


**PREDICCIÓN CON REDES NEURONALES DE UN PROCESO DE SECADO  
DE ÑAME (*Dioscorea rotundata*) EN HORNO MICROONDAS.**



**ANDERLEY DE JESÚS MACEA HOYOS  
DARÍO SEGUNDO MARTELO SALGADO**

**UNIVERSIDAD DE CÓRDOBA  
FACULTAD DE INGENIERÍA  
INGENIERÍA DE ALIMENTOS  
BERASTEGUI**

**2016**

**PREDICCIÓN CON REDES NEURONALES DE UN PROCESO DE SECADO  
DE ÑAME (*Dioscorea rotundata*) EN HORNO MICROONDAS.**

**ANDERLEY DE JESÚS MACEA HOYOS**

**DARÍO SEGUNDO MARTELO SALGADO**

**Trabajo de grado presentado como modalidad de tesis, como parte de los requisitos  
para optar al título de ingeniero de alimentos.**

**DIRECTOR:**

**EMIRO LÓPEZ ACOSTA. I.A, M.Sc.**

**UNIVERSIDAD DE CÓRDOBA**

**FACULTAD DE INGENIERÍA**

**INGENIERÍA DE ALIMENTOS**

**BERASTEGUI**

**2016**

El Jurado Calificador del Trabajo no será responsable de las ideas emitidas por los autores (Artículo 46, Resolución No. 060 de 2015, Consejo Directivo)

**Nota de aceptación**

---

---

---

---

---

---

---

---

---

FABÍAN ORTEGA QUINTANA

---

RAMIRO TORRES GALLO

**Dedicatoria, Anderley:**

Primeramente a Dios por haberme dado la sabiduría, la fortaleza y la salud para llegar a éste punto y alcanzar ésta meta.

A mis padres Carmen y Emilso, por ser los pilares fundamentales de mi vida. Por su apoyo, consejos, comprensión, amor y por los principios y valores que me inculcaron para lograr ser la persona que soy.

A mis hermanos por acompañarme en los buenos momentos y más aún en los momentos difíciles. Por creer en mí, ayudarme y apoyarme siempre. En especial a mi hermana Rosa, porque gracias a su aporte económico pude lograr éste objetivo.

A mi sobrina Daniela por llegar a iluminar mi vida y convertirse en mi razón principal de superación. Te amo princesa.

**Dedicatoria, Darío:**

A Dios, por mantener la promesa de estar siempre a mi lado.

A Rosmery, mi madre, por haberme dado la vida y todas esas esas enseñanzas, y en especial, haberme mostrado el camino de Dios; A Tía María, por ser esa mujer que siempre ha merecido el título de Madre por su apoyo y amor incondicional. A Domingo, mi padre, por ser quien con su esmero y sacrificio me permitió alcanzar esta meta.

A mis hermanos: Heblim, Carla, Lorna y Pedro, quienes con su permanente apoyo y amor me han permitido seguir sin desfallecer. También, al mejor obsequio que hasta ahora me han dado: Sebastián, Jerónimo y Sofía.

A dos hermanos más que me regaló Dios: Fray y Orlando, por esa amistad sincera e incondicional.

A mis amigos, en especial 318, y todos los compañeros que sufrieron y rieron a mi lado.

A mi familia y todos aquellos que de alguna forma aportaron su granito de arena para que avanzara en este camino.

## **AGRADECIMIENTOS**

En primer lugar, es preciso agradecer por todas las bendiciones que Dios nos ha dado, por las cuales hoy se consolida este trabajo.

A los amigos, compañeros, cuerpo docente, familiares y todos aquellos que con su apoyo, sonrisa y voz de aliento nos instaron a seguir adelante hasta alcanzar esta meta.

A Emiro López Acosta a quien le estamos especialmente agradecidos por el esfuerzo de apoyarnos en la labor de culminar este proceso.

A Fabián Ortega Quintana, quien con su apoyo incondicional a pesar de la distancia, nos guio con sus consejos.

## TABLA DE CONTENIDO

	Pág.
1. INTRODUCCIÓN.....	16
2. ESTADO DEL ARTE.....	18
2.1. El ñame.....	18
2.1.1. Producción mundial del ñame.....	18
2.1.2. Producción de ñame en Colombia.....	19
2.1.3. Usos del ñame.....	20
2.2. El secado.....	21
2.2.1. Modelado del secado.....	21
2.3. Secado por microondas.....	22
2.4. Redes Neuronales Artificiales.....	22
2.4.1. Fundamentos biológicos de las Redes Neuronales Artificiales.....	22
2.4.2. Redes Neuronales Artificiales.....	24
2.4.2.1. La neurona artificial.....	24
2.4.2.2. Arquitectura de la red neuronal artificial.....	26
2.4.2.3. Aprendizaje en las redes neuronales.....	27
2.4.2.4. Modelos de redes neuronales artificiales.....	28



3.	METODOLOGÍA.....	30
3.1.	Tipo de investigación.....	30
3.2.	Localización del proyecto.....	30
3.3.	Variables.....	30
3.4.	Procedimiento.....	31
3.4.1.	Secado en microondas .....	31
3.4.2.	Entrenamiento de la red neuronal.....	32
4.	RESULTADO Y DISCUSIÓN.....	35
4.1.	Selección de la función de transferencia.....	35
4.2.	Selección del número de neuronas en la capa oculta.....	36
4.3.	Validación de la red neuronal.....	40
4.4.	Comparación del modelo de redes neuronales obtenido con un modelo matemático convencional.....	41
5.	CONCLUSIONES.....	45
6.	RECOMENDACIONES.....	47
	BIBLIOGRAFÍA.....	48
	ANEXOS.....	54

## LISTA DE TABLA

	Pág.
Tabla 1. Variables de proceso.....	30
Tabla 2. EMC de las redes neuronales artificiales evaluando las funciones de transferencia tangente hiperbólica, Lineal y logarítmica sigmoideal con diferente número de neurona en la capa oculta.....	35
Tabla 3. EMC y número de iteraciones de entrenamiento de las redes neuronales al variar el número de neuronas en la capa oculta.....	37
Tabla 4. Valores de EMC y R2 de la validación de la red neuronal artificial seleccionada.....	41
Tabla 5. Parámetros del modelo de Midilli and Cukuk.....	42
Tabla 6. EMC del modelo de Midilli and Cukuk para cada uno de los tratamientos	43
Tabla 7. EMC y R <sup>2</sup> de la validación del modelo de Midilli and Cukuk para cada tratamiento.....	44

## LISTA DE FIGURAS

	Pág.
Figura 1. Descripción de una célula nerviosa típica.....	23
Figura 2. Esquema de una neurona artificial típica.....	25
Figura 3. Funciones de activación más habituales: a) lineal; b) escalón; c) lineal a tramos; d) sigmoidea.....	26
Figura 4. Clasificación de algunos modelos de redes neuronales artificiales.....	29
Figura 5. Error medio cuadrático vs. número de neuronas en la capa oculta...	37
Figura 6. Comparación del EMC de los datos de entrenamiento y test vs. Número de neuronas en la capa oculta.....	39
Figura 7. Comparación del EMC de los datos de entrenamiento y test vs. Número de neuronas en la capa oculta (más de 20 neuronas).....	40

## LISTA DE ANEXOS

Anexo 1.	Paso a paso de entrenamiento y validación de la red neuronal artificial.....	55
Anexo 2.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 50,9 g Potencia 420 W.....	64
Anexo 3.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 59,92 g Potencia 420 W.....	65
Anexo 4.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 72,23 g Potencia 420 W.....	66
Anexo 5.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 50,84 g Potencia 560 W.....	67
Anexo 6.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 61,83 g Potencia 560 W.....	68

Anexo 7.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 69,84 g Potencia 560 W.....	69
Anexo 8.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 52,54 g Potencia 700 W.....	79
Anexo 9.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 60,72 g Potencia 700 W.....	71
Anexo 10.	Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 69,69 g Potencia 700 W.....	72

## RESUMEN

El objetivo de este trabajo fue evaluar la capacidad predictiva de las redes neuronales artificiales en un proceso de secado de ñame en hornos microondas. Para lo cual se sometieron a secado muestras de ñame cortadas en rodajas, con masas iniciales de 50 g, 60 g y 70 g, a potencias de 420 W, 560 W y 700 W. Se evaluó la influencia del número de neuronas en la capa oculta y la función de transferencia de las mismas: función tangente hiperbólica, lineal y logarítmica sigmoideal. La red seleccionada se sometió a una validación comparando los datos simulados con datos reales, así mismo, se procedió al modelado con el modelo de Midilli and Cukuk y se comparó la capacidad de predicción de este modelo a la capacidad del modelo de redes neuronales. El número de neuronas seleccionada en la capa oculta fue 5 y la función de transferencia fue la función tangente hiperbólica, debido a que arrojó el más alto ajuste a los datos, con un error medio cuadrático inferior a 0,001. Las redes neuronales mostraron alta capacidad predictiva frente a datos desconocidos con valores de error medio cuadrático inferiores a 0,01 y  $R^2$  superior a 0,99. A pesar del buen ajuste del modelo convencional (valores error medio cuadrático entre 0,01 y 0,1), el modelo de redes neuronales presentó una mayor capacidad predictiva frente a nuevos datos.

