

$r$  : radio, m

$s$  : subíndice para indicar sólido

$t$  : tiempo, s

$T$  : temperatura, °C

$T_c$  : temperatura del aire en la entrada del secador, °C

$T_g$  : temperatura del aire en la salida del secador, °C

$T_s$  : temperatura del sólido, °C

$U_a$  : coeficiente volumétrico de transferencia de calor, J/s.m<sup>3</sup>.°C

$V$  : volumen, m<sup>3</sup>

$V_s$  : velocidad axial del sólido, m/s

$V_g$  : velocidad axial del gas, m/s

$X$  : humedad en el sólido a la salida del secador (base seca),  
kg agua / kg sólido

$X_c$  : humedad en el sólido en la entrada del secador (base seca),  
kg agua / kg sólido

$z$  : longitud axial, m

## CAPÍTULO IV

### RESULTADOS Y DISCUSIÓN

#### 4.1. RESULTADOS

##### 4.1.1. Set de ecuaciones de conservación de materia y energía

En el anterior capítulo a través de la resolución de las ecuaciones diferenciales obtenidas a partir de los balances de materia y energía, se obtuvieron las siguientes ecuaciones de conservación (*para identificar las variables y constantes ver el apartado **h** del capítulo III*):

$$\frac{\partial X}{\partial t} = -V_s \frac{\partial X}{\partial z} - N_s \quad [6]$$

$$C_g \frac{G_s}{V_g} \frac{\partial T_g}{\partial t} = -U_a A (T_g - T_s) - C_g G_s \frac{\partial T_g}{\partial z} + \frac{L_s}{V_s} N_s \lambda \quad [7]$$

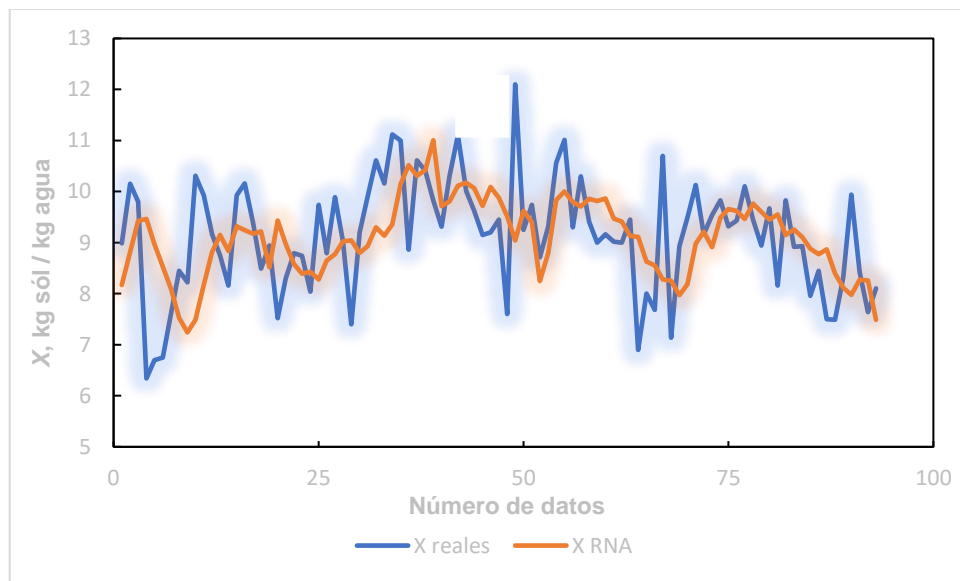
Las cuales fueron utilizadas en la hoja de cálculo de Excel para el desarrollo del modelo neural.

##### 4.1.2. Modelo de proceso de secado usando Microsoft Excel

El comportamiento de la predicción de las redes neuronales con respecto a la humedad del sólido y la temperatura del gas puede notarse en las figuras 6 y 7; y el comportamiento con las ecuaciones fenomenológicas pueden notarse en las figuras 8 y 9.

**Figura 6**

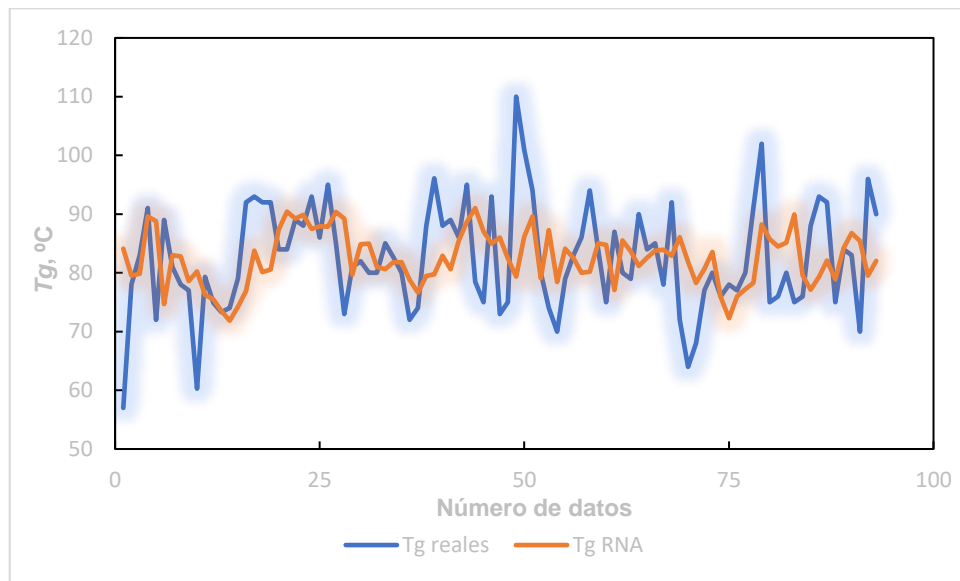
*Predicción de la RNA para la variable X*



En la figura 6, se tiene la gráfica de la humedad del sólido vs el número de datos históricos (que son 100), obtenida mediante la ecuación [6] a través de los resultados obtenidos en Excel (ver Anexo 3), además el comportamiento de las redes neuronales artificiales sobre la variable de salida de la humedad del sólido tiene cierta precisión, pero no del todo, es por ello que se refuerza este método combinándolo con las ecuaciones fenomenológicas.

**Figura 7**

*Predicción de la RNA para la variable  $T_g$*




En la figura 7 tenemos a la temperatura del gas de salida vs el número de datos históricos (que son 100), obtenida mediante la ecuación [7] a través de los resultados de Excel (ver Anexo 4), además observamos que el comportamiento de las redes neuronales para la variable de salida de la temperatura del gas es un tanto mejor que para la figura 6.

También observamos las gráficas de los comportamientos de las predicciones obtenidas mediante las ecuaciones fenomenológicas en las figuras 8 y 9.



**Figura 9**

*Predicción mediante ecuaciones fenomenológicas para la variable  $T_g$*



En la figura 9 tenemos a la temperatura del gas de salida vs el número de datos históricos (que son 100), en donde observamos que el comportamiento con las ecuaciones fenomenológicas para la variable de salida de la temperatura del gas presenta una predicción con cierta mejoría.

Para ver los resultados obtenidos en Excel, dirigirse al Anexo 5.

#### **4.1.3. Parámetros**

Luego de correr la simulación del modelo sugerido, se obtuvieron algunos parámetros tanto como para las RNA, las ecuaciones

fenomenológicas y especialmente los parámetros objetivo  $N_s$  y  $U_a$ , las cuales detallamos a continuación.

**Tabla 2**

*Pesos o bias de las RNA para la variable X*

<b>Peso <math>w_{11}</math></b>	<b>Peso <math>w_{12}</math></b>	<b>Peso <math>w_{21}</math></b>	<b>Peso <math>w_{22}</math></b>
1,4528	0,5752	-2 157,5686	2,6159
<b>Peso <math>w_{31}</math></b>	<b>Peso <math>w_{32}</math></b>	<b>Peso <math>p_{12}</math></b>	<b>Peso <math>p_{22}</math></b>
-622,5942	0,6759	-0,5515	-0,6276

**Tabla 3**

*Pesos o bias de las RNA para la variable  $T_g$*

<b>Peso <math>w_{11}</math></b>	<b>Peso <math>w_{12}</math></b>	<b>Peso <math>w_{21}</math></b>	<b>Peso <math>w_{22}</math></b>
-0,9801	-0,9873	2,6269	2,5610
<b>Peso <math>w_{31}</math></b>	<b>Peso <math>w_{32}</math></b>	<b>Peso <math>p_{12}</math></b>	<b>Peso <math>p_{22}</math></b>
-2,0395	-1,9586	-20,3699	20,3271

**Tabla 4**

*Constantes físicas finales*

<b><math>\emptyset</math>, s</b>	<b>A, m<sup>2</sup></b>	<b><math>V_g</math>, m/s</b>	<b><math>G_s</math>, kg/s</b>	<b><math>C_g</math>, J/kg°C</b>	<b><math>V_s</math>, m/s</b>
300	78,5398	1,14	4	1 005	0,0333
<b><math>L_s</math>, kg/s</b>	<b><math>\lambda</math>, J/kg</b>	<b>z, m</b>	<b><math>T_s</math>, °C</b>	<b><math>\emptyset_{muestra}</math>, s</b>	<b>D, m</b>
0,5	2 500 000	10	70	10	2,5