## **ABSTRACT**

The purpose of this study was to evaluate the predictive ability of artificial neural networks in a drying process yam in microwave ovens. For which they were subjected to drying yam samples sliced, with initial mass of 50 g, 60 g and 70 g, to microwave powers of 420 W, 560 W and 700 W. the influence of the number of neurons in the hidden layer and the transfer function thereof was evaluated: hyperbolic tangent function, lineal and logarithmic sigmoidal; the selected network underwent a validation by comparing the simulated it with real data, likewise, proceeded to modeling Midilli and Cukuk model's and the predictive ability of this model to the ability of neural network model was compared. The number of selected neurons in the hidden layer was 5 and the transfer function was the hyperbolic tangent function, since yielded the highest setting data, with an average mean square error less than 0.001. Neural networks showed high predictive ability against unknown data, with values below 0.01 mean square error and R<sup>2</sup> greater than 0.99. Despite the good fit the conventional model (mean square error values between 0.01 and 0.1), the neural network model showed greater predictive capacity versus new data.

## 1. INTRODUCCIÓN

El ñame (*Dioscorea rotundata*), en conjunto con otros tubérculos, en Colombia es considerado como producto básico dentro de la costumbre alimenticia, en especial en la población de la Costa Atlántica (Andrade et al 2012; Montes et al 2008). Colombia se encuentra entre los doce países del mundo con mayor producción de ñame, esta producción en el país se concentra en la región Caribe, con una participación del 90% (Reina 2012). Su alto contenido de humedad lo hace altamente perecedero en fresco, y el poco desarrollo de tecnologías de procesamiento, obliga un alto consumo en esta presentación y altas pérdidas de poscosechas (Andrade et al 2012; Morales 2010; Montes et al 2008).

Actualmente se utilizan diversos tipos de procesos tecnológicos para la conservación de productos agroindustriales, entre los más utilizados se encuentra el proceso de secado, que resulta ser una técnica que facilita obtener un producto con características similares al mismo en estado fresco. Además se consigue aumentar la vida útil del producto, por ende, el tiempo aprovechable del mismo (García 2013).

Además de las tecnologías convencionales usadas para el secado, surge en la actualidad un grupo de tecnologías conocidas como emergentes para mejorar sus resultados o reemplazarlas en los procesos, entre estas se encuentra el secado en hornos microondas,



el cual ha arrojado resultados óptimos en tiempo de secado y calidad del producto final (Ninaquispe 2013; Della 2010).

En este sentido, el uso del secado en hornos microondas es estudiada como técnica con diversos fines en los productos agrícolas: disminuir la humedad del producto (Ninaquispe 2013) y para la determinación de la humedad los mismos (García 2012). El horno microondas usado como tecnología para el secado de productos agroindustriales representa una serie de ventajas frente a las tecnologías convencionales, entre las cuales se pueden encontrar mejoras en el proceso de difusión de calor y materia, disminución de la temperatura superficial, mejora en la calidad del producto final (Della 2010)

El modelado del proceso de secado permite predecir el mejor proceso y ofrece la posibilidad de establecer el contenido final de humedad de los productos agrícolas (Ocampo 2006). Estudios en torno al secado de frutos y vegetales han determinado que es un proceso difícil de describir, debido a la complejidad de los fenómenos internos y externos que ocurren durante él (Montes et al, 2008).

Por su parte, las redes neuronales artificiales, a diferencia de los procedimientos convencionales de modelización de los procesos térmicos, no necesitan conocer de antemano las propiedades físicas que gobiernan dentro del alimentos el proceso de difusión de calor y masa, por lo tanto es una forma efectiva de modelar matemáticamente el proceso, eliminando la dificultad de las variaciones que presentan las propiedades físicas durante el calentamiento y la eliminación de la humedad (Vásquez y Lescano 2010; Luera y Minim 2001; Tomezak y Kaminski 2001).

## **2. ESTADO DEL ARTE**

### **2.1. El ñame**

El ñame, específicamente *Dioscorea* rotundata, hace parte de un conjunto de aproximadamente 600 especies perteneciente al género *Dioscorea*, que tienen origen en diversos continentes: África, América y Asia (Reina 2012). En Colombia las especies de mayor cultivo son la *D. alata* y *D. rotundata* conocidas con los nombres vulgares ñame criollo y ñame espino, respectivamente. Estas se han constituido como un producto de consumo tradicional en la región Caribe (Morales 2010).

#### **2.1.1. Producción mundial del ñame**

Según la FAO (Agronet 2013), en las estadísticas mostradas para el año 2013, Nigeria, Ghana y Costa de Marfil son en ese orden los tres países de mayor producción de ñame de todas especies, de los 50 que a nivel mundial se reportan como mayores productores, con el 61,9%, 12,3% y 10,0% de la producción total respectivamente. Según este mismo reporte, entre Haití, Cuba, Colombia, Brasil, Venezuela, Panamá, República Dominicana, Costa Rica, Puerto Rico y Guyana, países latinoamericanos, aportaron el 2,7% de la producción de ñame.

De esta forma Colombia se ubica en el puesto número 12 de los países de mayor de producción de ñame con 363.036 Toneladas.

### **2.1.2. Producción de ñame en Colombia**

La producción de ñame para el 2013, según reporte de la FAO (Agronet 2013), alcanza una producción aproximada de 314.991 Toneladas, distribuida en un área de 29.381 hectáreas. Es decir presentando un rendimiento de cosecha de 10,7 toneladas por hectárea sembrada.

En el periodo comprendido entre 2000 y 2013, la región Caribe registró una producción promedio anual de ñame de 283.744 toneladas, lo que representa una alta concentración de la producción nacional en esta región, con una participación del 92,9% de la producción total del país. De igual forma, es en esta región en donde se presenta la mayor concentración de tierras destinadas para el cultivo de con una participación del 95,48% del área nacional destinada para este fin (FAO, Agronet 2013).

Entre los departamentos con mayor producción se encuentran Bolívar con el 44,2% de la producción nacional, seguido por Córdoba con el 36,2%, Sucre con el 7,8% y Antioquia con el 5,3%; los otros departamentos reportan valores inferiores al 2,5% de la producción nacional. Algunos departamentos de otras regiones que reportan producción de ñame, con una menor participación, son: Chocó, Vaupés, Nariño y Casanare (FAO, Agronet 2013).

Así mismo, son los departamentos de Bolívar, Córdoba y Sucre los de mayor participación en el área destinada para la cosecha de ñame, con valores de 39,64%, 39,10% y 8,8% respectivamente (FAO, Agronet 2013).

En el departamento de Córdoba se destacan por su volumen de producción los municipios de Moñitos (18.240 toneladas), Ciénaga de Oro (16.400 toneladas), Sahagún (13.800 toneladas), Lórica (12.750 toneladas) y Chinú (10.160 toneladas) (FAO, Agronet 2013).

### **2.1.3. Usos del ñame**

La producción mundial de ñame está destinada casi en su totalidad a abastecer el mercado interno de los países productores y por lo general es comercializado sin ningún procesamiento industrial (Montes 2008).

Tradicionalmente, el ñame se ha usado para la alimentación humana, siendo en varias partes del mundo, y en Colombia en la región Caribe, un producto básico de la dieta alimenticia de la población (Beltrán 2001).

El ñame se consume como hortaliza cocida y en la elaboración de harina para la preparación de purés, sopas o pastas; también se utiliza en la elaboración de hojuelas y como sustitutos de las papas fritas, dado que el sabor es muy parecido al de la papa dulce o batata (Guízar 2009).

En la Región Caribe, en Colombia, es diversificado su uso, se puede presentar en preparaciones como el mote de queso, como también en el típico dulce de ñame (Reina 2012).

## **2.2. El secado**

El secado es un proceso unitario en el que se presenta transferencia de masa y energía simultáneamente, de forma tal que al transferir calor a un cuerpo se ocasiona en él una remoción de agua u otro compuesto a través de la evaporación. El proceso se realiza por diversas razones, en la mayoría de los casos se hace con el fin de aumentar la vida útil del producto, como es en el caso de los alimentos (Montes et al 2009).

La deshidratación es una técnica adecuada para preservar los productos agrícolas y a la vez para reducir los costos de empaque, transporte y almacenamiento. Consiste en remover la humedad, lo cual impide el crecimiento de bacterias y hongos que deterioran la calidad del alimento (Ocampo 2006).

### **2.2.1. Modelado del secado**

Estudios en torno al secado de frutos y vegetales han determinado que es un proceso difícil de describir, debido a la complejidad de los fenómenos internos y externos que ocurren durante éste (Sandoval et al 2006).

Los modelos de secado basados en la teoría de difusión de líquidos han sido preferidos por los investigadores en el área de secado de alimentos, dado que permiten predecir el mejor proceso y también ofrecen herramientas para predecir las condiciones de almacenamiento y empaque; además, ayudan a establecer el contenido final de humedad de los productos agrícolas y los requisitos del proceso de secado (Vega y Lemus 2006).

### **2.3. Secado por microondas**

Las microondas son parte del espectro electromagnético y en consecuencia, se componen de campos magnéticos y eléctricos. En el calentamiento de alimentos por microondas, los campos eléctricos interactúan con las moléculas de agua e iones en el alimento, generando calor en forma volumétrica en el interior del mismo, este calor suele ser no uniforme, y gracias a él se producen gradientes de temperatura que ocasiona la difusión del agua. Este influye en las características del alimento mismo haciendo que sus propiedades fisicoquímicas varíen (Della 2010).