**Tabla 5**

*Parámetros objetivo*

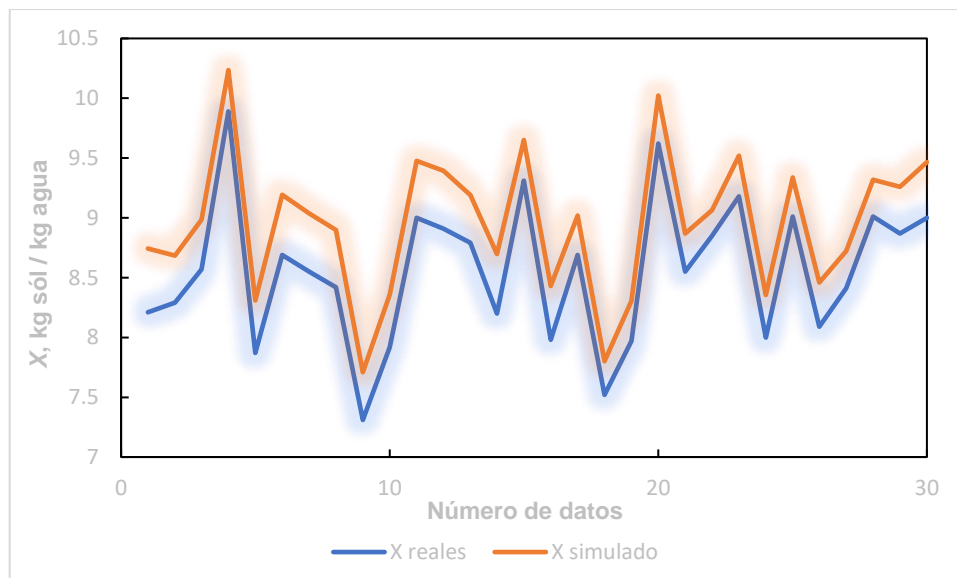
$N_s$	$U_a$
-0,0013	75,1267

#### 4.1.4. Validación de resultados

Se usó un conjunto de 30 datos históricos adicionales para corroborar gráficamente la eficacia de la predicción. Estos gráficos se elaboraron a partir del nuevo modelo obtenido en Excel cuyos resultados están graficados en las figuras 10 y 11.

**Figura 10**

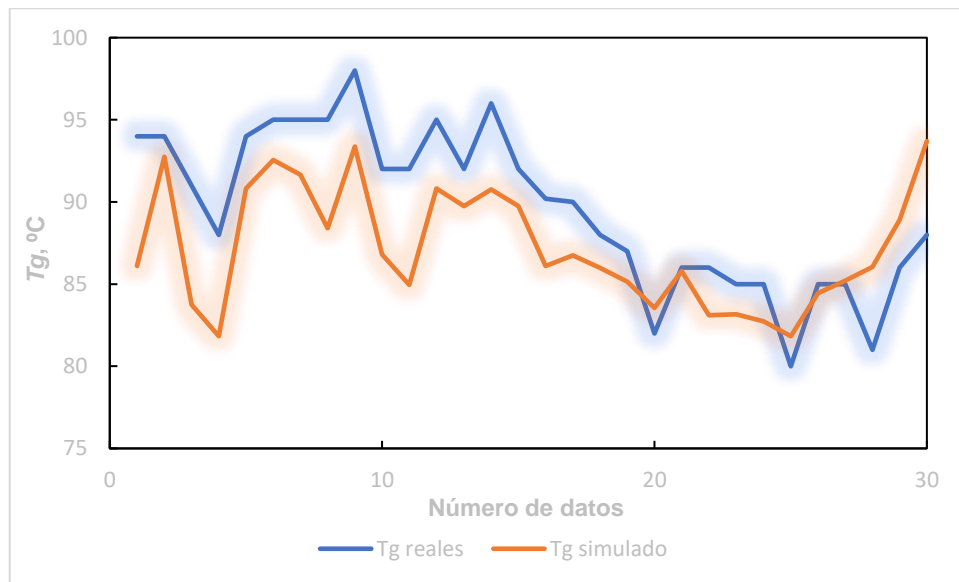
*Modelo Híbrido Neural para la variable X*



En la figura 10 observamos una muy buena predicción de parte de la red híbrida neural (redes neuronales con ecuaciones fenomenológicas), para la variable de salida de humedad del sólido.

### Figura 11

*Modelo Híbrido Neural para la variable  $T_g$*



En la figura 11 observamos una buena predicción de parte de la red híbrida neural (redes neuronales con ecuaciones fenomenológicas), para la variable de salida de temperatura del gas.

La validación matemática de resultados se realizó usando las ecuaciones [2], [3] y [4], que son ERROR CUADRÁTICO MEDIO, ERROR PORCENTUAL MEDIO y ERROR ABSOLUTO MEDIO respectivamente.

Aplicando las 3 ecuaciones obtenemos los resultados de los errores en la tabla 6.

**Tabla 6**

*Validación de resultados con errores ECM, EPM y EAM*

	<b>X</b>			<b>T<sub>g</sub></b>		
	ECM	EPM	EAM	ECM	EPM	EAM
RNA	1,7324	16,9836	66,5345	87,6630	95,1086	519,5703
EC FENOM	2,1858	26,0974	-64,5987	169,2045	210,3751	-542,5836
HN	0,9057	11,3555	-36,4232	20,9359	22,4535	242,5591

Además, también es posible hacer la comparación con otros resultados de investigaciones similares, esto se aprecia en la tabla 7.

**Tabla 7**

*Comparación con otras investigaciones*

Fuentes	<b>ERRORES</b>
	ECM
Cubillos y col., 1995	0,2454
Moscol y col., 2021	0,0538
Investigación actual	0,9057

## 4.2. DISCUSIÓN

En primer lugar, observamos que las ecuaciones fenomenológicas [6] y [7] han sido obtenidas a través de los balances de materia y energía, las cuales fueron usadas para calcular los valores futuros de las variables de salida  $X$  y  $T_g$  respectivamente, y a su vez estos resultados sirvieron para la predicción con el método de Redes Neuronales Artificiales.

En la figura 6 se observa el resultado de la RNA para la variable de salida  $X$ , las cual según el error calculado en la tabla 6 nos damos cuenta que tiene un error ECM 1,7324, el cual es muy bajo, lo que indica una buena predicción. Análogamente, en la figura 7 se observa que la predicción calculada con la RNA sigue regularmente la tendencia que dejan los datos históricos reales, esto se confirma en el error ECM calculado 87,6630.

En las figuras 8 y 9, tenemos los gráficos de los resultados predichos a través del set de ecuaciones fenomenológicas. En el caso de la predicción para la variable  $X$  notamos que la simulación alcanza similitud con los datos reales, pero la única desventaja es que la similitud está desfasada, por ello el error es mayor que para la predicción por RNA, el error ECM es 2,1858. Para el caso de la variable  $T_g$ , el error ECM resultó 169,2045, esto es porque claramente en la figura 9 se observa que la ecuación sigue la tendencia, pero sin precisión.

Con respecto a las figuras 10 y 11, notamos la eficacia en los resultados del modelo híbrido neural gráficamente, incluso si observamos el error ECM en la tabla 6 veremos que es 0,9057 y 20,9359, para la variable de salida  $X$  y  $T_g$  respectivamente, lo cual es muy bajo. Aunque también se aprecia que el ajuste funcionó mucho mejor para la variable  $X$  que para la variable  $T_g$ . posiblemente tenga que ver con los datos históricos extraídos de planta.

También observamos que en las tablas 2 y 3 se lograron corregir y obtener los pesos o bias que se aplicaron en las RNA; sus valores van desde -2 157 hasta 20,3271. Este ajuste se realizó por medio de la herramienta SOLVER en Excel.

En la tabla 4 se encuentran las constantes físicas finales, es decir que durante el modelamiento se hicieron correcciones a algunos valores supuestos inicialmente a partir de bibliografía, esto para ajustar el modelo planteado, y así optimizar el modelo híbrido neural. La corrección principal fue en la amplitud del tiempo de muestreo de los datos históricos, porque mientras más amplio era el tiempo de muestreo, menor era la eficacia del modelo.

Finalmente se lograron obtener parámetros satisfactorios para  $N_s$  y  $U_a$ , estos los podemos encontrar en la tabla 5.

En la tabla 6 encontramos los errores obtenidos para cada variable y para cada método de simulación. Además, se calcularon distintos tipos de errores para verificar la veracidad de la eficacia de un modelo predictivo. Según se observa, el error con menor variación es ECM, por ello se trabaja principalmente con este error. Así, notamos que el modelo predictivo menos eficaz es el propuesto por las ecuaciones fenomenológicas. Luego le sigue el modelo propuesto por las RNA, y finalmente el modelo con mejor predicción es la unión de ambos métodos, formando el modelo híbrido neural.