A medida que se aumenta la potencia de trabajo de las microondas se seca con mayor rapidez. La potencia, en conjunto con el tiempo, determina cómo va a secarse un alimento. El secado por microondas implica controlar la temperatura del producto, la potencia por unidad de masa del producto ( $\text{watts g}^{-1}$ ) y el tiempo de contacto (Soysal et al 2006).

### **2.4. Redes Neuronales Artificiales**

#### **2.4.1. Fundamentos biológicos de las Redes Neuronales Artificiales**

En el desarrollo de las diferentes actividades que el hombre y en general los animales llevan a cabo cada día, interviene, y está determinada en gran medida, por la actividad neuronal. Esta actividad se apoya en los órganos que perciben la información del exterior, luego esta es transportada hasta el sistema nervioso, en donde se procesa, se almacena y se transforma la información recibida, y luego es enviada a los órganos efectores que reciben la información y la interpretan en forma de movimiento y otras acciones (Isasi 2004).

La unidad estructural del sistema nervioso es la neurona, se estima que en cada cerebro hay 100.000 millones de ellas, cada una de estas neuronas toma la información, la procesa, y la envía a otra neurona, este proceso lo hace a través de la emisión de impulsos electro-químicos. Una figura que describe la forma como se constituye el cuerpo de una neurona se muestra en la Figura 1. El proceso que se desarrolla en un cerebro comienza con la recepción de la información, proveniente del exterior o de otras neuronas, luego se procede a la integración de toda la información recibida en un código de activación y luego es transmitida a otras neuronas o a las células efectoras (Isasi 2004).



**Figura 1** Descripción de una célula nerviosa típica. Fuente: Romero, 2016.

La comunicación de cada neurona básicamente está dada a través de las sinapsis, que no es más que la unión del axón de una neurona con una dendrita de otra, y es por este puente por el que se transmite cada una de las señales que permiten la difusión de la información. El gran número de estas sinapsis existentes en un cerebro permite la

constitución de una extensa red neuronal, se estima que cada neurona posee cerca de 10.000 sinapsis (Isasi 2004).


#### **2.4.2. Redes Neuronales Artificiales**

Las redes neuronales artificiales tratan de emular la actividad cerebral biológica, en general consiste en una serie de unidades denominadas neuronas conectadas entre sí. (Martín y Serrano, 1995) Básicamente, las redes neuronales artificiales están constituidas por una capa de neuronas de entrada conformadas por las variables independientes que intervienen en el proceso. Esta primera capa de neuronas no procesa los impulsos recibidos, si no que los transfiere a una segunda capa de neuronas (neuronas ocultas) para su procesamiento. Por el contrario, las neuronas de la capa oculta son las encargadas de extraer la información de la variable independiente y transferirla hacia la capa de neuronas de salida, equivalente a las variables dependientes del proceso (Millán et al 2001).

##### **2.4.2.1. La neurona artificial**

La neurona artificial es un elemento que posee un estado interno, llamado nivel de activación, y recibe señales, sea de otras neuronas o del exterior, que le permiten cambiar de estado, determinado por la función de activación. En la Figura 2 se puede observar la estructura básica de una neurona artificial (Isasi 2004; Martín y Serrano 1995).






**Figura 2.** Esquema de una neurona artificial típica. Fuente: Autor

El funcionamiento de una neurona, básicamente consiste en la recepción de cada una de las señales de entradas  $x_1, x_2, \dots, x_n$ ; cada una de estos valores de entrada serán multiplicadas por un valor asignado a cada una de las sinapsis, llamado peso,  $w_{j1}, w_{j2}, \dots, w_{jn}$ . Posteriormente, se aplicará un proceso de sumatoria a los resultados de las productos entre la señal de entrada y su respectivo peso; lo cual pasará a través de la función de activación que producirá el proceso de transformación de la señal recibida, y será luego emitido el resultado a través de cada una de las conexiones que posea la neurona (Isasi 2004; Martín y Serrano 1995).

Las funciones de activación más empleadas en las redes neuronales artificiales suelen ser, la función lineal, la función escalón, la función lineal a tramos y la función sigmoidea (logarítmica sigmoideal y tangente hiperbólica). En la Figura 3 pueden observarse los grafos de estas funciones (Isasi 2004; Martín y Serrano 1995).



**Figura 3.** Funciones de activación más habituales: a) lineal; b) escalón; c) lineal a tramos; d) sigmoidea. Fuente: Martín y Serrano, 1995

#### 2.4.2.2. Arquitectura de la red neuronal artificial

Se denomina arquitectura a la topología, estructura o patrón de conexionado de una red neuronal. En general, y de modo análogo a lo que sucede en el cerebro, las neuronas se suelen agrupar en unidades estructurales que se denominan capas. El conjunto de una o más capas conforma la red neuronal. Se distinguen distintos tipos de capas: la capa de entrada, está compuesta por neuronas que reciben datos o señales del entorno, la capa de salida es aquella cuyas neuronas proporcionan la respuesta de la red neuronal; las capas ocultas no tienen conexión directa con el entorno, proporcionando a la red neuronal grados de libertad adicionales (Millán y Ostojich 2006; Isasi 2004; Martín y Serrano 1995).

Se pueden distinguir diferentes tipos de arquitecturas, las cuales pueden variar según el número de capas; el número de neuronas en cada capa; la dirección del flujo de información, según este se puede diferenciar arquitecturas hacia adelante (feedforward) o arquitecturas recurrentes (feedback), en la primera los datos solo fluyen en un sentido, en cambio en la segunda se da realimentación (Isasi 2004; Martín y Serrano 1995).

#### **2.4.2.3. Aprendizaje en las redes neuronales**

En el funcionamiento de las redes neuronales se tienen dos fases: entrenamiento y operación. En la primera se da un proceso mediante el cual se ajustan los pesos sinápticos hasta conseguir que la red se adapte a la situación presentada. Este proceso se basa en el aprendizaje al que es sometida la red con los datos de la situación que se le presentan (Martín y Serrano 1995).

De este proceso se encuentran principalmente dos tipos: el aprendizaje supervisado y el no supervisado.

Según Martín y Serrano (1995) en el aprendizaje supervisado se presentan a la red un conjunto de patrones, junto con la salida deseada u objetivo. La red iterativamente ajusta sus pesos hasta que su salida tiende a ser la deseada, utilizando para ello información detallada del error que en cada paso comete. De este modo, la red neuronal artificial es capaz de estimar relaciones entrada/salida sin necesidad de proponer una cierta forma funcional de partida.

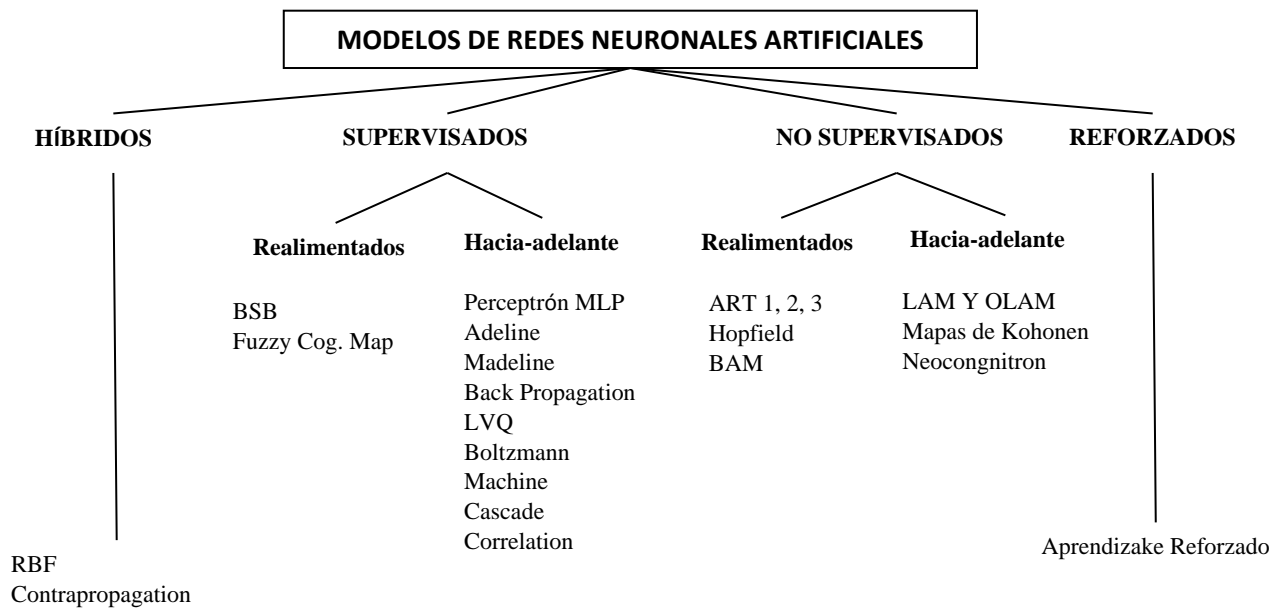
También, según Martín y Serrano (1995) en el aprendizaje no supervisado se presentan a la red multitud de patrones, pero sin adjuntar la respuesta deseada. El sistema, por

medio de la regla de aprendizaje definida, debe reconocer en ellos regularidades, extraer rasgos, estimar densidades de probabilidad o agruparlos según su similitud.