En la tabla 7 observamos la comparación con resultados de otras investigaciones, estas son “*Hybrid-neural modeling for particulate solid drying processes*” de los autores Cubillos y colaboradores de 1995; y también otra investigación más reciente “*Predicción de parámetros de calidad de la harina de pescado utilizando Imágenes Hiperespectrales y*

*Redes Neuronales Artificiales*” de los autores Moscol y colaboradores de 2021. La comparación se realizó tomando como factor de eficiencia el error ECM (error cuadrático medio). Al ver el contraste se aprecia claramente una mejor eficiencia en la investigación hecha por Moscol y col., esto porque el error ECM es el menor que en los demás casos. Esto puede deberse a que incluyeron adicionalmente Imágenes Hiperespectrales, que son técnicas de selección, además de las redes neuronales artificiales para encontrar los parámetros del proceso. El segundo proyecto de investigación usa también ecuaciones fenomenológicas obtenidas a través de balances de materia y energía, añadido con el método de redes neuronales artificiales, es por ello que obtuvo un bajo error ECM menor que 1, por lo que indica que el modelo obtenido es eficiente. Luego observamos el error ECM de nuestra tesis donde vemos que, aunque presenta el mayor de los errores, tiene un error ECM menor que 1, el cual también es válido para una futura adaptación a un sistema de control. El mayor error de las 3 investigaciones posiblemente se deba a que algunos datos específicos del equipo y material a secar fueron obtenidos de manera bibliográfica y no del mismo equipo de secado de la planta pesquera COPEINCA S.A.C.

## CONCLUSIONES

1. El método de redes neuronales artificiales con las ecuaciones fundamentales de conservación de materia y energía (modelo híbrido neural) funcionó como una excelente herramienta para el modelamiento del secador rotatorio con aire caliente para la planta pesquera COPEINCA S.A.C. sede Ilo.
2. El set de ecuaciones fenomenológicas fue obtenido correctamente mediante los balances de conservación de materia y energía en el proceso de secado. A su vez las constantes físicas fueron obtenidas de bibliografía, las cuales se reajustaron para una mayor eficacia del modelo.
3. El software Microsoft Excel fue utilizado a la perfección para el modelamiento del proceso de secado del secador rotatorio, incluyendo la herramienta SOLVER como medio iterativo de aprendizaje de la red.
4. Los resultados predichos fueron validados a través del cálculo de los errores ECM, EPM y EAM. Donde se concluyó que el modelo híbrido neural funcionó de mejor manera para la predicción de la variable de salida  $X$  (humedad de la harina).

## RECOMENDACIONES

1. Se recomienda utilizar el modelo híbrido neural para posteriores predicciones en planta, además de implementar un sistema de control PID, usando las ecuaciones obtenidas en esta investigación.
2. Es recomendable usar la mayor cantidad de datos históricos para mejorar el aprendizaje, y a su vez mejorar las predicciones.
3. Se recomienda que las muestras para los datos históricos sean tomadas lo más frecuentemente posible, por ejemplo, cada 5 o 10 min, porque si trabajamos con muestras tomadas cada 1 hora, esto generará menor precisión en la predicción.
4. Se recomienda usar datos históricos recientes, durante el mismo año, porque pasados puede generar un error en la predicción.
5. Si se desea acomodar el método a cualquier otra planta pesquera o incluso a otro equipo industrial, se recomienda usar el set de ecuaciones de conservación de materia y energía, sumado con el método RNA, así se obtendrá una mejor eficacia en la predicción.

## REFERENCIAS BIBLIOGRÁFICAS

Aceijas Pajares, W. N. (2011). *Optimización de un secador rotatubos a vapor de 40 ton/h para la Industria Pesquera*. Lima, Perú: Tesis de Maestría en Ciencias con mención en Ingeniería Mecánica, Universidad Nacional de Ingeniería.

Alegre, A. (2003). *Simulación de redes neuronales artificiales: Una aplicación didáctica*. Argentina: Tesis Lic. Sistemas, Universidad Nacional del Nordeste.

Au Díaz, N. (1996). *Elaboración de harinas de pescado de alta calidad*. Concepción, Chile.

Basogain Olabe, X. (2002). *Redes neuronales artificiales y sus aplicaciones*. Bilbao, España: Escuela Superior de Ingeniería de Bilbao.

Recuperado el 2015, de

[www.ciberesquina.una.edu.ve:8080/2014\\_2/350\\_E.pdf](http://www.ciberesquina.una.edu.ve:8080/2014_2/350_E.pdf)

Cruz, F., Acuña, G., Badillo, G. (2011). *Propuesta Metodológica Para la Creación de Modelos Neuronales de Caja Gris Utilizando Matlab*.

Medellín, Colombia: 9th Latin American and Caribbean Conference for Engineering and Technology.

Cubillos, F., Alvarez P., Pinto, J. & Lima E. (1995). *Hybrid-neural modeling for particulate solid drying processes. Powder Technology, Vol. 87, No. 2, 153-160.*

Cubillos, F., Callejas, H., Lima, E. & Vega, M. (2001). *Adaptive control using a hybrid-neural model: application to a polymerisation reactor. Brazilian Journal of Chemical Engineering, Vol. 18, No. 1. 113-120.*

Diccionario de la lengua española. (2021). *Algoritmo.*

Recuperado el 2021, de

<https://dle.rae.es/algoritmo>

Echeverry Ocampo, D. A. (2010). *Diseño y simulación de la automatización de un secador electromecánico de café.* Pereira, Colombia: Universidad Tecnológica de Pereira.

Estrada, S., Rayo, V., Salgado, M., García, M. & Rodríguez, G. (2001). *Simulación y control del proceso de secado sobre tambor rotatorio utilizando un modelo híbrido neuro-diferencial.* Veracruz, México: Instituto Tecnológico de Veracruz.

Fernández Rodríguez, E., González Santos, A. I. & Águila Camacho, N. (2011). *Modelo híbrido del secador rotatorio de la fábrica Cementos Cienfuegos S.A.* Ciudad de La Habana, Cuba.

Flórez López, R. & Fernández Fernández, J. M. (2008). *Las Redes Neuronales Artificiales: Fundamentos teóricos y aplicaciones prácticas.* España: Gesbiblio, S. L.

Recuperado el 2015, de

<https://books.google.com.pe/books?id=X0uLwi1Ap4QC&printsec=frontcover&dq=redes+neuronales&hl=es&sa=X&ei=RQE5VaXmKcu mNuvlgYgH&ved=0CBsQ6AEwAA#v=onepage&q=redes%20neuronales&f=false>

García, J., López, A. M., Romero, J. E. & García, A. R. (2002). *Hojas de cálculo para la simulación de redes de neuronas artificiales (RNA).* *Questiío, Vol. 26, 1-2, 289-305.*

Goalco Proyectos S.A. (2005). *Sistema de secado por aire caliente GOALCO BT.*

Recuperado el 2015, de

[www.goalco.com.pe/documentos/Brochuresecador.pdf](http://www.goalco.com.pe/documentos/Brochuresecador.pdf)

Haarslev Industries. (2000). Concepto de secado de aire caliente.

Recuperado el 2015, de

[http://www.haarslev.com/media/AirDryingSolution\\_ES.pdf](http://www.haarslev.com/media/AirDryingSolution_ES.pdf)

Incropera, F. P. & De Witt, D. P. (1999). *Fundamentos de transferencia de calor*. Cuarta Edición. México: Prentice Hall Latinoamericana S.A.

Kasiri, N., Hashemabadi, S. H., Khazraee, M. & Shahhosseini, S. (2004). *Mathematical Modeling and Computer Simulation of Continuous Rotary Dryers*. Tehran, Irán: Iran University of Science and Technology (IUST).

Landeo, G. & Ruiz, A. (1996). *Producción de Harina de Pescado*. Lima, Perú: Universidad Faustino Sánchez Carrión.

Laqui Vilca, W. F. (2010). *Aplicación de Redes Neuronales Artificiales a la Modelización y Previsión de Caudales Medios Mensuales del Río Huancané*. Lima, Perú: Servicio Nacional de Meteorología e Hidrología del Perú.

Lee, A., Sheehan, M. E. & Schneider, P. A. (2004). *Solids transport in rotary sugar dryers*. Townsville, Australia: James Cook University.

Londoño García, R. (2015). *Balances de masa y energía*. Pereira, Colombia: Universidad Tecnológica de Pereira.

- Martínez-Martínez, V., Baladrón, C., Gómez-Gil, J., Ruiz-Ruiz, G., Navas-Gracia, L. M., Aguiar, J. M. & Carro, B. (2013). *Modelo basado en redes neuronales artificiales para el cálculo de parámetros ambientales en el proceso de curado del tabaco*. Colombia.
- Moscol, I., Peltroche, G. & Ruesta, V. (2021). *Predicción de parámetros de calidad de la harina de pescado utilizando Imágenes Hiperespectrales y Redes Neuronales Artificiales*. Piura, Perú: Universidad de Piura.
- Mueller-Vollmer, J., P. Bimbo, A., Basurco Zeballos, F. & Egocheaga Young, L. (1998). *Incremento de ganancias y reducción de residuos en la industria de harina de pescado mediante prácticas de manejo preventivo*. Virginia, Estados Unidos: CONAM.
- Ocon García, J. & Tojo Barreiro, G. (1990). *Problemas de Ingeniería Química Operaciones Básicas Tomo I*. España: Editorial Aguilar S.A.
- Rich, E., & Knight, K. (1994). *Inteligencia artificial*. Segunda Edición. España: McGraw-Hill.
- Shahhosseini, Sh., Sadeghi, M. T. & Golsefatan, H. R. (2010). *Dynamic Simulation of an Industrial Rotary Dryer*. Tehran, Irán: Iran University of Science and Technology (IUST).

Sociedad Nacional de Pesquería (2018). *Harina de pescado: Perú lidera su producción mundial*.

Recuperado el 2018, de <https://www.snp.org.pe/harina-de-pescado/>

Treybal, R. E. (1980). *Operaciones de Transferencia de Masa*. Estados Unidos: McGraw Hill Book Co.

Valdés-González, H., Salazar, J. L., Reyes-Bozo, L., Vyhmeister, E., Gómez-Varela, M. & Cubillos Montecinos, F. (2011). *Control basado en optimización de un secador rotatorio directo*. Santiago, Chile: Universidad Andres Bello.

Vallejos Romaña, C. A. (2013). *Modelación, simulación, control PID y control predictivo de un secador Rotadisco en la Industria Pesquera*. Piura, Perú: Tesis de pregrado en Ingeniería Mecánico Eléctrica. Universidad de Piura.

Wayne Bequette, B. (1998). *Process dynamics: modeling, analysis, and simulation*. Estados Unidos: Prentice Hall, Inc.

Wikipedia, Enciclopedia libre. (2015). *Red neuronal artificial*.

Recuperado el 2015, de

[http://es.wikipedia.org/wiki/Red\\_neuronal\\_artificial](http://es.wikipedia.org/wiki/Red_neuronal_artificial)

Wikipedia, Enciclopedia libre. (2014). *Perceptrón*.

Recuperado el 2015, de

<http://es.wikipedia.org/wiki/Perceptr%C3%B3n>

Yliniemi, L. (1999). *Advanced control of a rotary dryer*. Oulu, Finlandia:

Universidad de Oulu.

# **ANEXOS**

## ANEXO 1: DATOS DEL PROCESO DE SECADO

Los valores aquí presentados son datos obtenidos de referencias bibliográficas debido a que fueron de difícil acceso en planta.

*Fuente: Cubillos y col., 1995*

Parámetros de proceso	Valores
Flujo másico del sólido seco, $L_s$	0,627 kg/s
Temperatura de ingreso del sólido, $T_s$	70 °C
Flujo másico del gas seco, $G_s$	4 kg/s
Diámetro del secador rotatorio, $D$	2,5 m
Longitud del secador rotatorio, $L$	10 m
Tiempo de retención, $\phi$	300 s
Velocidad axial del gas, $V_g$	1,14 m/s
Velocidad axial del sólido, $V_s$	0,035 m/s
Capacidad calorífica del aire seco, $C_g$	1 005 J/kg°C
Calor latente de vaporización, $\lambda$	2 500 000 J/kg

## ANEXO 2: DATOS HISTÓRICOS DE PLANTA

Son los datos obtenidos de la planta pesquera COPEINCA S.A.C. con los cuales se realizará el modelo híbrido neural.

*Fuente: Planta Pesquera COPEINCA S.A.C, 2013*

Datos de planta									
Nº	$X_c$	$T_c$	$X(k)$	$Tg(k)$	Nº	$X_c$	$T_c$	$X(k)$	$Tg(k)$
1	13,2	126	9,42	51,2	51	32	650	9,62	78,5
2	11,72	260	6,94	116	52	5,6	647	9,15	75
3	15,26	350,8	6,24	74,5	53	33,8	513	9,2	93
4	32,64	349	7,2	82,9	54	26,02	479	9,45	73
5	29,3	487	9,42	95	55	21,4	333	7,6	75
6	35,6	615	9,84	75	56	44,97	448	12,1	110
7	39,61	654	8,75	91	57	45,38	434	9,25	101
8	39,6	325	8,99	57	58	37,4	585	9,74	94
9	30	323	10,15	78	59	30,1	513	8,71	80
10	38,14	470	9,8	83	60	27,93	439	9,31	74
11	22,5	420	6,34	91	61	26,93	454	10,56	70
12	24,91	305	6,7	72	62	27,16	507	11,01	79
13	20,66	207	6,75	89	63	29,4	633	9,3	83
14	21,32	325	7,62	81	64	30,16	671	10,3	86
15	24,3	331	8,45	78	65	30,01	670	9,41	94
16	25,12	372	8,22	77	66	29,3	580	9	84
17	34,1	311	10,31	60,3	67	28,86	545	9,16	75
18	28,23	341	9,93	79,3	68	28,52	604	9,02	87
19	30,16	449	9,16	74,9	69	29,31	625	9	80
20	31,3	415	8,75	73,3	70	31,46	647	9,45	79
21	32,1	358	8,16	74	71	24,4	601	6,9	90
22	34,24	359	9,93	79,1	72	22,4	396	8	84
23	32,1	580	10,16	92	73	15,06	472	7,68	85
24	34,9	559	9,39	93	74	33,7	282	10,7	78
25	34,3	413	8,49	92	75	20,87	315	7,14	92

<b>26</b>	30	623	8,94	92	<b>76</b>	22,52	286	8,93	72
<b>27</b>	31,1	523	7,52	84	<b>77</b>	29,61	324	9,49	64
<b>28</b>	30,85	631	8,3	84	<b>78</b>	29,3	306	10,13	68
<b>29</b>	31,15	629	8,79	89	<b>79</b>	24,48	315	9,16	77
<b>30</b>	30,4	641	8,74	88	<b>80</b>	26,69	340	9,54	80
<b>31</b>	30,7	632	8,04	93	<b>81</b>	28,19	357	9,83	76
<b>32</b>	33,34	679	9,74	86	<b>82</b>	29,14	364	9,32	78
<b>33</b>	33,2	661	8,79	95	<b>83</b>	22,3	309	9,43	77
<b>34</b>	31,9	658	9,89	85	<b>84</b>	23,19	413	10,1	80
<b>35</b>	37,55	542	9,02	73	<b>85</b>	23,9	585	9,45	91
<b>36</b>	16,8	449	7,4	81	<b>86</b>	37,1	410	8,94	102
<b>37</b>	20,7	509	9,2	82	<b>87</b>	15	263	9,67	75
<b>38</b>	21,49	472	9,9	80	<b>88</b>	20,1	412	8,16	76
<b>39</b>	22,3	505	10,61	80	<b>89</b>	24,16	350	9,83	80
<b>40</b>	25,1	595	10,16	85	<b>90</b>	28,06	416	8,92	75
<b>41</b>	30,5	601	11,12	82,7	<b>91</b>	28,01	330	8,93	76
<b>42</b>	30,1	569	11	80	<b>92</b>	29	458	7,96	88
<b>43</b>	22,3	462	8,86	72	<b>93</b>	30,01	518	8,45	93
<b>44</b>	27,2	416	10,61	74	<b>94</b>	21,1	391	7,5	92
<b>45</b>	31,56	557	10,41	87,9	<b>95</b>	23,3	148	7,49	75
<b>46</b>	30,27	570	9,83	96,1	<b>96</b>	17	351	8,33	84
<b>47</b>	29,7	560	9,31	88	<b>97</b>	28	407	9,94	83
<b>48</b>	30	605	10,31	89	<b>98</b>	20,6	357	8,42	70
<b>49</b>	29,9	596	11,1	86	<b>99</b>	24,4	395	7,64	96
<b>50</b>	33,52	637	10,01	95	<b>100</b>	20,3	501	8,1	90