Además, se distinguen dos tipos de entrenamientos menos difundidos, los cuales son relaciones entre los dos mencionados. Aprendizaje híbrido, que consiste en la coexistencia de ambos, y el aprendizaje reforzado, que se sitúa a medio camino del aprendizaje supervisado y no supervisado, y en el cual se proporciona una única señal de error (Isasi 2004; Martín y Serrano 1995).

#### **2.4.2.4. Modelos de redes neuronales artificiales**

Existen un gran número de modelos de redes neuronales artificiales, en la Figura 3 se distingue una clasificación de algunos de estos modelos (Isasi 2004; Martín y Serrano 1995). En la actualidad no son muchos los modelos reconocidos, esto dado a la efectividad que han arrojado algunos de ellos sobresaliendo sobre el gran conjunto existente (Saldaña et al 2010).



**Figura 4.** Clasificación de algunos modelos de redes neuronales artificiales. Fuente: Martín y Serrano, 1995

### 3. METODOLOGÍA

#### 3.1. Tipo de investigación

Es una investigación de tipo experimental.

#### 3.2. Localización del proyecto

Para el proceso de secado se tomó como materia prima ñame (*Discorea rotundata*) cortado en rodajas, proveniente de los cultivos del departamento de Córdoba, evitando el uso de los que presenten daños. El secado se realizó en el laboratorio de Análisis de alimentos de la sede Berástegui de la Universidad de Córdoba, Ciénaga de Oro, Departamento de Córdoba, Colombia, con una temperatura ambiente promedio de 30°C, humedad relativa 80%, una altura de 20 m.s.n.m. y una presión atmosférica promedio de 752 mmHg.

#### 3.3. Variables

**Tabla 1.** Variables del proceso

<b>Variables independiente</b>	<b>Variables dependiente</b>
Masa inicial de la muestra	Masa de la muestra en el tiempo
Potencia de secado	Tiempo de secado

### **3.4. Procedimiento**

#### **3.4.1. Secado en microondas**

Previo al secado del ñame (*D. rotundata*) se adecuó la muestra, esta fue adquirida en el corregimiento de Berástegui del municipio de Ciénaga de Oro del departamento de Córdoba, con coordenadas astronómicas de latitud norte 75°54' de longitud oeste de Greenwich de 8°30', con temperaturas que oscilan entre 35 y 38 °C y presión atmosférica de 750 a 760 Torr. Para la adecuación se cortaron chips con dimensiones de 3 cm de diámetro y 1 cm de espesor.

Para el secado se usó un horno microondas con una frecuencia de 2450 MHz de marca Haceb modelo HM-1.1. Las muestras (con masas de 50, 60 y 70 g) se colocaron uniformemente en el plato del microondas, se procedió al ajuste de la potencia (420, 560 y 720 W) para proceder con el secado. Cada 30 segundos se evaluó la masa de la muestra, para ello se retiraba del horno el plato de la cámara de secado, para el registro del peso se usó balanza analítica Mettler PS4000 con precisión  $\pm 0,01$  gramo, y luego era regresado el plato con la muestra a la cámara de secado. Este procedimiento se repite hasta cuando no se aprecie variación en el peso de la masa. Se obtuvo un total de 27 unidades experimentales que corresponden a tres réplicas de cada uno de los tratamientos que resultan al combinar las tres masas de ñame (50, 60 y 70 g) y las tres potencias (420, 560 y 720 W) evaluadas.

### 3.4.2. Entrenamiento de la red neuronal

Los datos obtenidos de la variable dependiente en el proceso de secado, masa (g), fueron transformados a razón de humedad (MR) mediante la Ecuación 1., donde M corresponde al contenido de humedad en cada tiempo,  $M_e$  corresponde al contenido de humedad en el equilibrio,  $M_o$  corresponde al contenido inicial de humedad.

Ecuación 1. Razón de humedad

$$MR = \frac{M - M_e}{M_o - M_e}$$

Se tomaron dos de las tres réplicas de cada tratamiento para el entrenamiento y los datos fueron distribuidos en dos conjuntos así:

Entrada:

- potencia de secado
- masa inicial de la muestra
- tiempo de secado

Objetivo:

- Razón de humedad (MR)

De esta forma fueron presentados a cada una de las estructuras de las redes neuronales creadas para su evaluación. Para la creación de las diferentes estructuras de las redes neuronales en las que se varió el número de neuronas en la capa oculta y la función de



transferencia de las mismas, se usó el Toolbox de Matlab ® versión 2009, con licencia otorgada a la Universidad de Córdoba, para la construcción de redes neuronales artificiales. Para la selección de la mejor estructura se utilizó el Error Medio Cuadrático (EMC), el número de iteraciones y el sobreentrenamiento de la red.

Las diferentes estructuras de redes neuronales se constituyeron con las siguientes características en común:

- Número de capas ocultas: 1
- Número de neuronas en la capa de entrada: 3
- Número de neuronas en la capa de salida: 1
- Estructura: feed-forward, back propagation.
- Algoritmo de aprendizaje: Levenberg-Marquardt

La validación de la red neuronal seleccionada consistió en la simulación de la misma en las condiciones de la tercera réplica de cada experimento que se reservó, esta simulación se realizó con la ayuda de la herramienta Simulink ® del paquete informático Matlab ®. Los valores simulados fueron contrastados con los valores reales. Se realizó una regresión lineal (Muñoz, 2015) y se determinó el CME en cada uno de los nueve conjuntos de datos.

El modelado matemático de los datos se realizó ajustando al modelo de Midilli and Kucuk, Ecuación 2, basado en los resultados obtenidos por Jiménez y Romero (2014) quienes identifican este modelo como el que mejor ajuste muestra al proceso de secado de ñame en horno microondas en las mismas condiciones presentadas en este estudio,

haciendo uso de la hoja de cálculo de Excel ®, con las dos réplicas de cada tratamiento usadas para entrenar la red neuronal artificial. Se procedió a hacer una simulación bajo las condiciones de la tercera réplica de cada tratamiento y se contrastó con los valores reales. Se determinó el CME y el  $R^2$  para los nueve casos y posteriormente se comparó con los resultados obtenidos en la validación de la red neuronal artificial.

Ecuación 2. Modelo de Midilli and Cukuk

$$MR = a * Exp(-kt^n) + b$$

En el Anexo 1 puede observarse el paso a paso seguido en el procedimiento de entrenamiento y validación de la red neuronal.

## 4. RESULTADOS Y DISCUSIÓN

### 4.1. Selección de la función de transferencia

Los valores obtenidos de EMC fueron inferiores a 0,08 en todos los casos. Las funciones: lineal y Logarítmica sigmoideal arrojaron valores de EMC entre 0,01 y 0,02, y entre 0,07 y 0,08 respectivamente. Los valores inferiores se obtuvieron con la función de transferencia tangente hiperbólica que presentó EMC entre 0,0001 y 0,002. En La tabla 2 se puede observar los valores de EMC para cada una de las funciones de trasferencia con las variaciones del número de neuronas en la capa oculta. El EMC para la función tangente hiperbólica fue en todos los casos inferior a los presentados con las otras funciones.

**Tabla 2.** EMC de las redes neuronales artificiales evaluando las funciones de transferencia tangente hiperbólica, Lineal y logarítmica sigmoideal con diferente número de neurona en la capa oculta.

Función de transferencia	Neuronas en la capa oculta de la red			
	2	5	10	20
Tangente hiperbólica	0,001970	0,000885	0,000171	0,000068
Lineal	0,016200	0,017000	0,015400	0,016300
Logarítmica sigmoideal	0,071000	0,077100	0,074500	0,075500


El ajuste obtenido con la función tangente hiperbólica, se debe a la característica no lineal de esta y la capacidad que tiene de manejar un equilibrio entre la linealidad y no linealidad en el comportamiento aprendido (Argente et al, 2001). Así mismo, Sánchez (2006) y Del Brío (2002) indican que como comprobó Cybenko (1989) las funciones Sigmoidales tienen características de aproximador universal.

#### **4.2. Selección del número de neuronas en la capa oculta**

En la capa oculta fueron seleccionadas 5 neuronas, con base en los valores obtenidos de EMC y número de iteraciones de entrenamiento que pueden observarse en la Tabla 3, que evidencian que la disminución del error de ajuste no es significativa, por encima de este número de neurona, contrastando con el número de iteraciones que debe hacerse para alcanzar el estado óptimo de la configuración. Se puede ver que la disminución porcentual del EMC pasa de ser un 45 % al aumentar de 2 a cinco neuronas, a solo el 19% al aumentar de 5 a 10 neuronas en la capa oculta. Ajustes a modelos no lineales con pocas neuronas en la capa oculta fue encontrado por Robles (2010) en el pronóstico para el rendimiento del trigo, así mismo, Sánchez y Elanis (2006) indican que redes neuronales con un número inferior a 10 neuronas en la capa oculta ha arrojado resultados óptimos en los procesos de predicción y modelación de procesos no lineales. En la Figura 4 puede observarse la gráfica de la evaluación del CME conforme aumenta el número de neuronas en la capa oculta.