### ANEXO 3: RESULTADOS DE LA RNA EN EXCEL PARA LA VARIABLE X

Nº	RNA X(k+1)								
	STD	IN1A	IN2A	ON1A	ON2A	SUM1	DIF	DIFCUA	RESU
1	Peso w1	1,4528	0,5752						
2	Peso w2	-2157,5687	2,6159						
3	Peso w3	-622,5942	0,6759						
4	Peso p	-0,5515	-0,6276						
5	1,0642								
6	1,1952								
7	0,3020	-2765,1012	3,9427	-1	0,9992	-0,0756	-0,2246	0,0504	8,1748
8	0,1489	-742,5389	1,5781	-1	0,9183	-0,0248	-1,2676	1,6067	8,8150
9	1,2428	-1094,6695	1,4033	-1	0,8861	-0,0046	-0,4928	0,2428	9,4274
10	0,4882	-2985,0983	3,6666	-1	0,9987	-0,0753	1,5768	2,4863	9,4607
11	-1,6520	-23,0066	0,8754	-1	0,7041	0,1096	1,0689	1,1425	8,9696
12	-0,9592	4162,3375	-4,6892	1	-0,9998	0,0760	0,7196	0,5179	8,5303
13	-0,6437	2467,9695	-3,8946	1	-0,9992	0,0756	-0,0516	0,0027	8,0886
14	0,1272	1308,1490	-2,1496	1	-0,9732	0,0593	-1,4347	2,0584	7,5249
15	1,4940	-1205,4708	0,9722	-1	0,7497	0,0810	-0,7483	0,5600	7,2413
16	0,8293	-3739,5083	4,5418	-1	0,9998	-0,0759	-1,6259	2,6434	7,4865
17	1,5499	-2752,1497	4,0764	-1	0,9994	-0,0757	-0,9610	0,9235	8,1703
18	0,8853	-3894,0305	5,1299	-1	0,9999	-0,0760	-0,0165	0,0003	8,8181
19	-0,0596	-1870,6617	3,1670	-1	0,9965	-0,0739	0,5413	0,2930	9,1470
20	-0,6152	512,7904	-0,0624	1	-0,0623	-0,5124	0,7534	0,5676	8,8375
21	-1,2659	2115,3253	-2,4991	1	-0,9866	0,0677	-0,9029	0,8152	9,3209
22	0,9706	2126,0140	-3,0093	1	-0,9951	0,0730	-1,0492	1,1009	9,2420
23	1,1223	-2794,5937	2,5693	-1	0,9883	-0,0688	-0,2040	0,0416	9,1751
24	0,1352	-2504,1259	3,5854	-1	0,9985	-0,0751	0,7646	0,5846	9,2158
25	-0,8397	232,6908	0,4317	1	0,4067	-0,8068	-0,1649	0,0272	8,5188
26	-0,6419	2211,5724	-2,5527	1	-0,9879	0,0685	1,4658	2,1485	9,4292
27	-1,3973	2253,6094	-3,1065	1	-0,9960	0,0736	0,3974	0,1580	8,9727
28	-0,3239	3215,3924	-4,2432	1	-0,9996	0,0758	-0,6114	0,3738	8,5814
29	0,6872	268,8921	-1,1865	1	-0,8295	-0,0309	-0,5206	0,2710	8,3908
30	0,4896	-1788,0645	1,9424	-1	0,9597	-0,0508	0,4016	0,1612	8,4287

31	-0,4524	-773,7676	1,3704	-1	0,8788	0,0000	-1,5687	2,4609	8,2780
32	1,5687	0,0210	0,1586	0,0210	0,1572	-0,1103	-0,0607	0,0037	8,6504
33	-0,0496	-3354,3897	3,8099	-1	0,9990	-0,0755	-1,1809	1,3945	8,7744
34	1,1054	-578,9315	1,5197	-1	0,9086	-0,0187	0,0824	0,0068	9,0256
35	-0,1011	-2322,1710	2,7949	-1	0,9926	-0,0714	1,5087	2,2761	9,0423
36	-1,5801	1203,5166	-0,6966	1	-0,6022	-0,1736	-0,5457	0,2978	8,7957
37	0,3722	3177,2778	-3,9400	1	-0,9992	0,0756	-0,7257	0,5266	8,9291
38	0,8013	-1304,1108	0,6062	-1	0,5415	0,2117	-0,9429	0,8891	9,2981
39	1,1546	-2447,0962	3,0905	-1	0,9959	-0,0735	-0,6353	0,4036	9,1379
40	0,5618	-2839,7868	3,8610	-1	0,9991	-0,0755	-1,3462	1,8122	9,3591
41	1,2706	-2001,5211	2,9925	-1	0,9950	-0,0729	-0,9138	0,8350	10,1451
42	0,8408	-3264,1884	4,2154	-1	0,9996	-0,0758	1,5550	2,4179	10,5182
43	-1,6308	-797,0221	1,8283	-1	0,9497	-0,0445	-0,3290	0,1083	10,3094
44	0,2846	3342,5700	-3,5900	1	-0,9985	0,0751	0,0641	0,0041	10,4186
45	0,0110	-623,1992	-0,1862	-1	-0,1840	0,6670	1,0421	1,0860	11,0053
46	-0,3751	210,1541	-0,0610	1	-0,0609	-0,5133	0,1601	0,0256	9,7150
47	-0,6734	1228,4981	-1,4299	1	-0,8917	0,0081	-0,4044	0,1635	9,8099
48	0,4124	1195,5483	-1,6985	1	-0,9352	0,0354	-1,3201	1,7426	10,1126
49	1,3555	-1734,7613	1,6077	-1	0,9228	-0,0276	0,1266	0,0160	10,1735
50	-0,1543	-2827,9241	3,6789	-1	0,9987	-0,0753	0,5773	0,3332	10,0622
51	-0,6526	741,1059	-0,0649	1	-0,0649	-0,5108	0,6959	0,4843	9,7177
52	-1,2068	2159,0295	-2,6114	1	-0,9893	0,0693	0,8412	0,7076	10,0890
53	-0,7719	3083,3002	-4,0539	1	-0,9994	0,0757	0,1787	0,0319	9,8764
54	-0,1030	1727,7089	-2,7829	1	-0,9924	0,0713	1,8096	3,2747	9,5109
55	-1,7383	1303,4131	-1,8883	1	-0,9552	0,0480	-1,5503	2,4035	9,0428
56	1,5983	2755,3357	-3,5264	1	-0,9983	0,0750	0,2415	0,0583	9,6220
57	-0,1665	-3347,3240	3,0687	-1	0,9957	-0,0734	-0,1428	0,0204	9,4010
58	0,0694	318,2597	0,5308	1	0,4860	-0,8565	-0,3946	0,1557	8,2461
59	-0,4620	137,5960	-0,2264	1	-0,2226	-0,4118	-0,0254	0,0006	8,7936
60	-0,3864	1237,4392	-1,4298	1	-0,8916	0,0081	-1,5085	2,2755	9,8327
61	1,5165	-111,1010	-0,2516	-1	-0,2464	0,7062	-0,5253	0,2759	10,0011
62	1,2315	-4039,3137	4,5772	-1	0,9998	-0,0759	0,4199	0,1763	9,7955
63	-0,4958	-2346,1646	3,7587	-1	0,9989	-0,0754	-0,3419	0,1169	9,7053
64	0,2665	905,6531	-0,4086	1	-0,3873	-0,3085	0,6447	0,4156	9,8599
65	-0,9532	17,7050	-0,2323	1	-0,2282	-0,4083	0,5602	0,3139	9,8135
66	-0,9686	2659,9255	-2,9948	1	-0,9950	0,0729	0,6124	0,3750	9,8645
67	-0,5395	2424,2636	-3,4466	1	-0,9980	0,0748	0,7368	0,5429	9,4720
68	-0,6620	1574,6881	-2,4158	1	-0,9842	0,0661	0,7350	0,5403	9,4138
69	-0,6689	1844,0517	-2,4942	1	-0,9865	0,0676	-1,6105	2,5936	9,1299
70	1,6781	397,4898	-0,9964	1	-0,7601	-0,0745	1,6867	2,8448	9,1116

71	-1,7612	-2525,0155	2,8146	-1	0,9928	-0,0716	0,3894	0,1516	8,6326
72	-0,4610	4089,2328	-3,9534	1	-0,9993	0,0756	0,5888	0,3467	8,5518
73	-0,5132	1311,4820	-2,5657	1	-0,9883	0,0687	-1,3505	1,8238	8,2764
74	1,4192	222,9158	-0,6483	1	-0,5705	-0,1935	0,4254	0,1810	8,2524
75	-0,6189	-2677,4615	2,9991	-1	0,9950	-0,0730	-0,3881	0,1506	7,9727
76	0,3152	1141,1105	-0,5896	1	-0,5296	-0,2191	-0,7121	0,5071	8,1841
77	0,4929	-987,7882	0,8016	-1	0,6650	0,1342	-0,4886	0,2388	8,9791
78	0,6228	-1450,8699	1,8917	-1	0,9555	-0,0482	-0,2181	0,0476	9,2121
79	0,1699	-1448,8649	2,0277	-1	0,9659	-0,0547	-0,2527	0,0638	8,9088
80	0,1980	-488,9218	0,9365	-1	0,7336	0,0911	-0,4539	0,2060	9,4914
81	0,5450	-766,2496	0,9840	-1	0,7548	0,0778	0,7850	0,6162	9,6586
82	-0,7072	-735,3970	1,0617	-1	0,7863	0,0580	0,1613	0,0260	9,6186
83	-0,1032	1590,8068	-1,6062	1	-0,9226	0,0275	-1,4071	1,9800	9,4629
84	1,4346	-671,4831	0,2928	-1	0,2847	0,3728	0,9101	0,8282	9,7625
85	-0,5372	-2760,9910	3,3304	-1	0,9974	-0,0745	1,1400	1,2996	9,6016
86	-1,2145	1917,2866	-1,4010	1	-0,8856	0,0043	-0,3570	0,1274	9,4498
87	0,3612	2394,5994	-3,2418	1	-0,9969	0,0742	1,5554	2,4192	9,5492
88	-1,4812	141,0699	-0,7547	1	-0,6380	-0,1511	-1,0680	1,1407	9,1513
89	0,9169	2625,4801	-3,0473	1	-0,9955	0,0733	0,3476	0,1208	9,2595
90	-0,2743	-1809,5898	1,3611	-1	0,8766	0,0013	0,2576	0,0663	9,1049
91	-0,2562	752,7615	-0,3634	1	-0,3482	-0,3330	0,7459	0,5564	8,8785
92	-1,0789	1224,0923	-1,5572	1	-0,9150	0,0227	0,5541	0,3070	8,7768
93	-0,5313	2658,1695	-3,3287	1	-0,9974	0,0745	1,4450	2,0880	8,8696
94	-1,3705	1998,1164	-2,9368	1	-0,9944	0,0726	0,9957	0,9914	8,3971
95	-0,9231	3530,9304	-4,5147	1	-0,9998	0,0759	-0,7782	0,6056	8,1134
96	0,8541	1457,9620	-2,6259	1	-0,9896	0,0695	-1,5284	2,3360	7,9773
97	1,5979	-2839,0215	2,7833	-1	0,9924	-0,0713	-0,1554	0,0241	8,2707
98	0,0841	-3498,7670	4,7282	-1	0,9998	-0,0760	0,6692	0,4478	8,2601
99	-0,7452	284,8896	0,6354	1	0,5618	-0,9041	-0,4589	0,2106	7,4856
100	-0,4452						Σ error	73,0973	

**ANEXO 4: RESULTADOS DE LA RNA EN EXCEL PARA LA VARIABLE  $T_g$**

Nº	RNA $T_g(k+1)$								
	STD	IN1B	IN2B	ON1B	ON2B	SUM2	DIF	DIFCUA	RESU
1	Peso w1	-0,9801	-0,9873						
2	Peso w2	2,6269	2,5610						
3	Peso w3	-2,0395	-1,9586						
4	Peso p	-20,3700	20,3271						
5	0,4608								
6	-0,7872								
7	0,7917	-4,1343	-4,0217	-0,9995	-0,9994	0,0455	1,5838	2,5085	84,1008
8	-1,5383	5,9886	5,8177	1,0000	1,0000	-0,0430	0,0370	0,0014	79,5319
9	-0,0800	-4,6538	-4,5647	-0,9998	-0,9998	0,0436	-0,4478	0,2005	79,8545
10	0,4914	0,2954	0,3515	0,2871	0,3377	1,0162	0,2305	0,0531	89,6218
11	0,7857	-0,2333	-0,2015	-0,2291	-0,1988	0,6261	0,9544	0,9108	88,7654
12	-0,3283	2,2519	2,1701	0,9781	0,9743	-0,1201	-0,9375	0,8789	74,6637
13	0,8174	-3,2995	-3,2175	-0,9973	-0,9968	0,0526	0,3461	0,1198	83,0121
14	-0,2935	3,0675	2,9923	0,9957	0,9950	-0,0569	0,4778	0,2283	82,7731
15	-0,5347	-0,4815	-0,5114	-0,4475	-0,4710	-0,4590	-0,0761	0,0058	78,5949
16	-0,3828	-0,3362	-0,3298	-0,3240	-0,3183	0,1297	1,7280	2,9859	80,2133
17	-1,5982	2,7780	2,6778	0,9923	0,9906	-0,0771	-0,5736	0,3291	76,2510
18	0,4965	-4,8358	-4,6876	-0,9999	-0,9998	0,0438	-0,0849	0,0072	75,4886
19	0,1287	2,6082	2,5975	0,9892	0,9890	-0,0472	-0,0930	0,0086	73,5333
20	0,0458	-0,2419	-0,2503	-0,2373	-0,2452	-0,1496	-0,3795	0,1440	71,8488
21	0,2299	-0,4747	-0,4600	-0,4420	-0,4301	0,2602	-0,7785	0,6060	74,2162
22	1,0386	-1,5594	-1,4908	-0,9153	-0,9035	0,2800	-1,4325	2,0520	76,9234
23	1,7125	-0,9895	-0,9210	-0,7571	-0,7264	0,6579	-0,4587	0,2104	83,7849
24	1,1166	1,2033	1,1733	0,8346	0,8253	-0,2250	-0,9014	0,8126	80,1198
25	0,6764	-0,1249	-0,1560	-0,1243	-0,1548	-0,6152	-1,0188	1,0380	80,5811
26	0,4036	-0,1406	-0,1605	-0,1396	-0,1591	-0,3902	1,3865	1,9224	87,3193
27	-1,7767	4,0208	3,8456	0,9994	0,9991	-0,0484	1,0427	1,0873	90,4203
28	-1,0911	-2,8374	-2,8116	-0,9932	-0,9928	0,0500	-0,1488	0,0221	89,2289
29	0,1988	-1,5303	-1,4295	-0,9105	-0,8916	0,4232	0,2485	0,0618	89,9032
30	0,1747	1,2353	1,2442	0,8441	0,8466	0,0154	-1,4126	1,9954	87,4529

31	1,4280	-2,6484	-2,5458	-0,9900	-0,9878	0,0883	0,6781	0,4598	87,9340
32	-0,5898	4,7828	4,6398	0,9999	0,9998	-0,0438	-1,3407	1,7974	87,8513
33	1,2968	-5,5937	-5,4603	-1,0000	-1,0000	0,0431	1,0446	1,0912	90,3594
34	-1,0016	6,0273	5,8652	1,0000	1,0000	-0,0430	1,5064	2,2692	89,2111
35	-1,5494	-0,7420	-0,8107	-0,6304	-0,6700	-0,7786	-0,4036	0,1629	79,6666
36	-0,3750	-2,3236	-2,2447	-0,9810	-0,9778	0,1074	0,2583	0,0667	84,8589
37	-0,1509	0,8413	0,8649	0,6865	0,6988	0,2205	0,2656	0,0705	84,9531
38	-0,0451	0,0629	0,0719	0,0628	0,0718	0,1793	-0,0452	0,0020	80,9959
39	0,2245	-0,4283	-0,4061	-0,4039	-0,3851	0,3986	-1,2411	1,5403	80,6203
40	1,6396	-2,7102	-2,5920	-0,9912	-0,9889	0,0900	-0,2736	0,0749	81,7867
41	0,3636	3,3455	3,2653	0,9975	0,9971	-0,0516	0,6298	0,3967	81,8322
42	-0,6814	0,7380	0,6471	0,6279	0,5697	-1,2100	0,4084	0,1668	78,8052
43	-1,6185	1,1545	1,0659	0,8192	0,7879	-0,6724	0,1777	0,0316	76,6410
44	-0,8501	-1,8498	-1,8071	-0,9517	-0,9475	0,1260	-1,2003	1,4407	79,4427
45	1,3263	-3,3520	-3,1771	-0,9976	-0,9965	0,0636	-1,3435	1,8051	79,7315
46	1,4072	1,4474	1,4801	0,8952	0,9015	0,0895	-0,3395	0,1153	82,8967
47	0,4290	1,5216	1,4541	0,9090	0,8965	-0,2926	-0,5418	0,2936	80,5985
48	0,2492	-0,7605	-0,7788	-0,6414	-0,6520	-0,1880	0,6840	0,4678	85,4916
49	-0,8719	2,0125	1,9225	0,9649	0,9581	-0,1792	-1,1148	1,2427	88,7012
50	0,9356	-4,4428	-4,3115	-0,9997	-0,9996	0,0446	1,5226	2,3183	91,0192
51	-1,4780	6,3266	6,1517	1,0000	1,0000	-0,0430	1,1630	1,3525	87,0442
52	-1,2059	-2,3400	-2,3470	-0,9816	-0,9819	0,0370	-0,8205	0,6732	84,9976
53	0,8575	-3,4681	-3,3087	-0,9981	-0,9973	0,0576	1,0145	1,0291	86,0040
54	-0,9568	5,3860	5,2608	1,0000	0,9999	-0,0431	0,4367	0,1907	82,4536
55	-0,4799	-2,3752	-2,3572	-0,9829	-0,9822	0,0548	-1,4885	2,2158	79,3457
56	1,5434	-3,4705	-3,3072	-0,9981	-0,9973	0,0580	-0,5984	0,3581	86,1316
57	0,6564	3,1859	3,1409	0,9966	0,9963	-0,0493	-0,2592	0,0672	89,6040
58	0,2099	-0,2166	-0,2539	-0,2133	-0,2486	-0,7095	0,1176	0,0138	79,1085
59	-0,8271	1,5950	1,5096	0,9209	0,9069	-0,3252	0,8771	0,7693	87,2822
60	-1,2023	0,0736	0,0293	0,0735	0,0293	-0,9011	0,1415	0,0200	78,4585
61	-1,0426	-0,2212	-0,2204	-0,2177	-0,2169	0,0246	0,0686	0,0047	84,1256
62	-0,0440	-1,4708	-1,3970	-0,8997	-0,8847	0,3439	-0,7786	0,6062	82,5293
63	1,1225	-1,3829	-1,2817	-0,8816	-0,8569	0,5391	-0,6294	0,3962	79,9856
64	1,1685	0,6084	0,6294	0,5430	0,5576	0,2733	-1,0377	1,0768	80,1772
65	1,3109	-0,7041	-0,6831	-0,6070	-0,5935	0,2992	0,5158	0,2661	85,0478
66	-0,2166	2,7401	2,6278	0,9917	0,9896	-0,0848	1,2966	1,6813	84,7301
67	-1,3815	0,9637	0,8568	0,7459	0,6946	-1,0753	-1,3387	1,7922	77,0830
68	0,2634	-3,9539	-3,8400	-0,9993	-0,9991	0,0467	0,6041	0,3649	85,5191
69	-0,5574	3,1827	3,1302	0,9966	0,9962	-0,0505	0,3809	0,1451	83,6378
70	-0,4313	-0,8426	-0,8427	-0,6872	-0,6873	0,0286	-1,2418	1,5420	81,1325