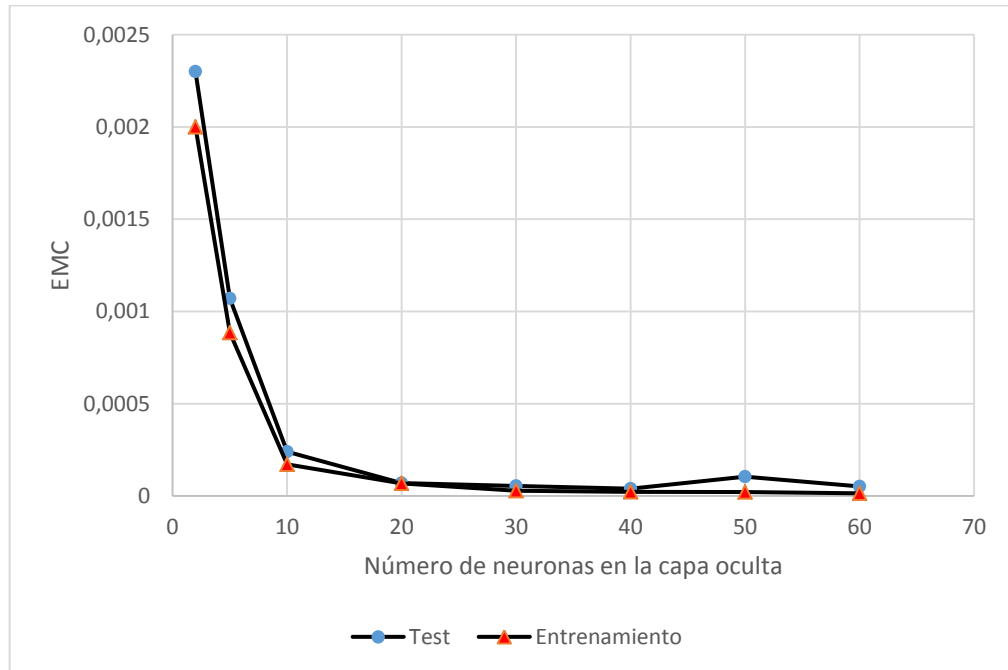
**Tabla 3.** EMC y número de iteraciones de entrenamiento de las redes neuronales al variar el número de neuronas en la capa oculta

Número de neuronas	EMC	Disminución del CME	Número de iteraciones de entrenamiento
2	0,00197000		6
5	0,00088500	45%	59
10	0,00017100	19%	126
20	0,00006800	40%	76
30	0,00002870	42%	159
40	0,00002190	76%	166
50	0,00002150	98%	139
60	0,00001450	67%	73
70	0,00000786	54%	236
80	0,00000515	66%	111
90	0,00001525	296%	96
100	0,00002010	132%	90



**Figura 5.** Error medio cuadrático vs. número de neuronas en la capa oculta

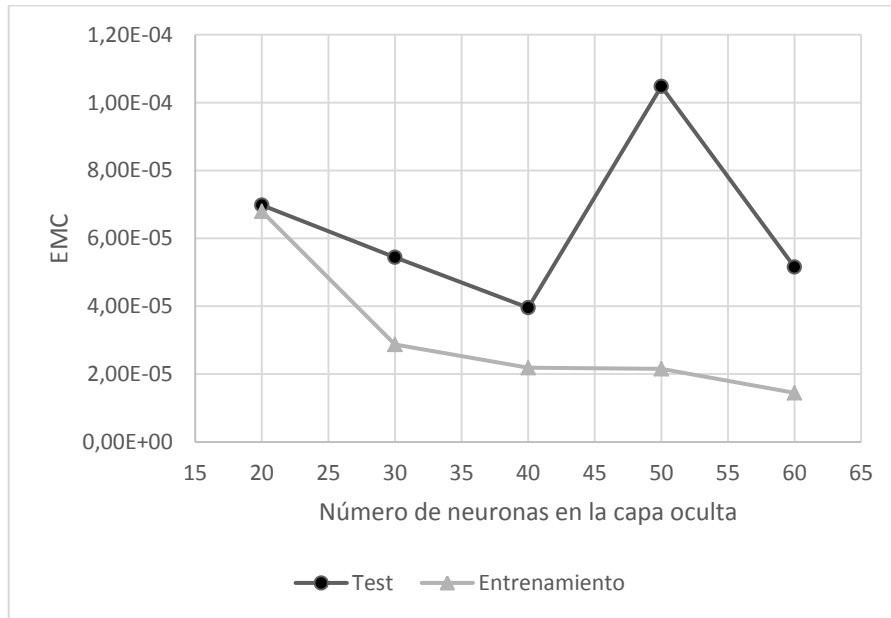
Otro criterio tenido en cuenta para la selección del número de neuronas corresponde al sobreentrenamiento o sobre ajuste de la red, una característica no deseable en una red neuronal artificial puesto que implica una pérdida en la capacidad de generalización, es decir, que la red neuronal artificial pierde la capacidad de predecir el comportamiento del proceso cuando se presenten nuevos datos que difieran de los valores usados para el entrenamiento, aun estando dentro del rango de estudio. En la Figura 6 se observa la comparación de los EMC de los datos usados para el Entrenamiento y de los datos usados como Test durante el aprendizaje de la red, en donde se observa un aumento en el EMC de los datos del Test mientras se presenta una disminución del EMC de Entrenamiento, lo cual es indicio de sobreentrenamiento. Se puede detallar en la Figura 7 (que muestra el EMC de Entrenamiento y de Test para más de 20 neuronas en la capa oculta) que a partir de 30 neuronas en la capa oculta se presenta una diferencia entre los valores de CME de Entrenamiento y Test, sugiriendo que a partir de este valor se produce el sobreentrenamiento. De esta forma se puede descartar la selección de redes neuronales con un número mayor a 20 neuronas en la capa oculta dado que este elevado ajuste a los datos presentados para su entrenamiento lo limita frente a nuevos datos presentados.



**Figura 6.** Comparación del EMC de los datos de entrenamiento y test vs. Número de neuronas en la capa oculta

La red fue generada como un modelo de Simulink® (Ver Anexo 1) con el fin de realizar las diferentes simulaciones. Las características de la red neuronal seleccionada fueron:

- Número de capas: 3
- Número de neuronas en la capa de entrada: 3 (Variables: Masa inicial, Potencia y tiempo de secado)
- Número de neuronas en la capa oculta: 5
- Número de neuronas en la capa de salida: 1 (Variable: razón de humedad MR)
- Función de transferencia de las neuronas: Tangente hiperbólica.



**Figura 7.** Comparación del EMC de los datos de entrenamiento y test vs. Número de neuronas en la capa oculta (más de 20 neuronas)

### 4.3. Validación de la red neuronal

Al presentar datos desconocidos a la red neuronal con el fin de evaluar la capacidad de predicción, se evidenció una respuesta altamente satisfactoria, en la Tabla 4 se observan los valores de EMC obtenidos a la hora de contrastar los datos reales y los obtenidos con la simulación de la red neuronal. En todos los casos se encontraron EMC inferiores a 0,01 y un  $R^2$  superiores a 0,99 en una prueba de comparación de los datos reales vs los datos simulados. Se evidencia que los errores inferiores se obtuvieron en la predicción de los procesos a 560 W, en orden ascendente en los valores del EMC, se encuentran los procesos a potencias de 700 W y 420 W. En los Anexos 2, 3 y 4 se pueden observar las curvas de razón de humedad versus tiempo correspondientes a los tratamientos



realizados a una potencia de 420 W, así mismo, para los tratamientos a una potencia de 560 W y de 700 W pueden verse en los anexos 5, 6 y 7 y 8, 9 y 10 respectivamente, comparando los datos reales con los obtenidos de la simulación del modelo de red neuronal.

**Tabla 4.** Valores de EMC y  $R^2$  de la validación de la respuesta de MR de la red neuronal artificial seleccionada frente a datos reales.

Potencia	Masa inicial	CME	$R^2$
420	50,9	0,00120000	0,9983
420	59,92	0,00404868	0,9961
420	72,23	0,00150000	0,9980
560	50,84	0,00044632	0,9987
560	61,83	0,00016538	0,9995
560	69,84	0,00029611	0,9995
700	52,54	0,00070000	0,9984
700	60,72	0,00075161	0,9983
700	69,69	0,00073456	0,9974

#### **4.4. Comparación del modelo de redes neuronales obtenido con un modelo matemático convencional**

Los datos se ajustaron al modelo de Midilli and Cukuk, en la Tabla 5 se observan las constantes del modelo para cada uno de los tratamientos. En la Tabla 6 se observan el EMC para cada uno de los modelos, con valores inferiores a 1. El mejor ajuste se obtuvo con el tratamiento a 700 W con valores del EMC entre 0,01 y 0,1. Al comparar estos valores con los obtenidos en el modelo de la red neuronal artificial, se logra evidenciar que este último tiene un mejor ajuste a los datos usados para el modelamiento. Bustamante et al (2016) identificó en un modelo basado en redes neuronales mayor

efectividad que en los modelos estadísticos convencionales y de series de tiempo aplicado a modelo de simulación de inventario.