71	1,2704	-3,1777	-3,0425	-0,9965	-0,9955	0,0646	0,0646	0,0042	82,5966
72	0,0000	3,7598	3,6793	0,9989	0,9987	-0,0467	-0,3654	0,1335	83,7834
73	0,3187	-1,8950	-1,8784	-0,9558	-0,9543	0,0707	1,1388	1,2969	83,9106
74	-1,0681	3,0156	2,9082	0,9952	0,9941	-0,0660	-1,1942	1,4261	82,8788
75	1,1282	-5,4192	-5,2599	-1,0000	-0,9999	0,0432	1,3919	1,9373	86,0374
76	-1,3487	6,7612	6,5855	1,0000	1,0000	-0,0429	1,2577	1,5818	81,8753
77	-1,3006	-1,9959	-2,0204	-0,9637	-0,9654	0,0067	0,6295	0,3963	78,2729
78	-0,6228	-0,8245	-0,7795	-0,6775	-0,6524	0,5388	0,3177	0,1009	80,6827
79	0,2211	-0,8124	-0,7441	-0,6709	-0,6316	0,8272	-0,3735	0,1395	83,5777
80	1,2007	-1,2576	-1,1705	-0,8504	-0,8244	0,5641	0,1168	0,0137	75,8642
81	0,4472	2,0253	1,9808	0,9658	0,9626	-0,1050	-0,5828	0,3396	72,2959
82	0,4778	-0,9765	-0,9760	-0,7516	-0,7513	0,0372	0,4328	0,1873	75,9711
83	-0,3956	1,6237	1,5570	0,9252	0,9149	-0,2475	-1,2537	1,5718	77,2247
84	1,0062	-3,5598	-3,4558	-0,9984	-0,9980	0,0504	-1,6852	2,8398	78,2902
85	1,7356	-0,5088	-0,4318	-0,4690	-0,4068	1,2839	-0,2434	0,0592	88,2413
86	1,5273	0,4581	0,4601	0,4285	0,4302	0,0150	0,8971	0,8049	85,7609
87	-0,8822	4,1102	3,9258	0,9995	0,9992	-0,0478	0,7162	0,5129	84,4586
88	-0,7639	-2,2562	-2,2709	-0,9783	-0,9789	0,0293	0,4460	0,1989	85,1378
89	-0,4167	-0,2923	-0,2694	-0,2843	-0,2630	0,4437	1,0133	1,0267	89,9117
90	-0,5695	0,8157	0,8025	0,6727	0,6655	-0,1763	0,0166	0,0003	79,5573
91	-0,1929	-0,6943	-0,6694	-0,6007	-0,5846	0,3541	-1,3172	1,7349	77,1343
92	1,6713	-3,3571	-3,2051	-0,9976	-0,9967	0,0603	-1,2936	1,6734	79,3246
93	1,3539	1,8180	1,8189	0,9486	0,9487	-0,0390	-0,8665	0,7508	82,0949
94	0,8275	0,2307	0,1965	0,2267	0,1940	-0,6750	0,4514	0,2038	78,9275
95	-1,1264	3,1441	2,9888	0,9963	0,9949	-0,0701	0,2586	0,0669	84,1897
96	-0,3287	-3,0994	-3,0578	-0,9959	-0,9956	0,0499	0,3756	0,1410	86,7641
97	-0,3257	0,9046	0,9081	0,7186	0,7202	0,0026	1,2693	1,6111	85,4194
98	-1,2666	2,0500	1,9713	0,9674	0,9619	-0,1523	-1,6047	2,5749	79,5018
99	1,4524	-5,9703	-5,7671	-1,0000	-1,0000	0,0430	-0,5145	0,2647	82,0267
100	0,5576						Σ error	72,1614	

**ANEXO 5: RESULTADOS DE LAS ECUACIONES FENOMENOLÓGICAS  
PARA LAS VARIABLES  $X$  y  $T_g$**

Calculado con ecuaciones fenomenológicas					
Nº	$X(k+1)$	$T_g(k+1)$	Nº	$X(k+1)$	$T_g(k+1)$
1	9,5567	65,8229	51	10,3665	99,2462
2	7,1095	74,3701	52	9,0464	99,0548
3	6,5485	80,1618	53	10,0193	90,5077
4	8,0468	80,0470	54	10,0060	88,3390
5	10,0846	88,8493	55	8,0652	79,0264
6	10,6973	97,0137	56	13,1904	86,3617
7	9,7745	99,5013	57	10,4473	85,4687
8	10,0063	78,5161	58	10,6596	95,1002
9	10,8136	78,3885	59	9,4241	90,5077
10	10,7419	87,7649	60	9,9332	85,7876
11	6,8826	84,5757	61	11,1095	86,7444
12	7,3098	77,2404	62	11,5523	90,1250
13	7,2188	70,9895	63	9,9718	98,1618
14	8,0819	78,5161	64	10,9639	100,5857
15	8,9824	78,8988	65	10,0982	100,5219
16	8,7869	81,5140	66	9,6783	94,7812
17	11,1027	77,6231	67	9,8187	92,5488
18	10,5428	79,5367	68	9,6721	96,3121
19	9,8613	86,4254	69	9,6786	97,6516
20	9,5021	84,2568	70	10,1844	99,0548
21	8,9577	80,6210	71	7,4865	96,1207
22	10,7398	80,6848	72	8,4849	83,0448
23	10,8921	94,7812	73	7,9348	87,8925
24	10,2391	93,4418	74	11,4668	75,7734
25	9,3490	84,1292	75	7,6029	77,8783

<b>26</b>	9,6432	97,5240	<b>76</b>	9,3883	76,0285
<b>27</b>	8,3059	91,1455	<b>77</b>	10,1624	78,4523
<b>28</b>	9,0521	98,0343	<b>78</b>	10,7713	77,3042
<b>29</b>	9,5359	97,9067	<b>79</b>	9,6751	77,8783
<b>30</b>	9,4629	98,6721	<b>80</b>	10,1151	79,4729
<b>31</b>	8,7957	98,0981	<b>81</b>	10,4447	80,5572
<b>32</b>	10,5265	101,0959	<b>82</b>	9,9826	81,0037
<b>33</b>	9,6031	99,9478	<b>83</b>	9,8647	77,4956
<b>34</b>	10,6244	99,7565	<b>84</b>	10,5419	84,1292
<b>35</b>	9,9681	92,3574	<b>85</b>	9,9365	95,1002
<b>36</b>	7,7210	86,4254	<b>86</b>	9,8760	83,9378
<b>37</b>	9,5898	90,2525	<b>87</b>	9,8575	74,5615
<b>38</b>	10,2928	87,8925	<b>88</b>	8,5642	84,0654
<b>39</b>	11,0061	89,9974	<b>89</b>	10,3126	80,1107
<b>40</b>	10,6626	95,7380	<b>90</b>	9,5603	84,3205
<b>41</b>	11,7682	96,1207	<b>91</b>	9,5683	78,8350
<b>42</b>	11,6390	94,0796	<b>92</b>	8,6626	86,9995
<b>43</b>	9,3134	87,2546	<b>93</b>	9,1696	90,8266
<b>44</b>	11,1667	84,3205	<b>94</b>	7,9587	82,7259
<b>45</b>	11,1162	93,3142	<b>95</b>	8,0211	67,2262
<b>46</b>	10,5129	94,1434	<b>96</b>	8,6270	80,1745
<b>47</b>	9,9913	93,5055	<b>97</b>	10,5449	83,7465
<b>48</b>	10,9683	96,3759	<b>98</b>	8,8321	80,5572
<b>49</b>	11,7291	95,8018	<b>99</b>	8,2023	82,9811
<b>50</b>	10,7936	98,4170	<b>100</b>	8,5128	89,7422

## ANEXO 6: ARTIFICIOS MATEMÁTICOS PARA OBTENER ECUACIÓN 8

$$-\left[\ln(X_c - X_{k+1} - \phi N_s) - \ln(X_c - X_k - \phi N_s)\right] = \frac{1}{\phi}(3600 - 0)$$

$$\ln \frac{X_c - X_k - \phi N_s}{X_c - X_{k+1} - \phi N_s} = \frac{3600}{\phi}$$