**Tabla 5.** Parámetros del modelo de Midilli and Cukuk

<b>Potencia</b>	<b>420</b>			<b>560</b>			<b>700</b>		
<b>Masa</b>	<b>50</b>	<b>60</b>	<b>70</b>	<b>50</b>	<b>60</b>	<b>70</b>	<b>50</b>	<b>60</b>	<b>70</b>
<b>a</b>	1,2149	1,3217	1,4701	1,0575	1,0708	1,2526	0,9704	0,9934	0,9960
<b>k</b>	0,1117	0,1596	0,1644	0,0552	0,0941	0,1556	0,0567	0,0406	0,0523
<b>n</b>	1,2856	0,8085	0,8362	1,4159	1,4142	0,9594	1,7600	1,7719	1,6209
<b>b</b>	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

La validación del modelo para cada uno de los tratamientos con datos reales, muestra un ajuste aceptable con valores de CME entre 0,0001 y 0,1 y  $R^2$  entre 0,85 y 0,99. En la Tabla 7 pueden observarse los diferentes valores de CME y de  $R^2$  para cada uno de los casos. El mejor ajuste se obtuvo en el tratamiento con potencia de 700 W. Al comparar estos resultados con los obtenidos en la validación de la red neuronal artificial seleccionada, se observa que el modelo de red neuronal tiene una mayor capacidad de predicción que el modelo convencional. Sánchez y Laqui (2015) encontraron que los modelos de redes neuronales artificiales mostraron comparativamente mejor desempeño en materia de predicción frente a un modelo estocástico para la predicción de caudales en fuentes hidricas. Martínez (2016) encontró una alta capacidad predictiva de las redes neuronales aplicada a la transferencia de masa en un proceso de deshidratación osmótica de frutas.

**Tabla 6.** EMC del modelo de Midilli and Cukuk para cada uno de los tratamientos

<b>Potencia (Watt)</b>	<b>Masa inicial (gramos)</b>	<b>CME</b>
420	50	0,31618398
420	60	0,54382473
420	70	0,75853371
560	50	0,09435085
560	60	0,10758757
560	70	0,33280701
700	50	0,01246527
700	60	0,01688526
700	70	0,02682168

**Tabla 7.** EMC y R2 de la validación del modelo de Midilli and Cukuk para cada tratamiento

<b>Potencia</b>	<b>Masa inicial</b>	<b>CME</b>	<b>R2</b>
420	50,9	0,0321	0,8511
420	59,92	0,0128	0,9307
420	72,23	0,0144	0,8900
560	50,84	0,0134	0,9974
560	61,83	0,0215	0,9204
560	69,84	0,0096	0,9273
700	52,54	0,0008	0,9951
700	60,72	0,0010	0,9934
700	69,69	0,0027	0,9825

## 5. CONCLUSIONES

Una red neuronal artificial con una capa oculta y cinco neuronas en ella, presenta un buen ajuste del proceso de secado de ñame en hornos microondas, presentando un EMC de 0,00197.

La función tangente hiperbólica como función de transferencia en las neuronas ocultas de la red neuronal artificial le confiere a la red neuronal artificial un mayor ajuste al proceso de secado de ñame en horno microondas que al usar la función lineal y Logarítmica sigmoideal

La red neuronal artificial tiene una alta capacidad de predicción frente a nuevos datos, siempre y cuando estos se encuentren dentro del rango de los datos usado para el entrenamiento. Mostrando valores de EMC inferiores a 0,01 y  $R^2$  superiores a 0,99

El modelo de red neuronal artificial presenta un mayor ajuste y una mayor capacidad predictiva para el proceso de secado de ñame en hornos microondas, mostrando valores

de EMC inferiores a 0,01, que el modelo de Midill and Cukuk, para el cual se obtuvieron valores de EMC entre 0,01 y 0,1

El modelo de redes neuronales, siendo uno el obtenido, presenta la ventaja de generalizar la modelización de las diferentes combinaciones de las variables estudiadas, a diferencia del modelado convencional en el cual se obtiene un modelo para cada una de las combinaciones de potencia y masa inicial.

## **6. RECOMENDACIONES**

Ampliar el rango de las variables independientes, con el fin de verificar la efectividad en la generalización de las redes neuronales, tal como el observado en este trabajo.

Estudiar el uso de otras herramientas de optimización a la hora de seleccionar los pesos durante el entrenamiento de la red neuronal artificial.

Evaluar, y modelar con redes neuronales artificiales, los posibles efectos en los cambios del producto final (color, detrimento de nutrientes, entre otros), teniendo en cuenta las variables estudiadas

## BIBLIOGRAFÍA

AGRONET. 2013. Anuario estadístico del sector agropecuario. Consultado 04 de mayo de 2016. Disponible en: [http://207.239.251.112/www/htm3b/public/Anuario/ANUARIO\\_2013.pdf](http://207.239.251.112/www/htm3b/public/Anuario/ANUARIO_2013.pdf).

ANDRADE, R; *et al.* 2012. Almacenamiento de trozos de ñame (*Dioscorea rotundata Poir*) en atmósferas modificadas. Información Tecnológica Vol. 23(4), 65-72 (2012). Versión on-line ISSN 0718-0764 Disponible en [http://www.scielo.cl/scielo.php?pid=S0718-07642012000400008&script=sci\\_arttext](http://www.scielo.cl/scielo.php?pid=S0718-07642012000400008&script=sci_arttext)

APAZA, G. BUSTAMANTE, E. QUINCHO, E. FLORES, J. VARGAS, E. SALINAS, E. 2016. Modelo de Simulación de Inventario Basado en Redes Neuronales Artificiales Supervisadas y Algoritmos Genéticos para Optimizar el Stock de Medicamentos de la Clínica Ricardo Palma. Revista de Investigación Business Intelligence, 1(2).

ARGENTE, E. SAPENA, O. BOTTI, V. 2001. Aplicación de una red neuronal para la predicción de la reacción catalítica isomerización del n-Octano, Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA'01), Actas CAEPIA-TTIA-2001, pp. 213-222, (2001)



ARGENTE, E. SAPENA, O. BOTTI, V.2003. Application of Neural Networks to Stock Prediction in Pool Companies Applied Artificial Intelligence, Taylor & Francis, Vol. 17, pp. 661-673.

BELTRÁN, J. 2001. Perspectivas en el cultivo del ñame. Informe de Coyuntura Económica Regional de Sucre (ICER), tercer trimestre (2001). Dane- Banco de la Republica. P. 37-40.

DEL BRÍO, B. SANZ, A. 2002. Redes neuronales y Sistemas difusos, Alfaomega Grupo Editor.

DELLA, P. 2010. Secado de alimentos por métodos combinados: Deshidratación osmótica y secado por microondas y aire caliente. Tesis de Maestría en Tecnología de los Alimentos. Facultad Regional Buenos Aires. Argentina. Disponible en: <http://posgrado.frba.utn.edu.ar/investigacion/tesis/MTA-2010-Rocca.pdf>

GARCÍA, A. 2013. Análisis comparativo de la cinética de deshidratación osmótica y por flujo de aire caliente (*Ananas comosus*, variedad Cayensa lisa). Revista Ciencias Técnicas Agropecuarias. vol. 22 no.1 San José de las Lajas ene. - mar. 2013. Disponible en: [http://sciELO.org/SciELOViewAction.jsp?pid=S2071-00542013000100011&script=sci\\_arttext](http://sciELO.org/SciELOViewAction.jsp?pid=S2071-00542013000100011&script=sci_arttext)

GARCÍA, C. *et al.* 2012. Uso de horno microondas en la determinación de contenido de humedad: yuca, ñame y plátano. Revista Biotecnología en el Sector Agropecuario y Agroindustrial. vol.10 no.1 Popayán Jan./June 2012.

GUÍZAR, A. 2009. Obtención y caracterización física y química del almidón de Camote de Cerro (*Dioscorea spp.*). Michoacán, 2009. Trabajo de grado (Maestro en Ciencias en Producción Agrícola Sustentable). Instituto Politécnico Nacional. Centro

Interdisciplinario de Investigación para el Desarrollo Integral Regional Michoacán. P. 18-21.

ISASI, P; GALVAN, I. 2004. Redes neuronales artificiales. Un enfoque práctico. Madrid: Editorial Pearson educación. P 5 – 16

JIMENEZ, J; ROMERO, F. 204. Evaluación de la cinetica de secado y rehidratación de chips de ñame (*Dioscórea rotundata*) secadas en horno microondas. Tesis de grado. Ingeniería de Alimentos. Facultad de Ingenierías. Universidad de Córdoba.

LUERA W; MINIM L. 2001. Aplicación de redes neuronales artificiales en la modelización del tratamiento térmico de alimentos. Ciencia y Tecnología Alimentaria 2001381-88. Disponible en: <http://www.redalyc.org/articulo.oa?id=72430102>. Fecha de consulta: 18 de agosto de 2014.

MARTIN, B; SERRANO, C. 1995. Fundamentos de las redes neuronales artificiales: hardware y software. Zaragoza, España.

MARTÍNEZ, L. GONZÁLEZ, L. y MIRANDA, M. 2015. Sistema de predicción financiera para hoteles mediante Redes Neuronales Artificiales/System of financial prediction for hotels intervening Neuronal Artificial Networks. Retos Turísticos, 14(1).

MARTÍNEZ, C. VELÁSQUEZ, J. 2011. Análisis de dependencias no lineales utilizando redes neuronales artificiales. Rev. Fac. Ing. Univ. Antioquia N.º 60 pp. 182-193. Septiembre, 2011

MILLÁN, F. *et al.*, 2001. Modelado matemático de isotermas de adsorción de humedad en alimentos usando redes neuronales artificiales. Interciencia Vol. 26 N° 5. Disponible en [http://www.interciencia.org/v26\\_05/millan.pdf?origin=publication\\_detail](http://www.interciencia.org/v26_05/millan.pdf?origin=publication_detail).