Aplicando antilogaritmo natural:

$$e^{\ln \frac{X_c - X_k - \phi N_s}{X_c - X_{k+1} - \phi N_s}} = e^{\frac{3600}{\phi}}$$

$$\frac{X_c - X_k - \phi N_s}{X_c - X_{k+1} - \phi N_s} = e^{\frac{3600}{\phi}}$$

Sustituimos el valor de  $\phi = 10 \text{ min} = 600 \text{ s}$ , tiempo de retención:

$$\frac{X_c - X_k - 600N_s}{X_c - X_{k+1} - 600N_s} = e^6$$

$$X_c - X_{k+1} - 600N_s = \frac{X_c - X_k - 600N_s}{e^6}$$

$$-X_{k+1} = \frac{X_c - X_k - 600N_s}{e^6} - X_c + 600N_s$$

$$X_{k+1} = X_c - 600N_s - \frac{X_c - X_k - 600N_s}{e^6}$$

$$X_{k+1} = \frac{e^6 X_c - e^6 \times 600N_s - X_c + X_k + 600N_s}{e^6}$$

$$X_{k+1} = \frac{(e^6 - 1)X_c - (e^6 - 1)600N_s + X_k}{e^6}$$

$$X_{k+1} = \frac{(e^6 - 1)}{e^6}(X_c - 600N_s) + \frac{1}{e^6} X_k$$

## ANEXO 7: ANÁLISIS DIMENSIONAL A ECUACIONES 6, 7, 8 y 9

### Ecuación 6:

$$\frac{\partial X}{\partial t} = -V_s \frac{\partial X}{\partial z} - N_s$$

$$\frac{\text{kg agua}}{\text{kg sólido} \cdot \text{s}} [=] \frac{\cancel{\text{m}}}{\text{s}} \times \frac{\text{kg agua}}{\text{kg sólido} \cdot \cancel{\text{m}}} [=] \frac{\text{kg agua}}{\text{kg} \cdot \text{s}}$$

$$\frac{\text{kg agua}}{\text{kg sólido} \cdot \text{s}} [=] \frac{\text{kg agua}}{\text{kg sólido} \cdot \text{s}} [=] \frac{\text{kg agua}}{\text{kg} \cdot \text{s}}$$

### Ecuación 7:

$$C_g \frac{G_s}{V_g} \frac{\partial T_g}{\partial t} = -U_a A (T_g - T_s) - C_g G_s \frac{\partial T_g}{\partial z} + \frac{L_s}{V_s} N_s \lambda$$

$$\frac{\cancel{\text{kg}} \cdot \cancel{\text{s}}}{\text{m} \cdot \cancel{\text{s}}} \times \frac{\text{J}}{\cancel{\text{kg}} \cdot \cancel{\text{°C}}} \times \frac{\cancel{\text{°C}}}{\text{s}} [=] \frac{\text{J}}{\text{s} \cdot \cancel{\text{m}} \cdot \cancel{\text{m}^2} \cdot \cancel{\text{°C}}} \times \cancel{\text{m}^2} \times \cancel{\text{°C}} [=] \frac{\cancel{\text{kg}}}{\text{s}} \times \frac{\text{J}}{\cancel{\text{kg}} \cdot \cancel{\text{°C}}} \times \frac{\cancel{\text{°C}}}{\text{m}} [=] \frac{\cancel{\text{kg}} \cdot \cancel{\text{s}}}{\text{m} \cdot \cancel{\text{s}}} \times \frac{1}{\text{s}} \times \frac{\text{J}}{\cancel{\text{kg}}}$$

$$\frac{\text{J}}{\text{m} \cdot \text{s}} [=] \frac{\text{J}}{\text{m} \cdot \text{s}} [=] \frac{\text{J}}{\text{m} \cdot \text{s}} [=] \frac{\text{J}}{\text{m} \cdot \text{s}}$$

### Ecuación 8:

$$X_{k+1} = \frac{(e^6 - 1)(X_c - 600N_s)}{e^6} + \frac{1}{e^6} X_k$$

$$\frac{\text{kg agua}}{\text{kg sólido}} [=] \frac{\text{kg agua}}{\text{kg sólido}} [=] \frac{\text{kg agua}}{\text{kg sólido} \cdot \cancel{\text{s}}} \times \cancel{\text{s}} [=] \frac{\text{kg agua}}{\text{kg sólido}}$$

$$\frac{\text{kg agua}}{\text{kg sólido}} [=] \frac{\text{kg agua}}{\text{kg sólido}} [=] \frac{\text{kg agua}}{\text{kg sólido}} [=] \frac{\text{kg agua}}{\text{kg sólido}}$$

**Ecuación 9:**

$$T_{gk+1} = \frac{m}{n}(1 - e^{-3600n}) + T_{gk}e^{-3600n}$$

Donde:

$$m = T_g \times a \times U_a + b \times T_c + c \times N_s$$

$$n = a \times U_a + b$$

A su vez:

$$a = \frac{A \times V_g}{G_s \times C_g}; \quad b = \frac{V_g}{z}; \quad c = \frac{V_g}{G_s \times C_g} \times \frac{L_s}{V_s} \times \lambda$$

Por lo tanto:

$$a = \frac{A \times V_g}{G_s \times C_g}; \quad b = \frac{V_g}{z}; \quad c = \frac{V_g}{G_s \times C_g} \times \frac{L_s}{V_s} \times \lambda$$

$$a[=] \frac{\frac{m^2 \times \frac{m}{s}}{kg} \times \frac{J}{kg \cdot ^\circ C}}{s}; \quad b[=] \frac{\frac{m}{s}}{m}; \quad c[=] \frac{\frac{m}{s}}{kg} \times \frac{kg}{J} \times \frac{J}{m} \times \frac{J}{kg}$$

$$a[=] \frac{\frac{m^2 \times \frac{m}{s}}{\cancel{kg}} \times \frac{J}{\cancel{kg} \cdot ^\circ C}}{\cancel{s}}; \quad b[=] \frac{\cancel{m}}{\cancel{s}}; \quad c[=] \frac{\frac{\cancel{m}}{\cancel{s}}}{\cancel{kg}} \times \frac{\cancel{kg}}{\cancel{s}} \times \frac{\cancel{J}}{\cancel{m}} \times \frac{\cancel{J}}{\cancel{kg}}$$

$$a[=] \frac{m^3 \cdot ^\circ C}{J}; \quad b[=] \frac{1}{s}; \quad c[=] ^\circ C$$

Entonces:

$$m = T_g \times a \times U_a + b \times T_c + c \times N_s$$

$$m [=] \text{ }^\circ\text{C} \times \frac{\text{m}^3 \cdot \text{ }^\circ\text{C}}{\text{J}} \times \frac{\text{J}}{\text{s} \cdot \text{m}^3 \cdot \text{ }^\circ\text{C}} [=] \frac{1}{\text{s}} \times \text{ }^\circ\text{C} [=] \text{ }^\circ\text{C} \times \frac{\text{kg agua}}{\text{kg s\u00f3lido} \cdot \text{s}}$$

$$m [=] \text{ }^\circ\text{C} \times \frac{\cancel{\text{m}^3} \cdot \cancel{\text{ }^\circ\text{C}}}{\cancel{\text{J}}} \times \frac{\cancel{\text{J}}}{\text{s} \cdot \cancel{\text{m}^3} \cdot \cancel{\text{ }^\circ\text{C}}} + \frac{1}{\text{s}} \times \text{ }^\circ\text{C} + \text{ }^\circ\text{C} \times \frac{\cancel{\text{kg agua}}}{\cancel{\text{kg s\u00f3lido}} \cdot \text{s}}$$

$$m [=] \frac{\text{ }^\circ\text{C}}{\text{s}} [=] \frac{\text{ }^\circ\text{C}}{\text{s}} [=] \frac{\text{ }^\circ\text{C}}{\text{s}}$$

Ahora n:

$$n = a \times U_a + b$$

$$n [=] \frac{\text{m}^3 \cdot \text{ }^\circ\text{C}}{\text{J}} \times \frac{\text{J}}{\text{s} \cdot \text{m}^3 \cdot \text{ }^\circ\text{C}} [=] \frac{1}{\text{s}}$$

$$n [=] \frac{\cancel{\text{m}^3} \cdot \cancel{\text{ }^\circ\text{C}}}{\cancel{\text{J}}} \times \frac{\cancel{\text{J}}}{\text{s} \cdot \cancel{\text{m}^3} \cdot \cancel{\text{ }^\circ\text{C}}} [=] \frac{1}{\text{s}}$$

$$n [=] \frac{1}{\text{s}} [=] \frac{1}{\text{s}}$$

Finalmente:

$$T_{gk+1} = \frac{m}{n} (1 - e^{-3600n}) + T_{gk} e^{-3600n}$$

$$T_{gk+1} [=] \frac{\frac{\text{ }^\circ\text{C}}{\cancel{\text{J}}}}{\frac{\cancel{\text{J}}}{1}} [=] \text{ }^\circ\text{C}$$

$$T_{gk+1} [=] \text{ }^\circ\text{C} [=] \text{ }^\circ\text{C}$$