MILLÁN, F; OSTOJICH, Z. 2006. Predicción mediante redes neuronales artificiales de la transferencia de masa en frutas osmóticamente deshidratadas. Interciencia Venezuela. Disponible en [http://www.scielo.org.ve/scielo.php?script=sci\\_arttext&pid=S0378-18442006000300011&lng=es&nrm=iso&tlng=es](http://www.scielo.org.ve/scielo.php?script=sci_arttext&pid=S0378-18442006000300011&lng=es&nrm=iso&tlng=es).

MONTES, E; et al. 2009. Modelado de las isoterms de desorción del ñame (*Dioscorea rotundata*). Revistas Universidad Nacional de Colombia. P 148.

MONTES, E. *et al.* 2008. Modelado de la cinética de secado de ñame (*dioscorea rotundata*) en capa delgada. REVISTA INGENIERÍA E INVESTIGACIÓN VOL. 28 No. 2. P. 45-52

MORALES, E. (2010). Fogón Caribe: la historia de la gastronomía del Caribe colombiano. Bogotá: editorial La Laguna Ciega. P. 159.

MUÑOZ, E. Y SEIJAS, C. 2015. Análisis Comparativo de Ajuste en Entrenamiento de Redes Neuronales artificiales a partir de las Librerías Open NN y ALGLIB. La Granja. Revista de Ciencias de la Vida, 21(1).

NINAQUISPE, V. 2013. Secado del tarwi (*Lupinus mutabilis*) por métodos combinados: deshidratación osmótica y microondas con aire caliente. Agroindustrial science. Universidad Nacional de Trujillo.

OCAMPO, A. 2006. Modelo cinético del secado de la pulpa de mango. Revista EIA, Escuela de Ingeniería de Antioquia. Envigado, Colombia. ISSN 1794-1237. N° 5. P. 119-128. Disponible en: <http://redalyc.uaemex.mx/src/inicio/ArtPdfRed.jsp?iCve=14921690>.

OCHOA, C. 2016. Red neuronal artificial en respuesta a predicciones de parámetros de transferencia de masa (pérdida de humedad y ganancia de sólidos) durante la deshidratación osmótica de frutas. *Acta Agronómica*, 65(4).

REINA, Y. 2012. El cultivo del ñame en Colombia. Documentos de trabajo sobre economía regional. Banco de la república. Centro de estudios regionales. CEER. Cartagena. ISSN 1692-3715. Num. 168. P. 2-21.

ROBLES, A. JÖNS, S. ROBLES, N. & ASCENCIO, D. 2010. Pronósticos para el Rendimiento Del Trigo Usando Redes Neuronales Artificiales, *Conciencia Tecnológica*, nº 40, pp. 25-28.

ROMERO, R. DUNRÁN, H. LARA, P. PÉREZ, F. OVIEDO, F. PACHECO, A. 2016. Use of artificial neural networks for prediction of the convective heat transfer coefficient in evaporative mini-tubes. *Ingeniería Investigación y Tecnología*, volumen 17, N° 1, , p. 23-34

SAGÑAY, N. 2009. Control de calidad de frutilla (*fragaria vesca*) deshidratada por método de microondas a tres potencias. Riobamba, Ecuador. 2009. Trabajo de grado (Bioquímico Farmacéutico). Escuela Superior Politécnica de Chimborazo. Facultad de Ciencias. Escuela de Bioquímica y Farmacia. P. 38-42.

SALDAÑA, A. *et al.* 2010. Pronósticos para el Rendimiento Del Trigo Usando Redes Neuronales Artificiales. *Conciencia Tecnológica* No. 40, Julio-Diciembre.

SÁNCHEZ, E. ALANIS, A. 2006. Redes neuronales Conceptos fundamentales y aplicaciones a control automático, Madrid, España: Pearson Prentice Hall.

SÁNCHEZ, M. Y LAQUI, W. 2015. Predicción de caudales medios mensuales del Río Huancané utilizando modelos de redes neuronales. In Anales Científicos (Vol. 70, No. 2, pp. 196-206).

SANDOVAL, S et al. 2006. Rapidez de Secado. Reducida: Una aplicación de secado convectivo de plátano Roatán. Revista Mexicana de Ingeniería Química. Vol. 5 N° 1, p. 35-38.

SOYSAL, Y. et al. 2006. Microwave drying of parsley modeling, kinetics and energy aspects, Biosystems Engineering, p 403–4

TOMEZAK, E. KAMINSKI K. 2001. Drying kinetics simulation by means of artificial neural networks. Handbook of Conveying and Handling of Particulate Solids. Elsevier Science. P. 569-580

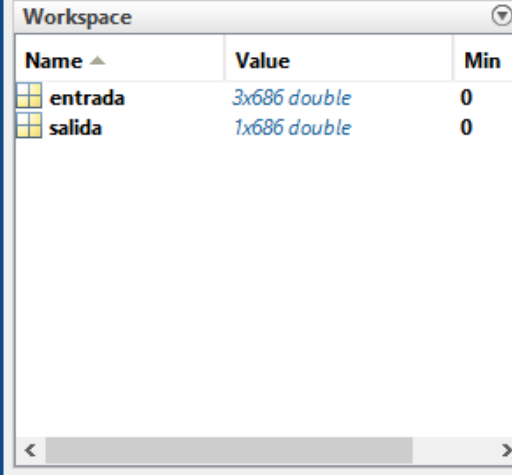
VÁSQUEZ, V. LEZCANO C. 2010. Predicción por redes neuronales artificiales de la calidad fisicoquímica del vinagre de melaza de caña por efecto de tiempo-temperatura de alimentación a evaporador–destilador flash. Scientia Agropecuaria. Universidad Nacional de Trujillo. Disponible en <http://www.revistas.unitru.edu.pe/index.php/scientiaagrop/article/view/17>.

VEGA, A. LEMUS, R. 2006. Modelado de la cinética de secado de papaya chilena (*basconcellea pubescens*). Información tecnológica. Vol. 17, N° 3, p. 23-31.

## **ANEXOS**


## Anexo 1. Paso a paso de entrenamiento y validación de la red neuronal artificial.

Paso 1. Creación de variables en Workspace



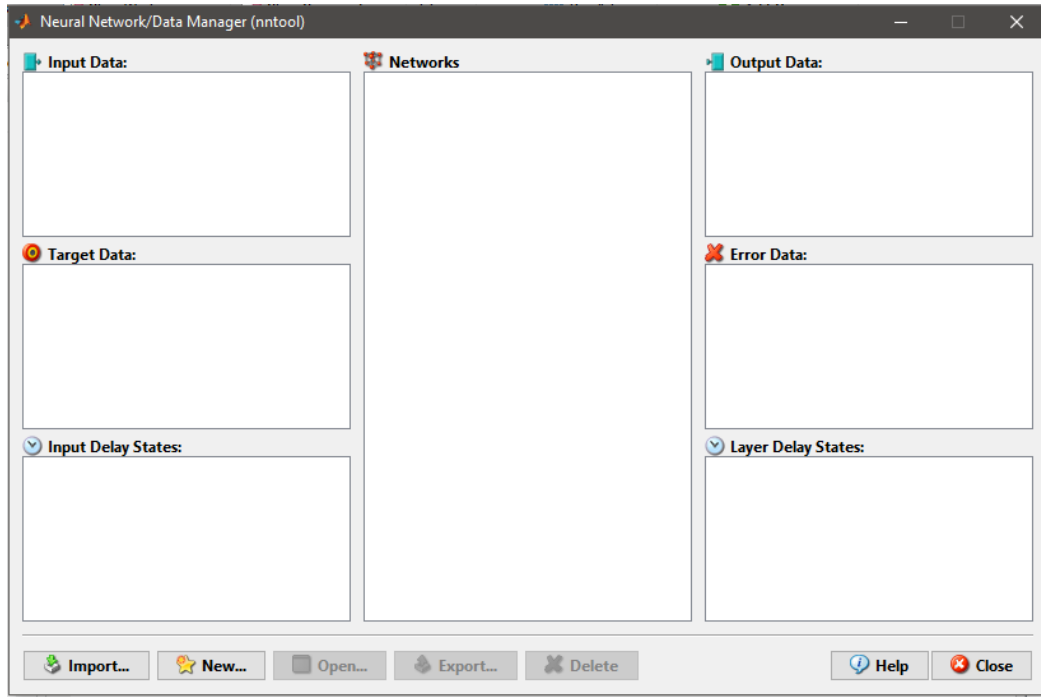
Name ▲	Value	Min
entrada	3x686 double	0
salida	1x686 double	0

Paso 2. Código de llamado para el toolbox de construcción y entrenamiento de las Redes Neuronales Artificiales

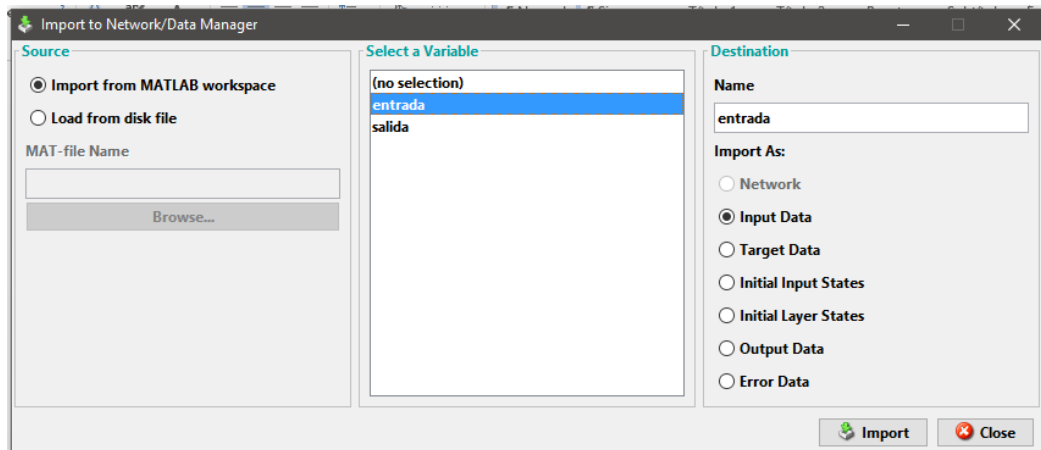


```
fx >> nntool|
```

### Paso 3. Toolbox para la creación y el entrenamiento de las redes neuronales artificiales

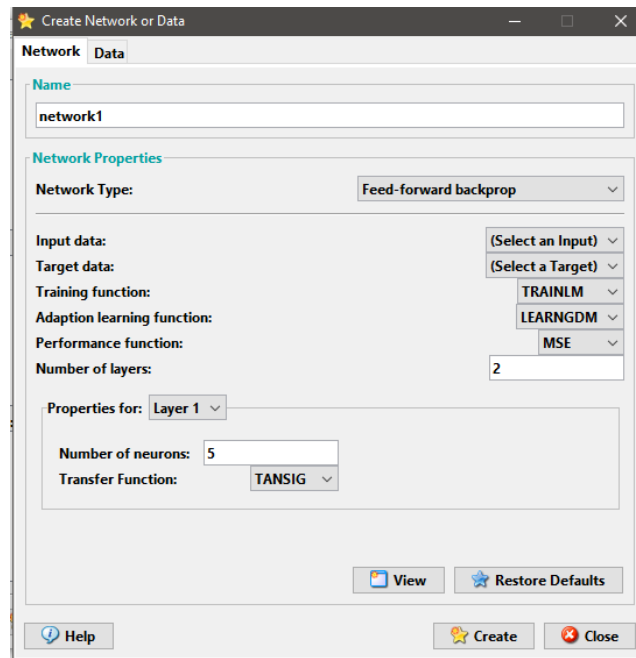


### Paso 4. Caja para importar las variables “input data” y “Target data” para el entrenamiento de las redes neuronales artificiales

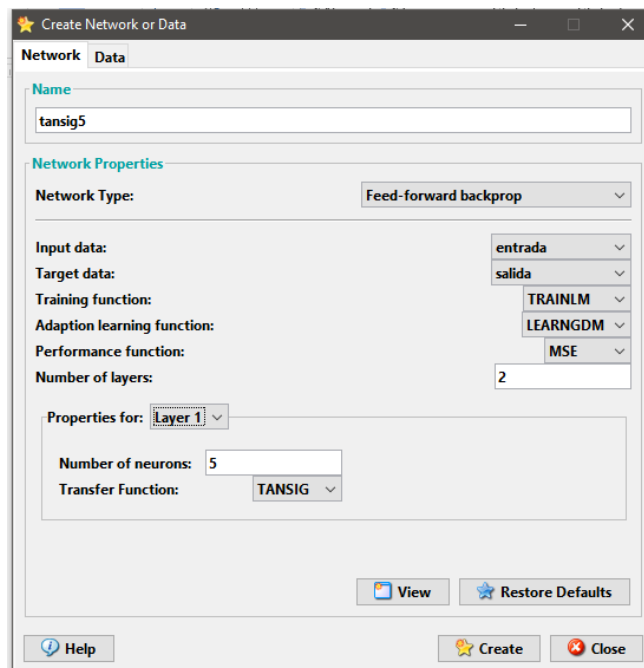




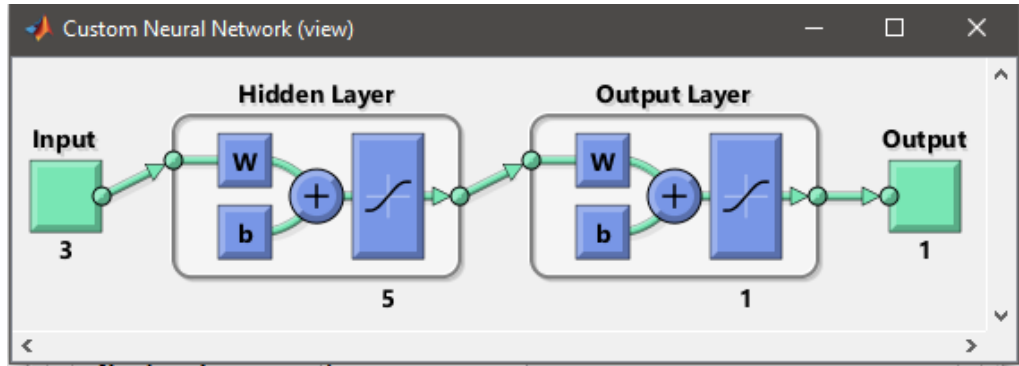
Paso 5. Caja para la construcción de las redes neuronales artificiales



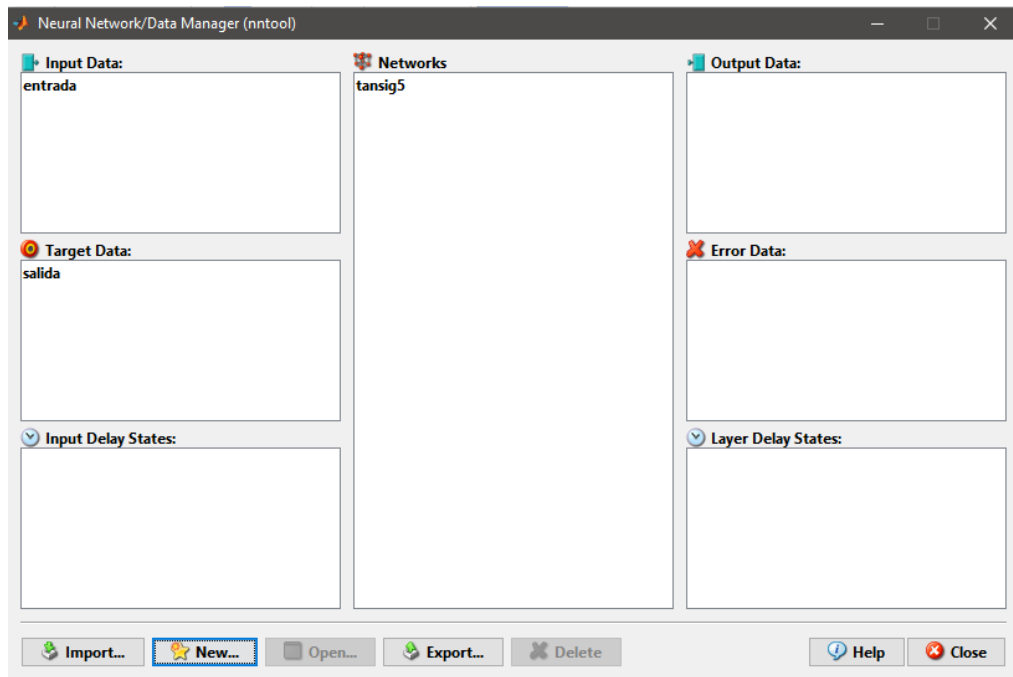
Paso 6. Caja para la construcción de las redes neuronales artificiales (Datos correspondientes a la red con 5 neuronas artificiales y función de transferencia tangente hiperbólica)



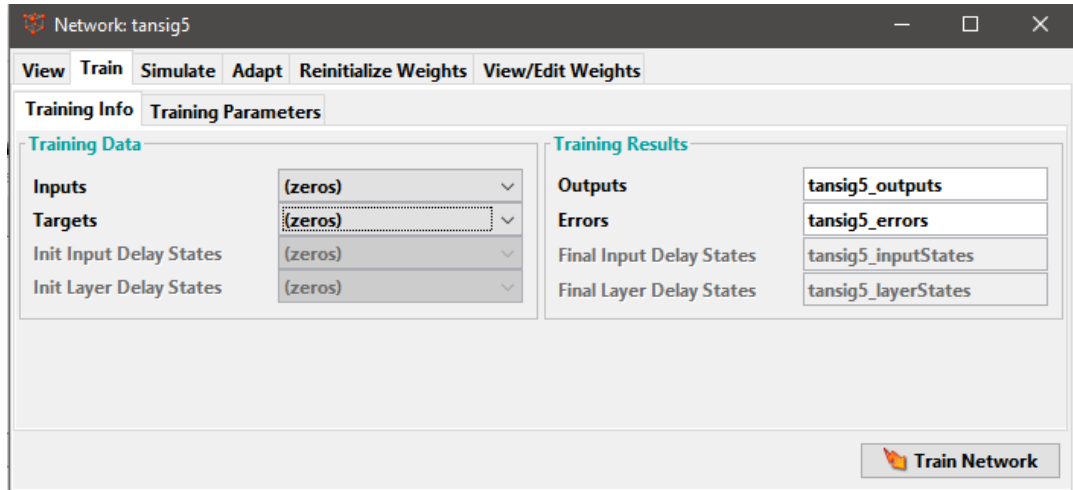
Paso 7. Imagen de la estructura de la red neuronal artificial



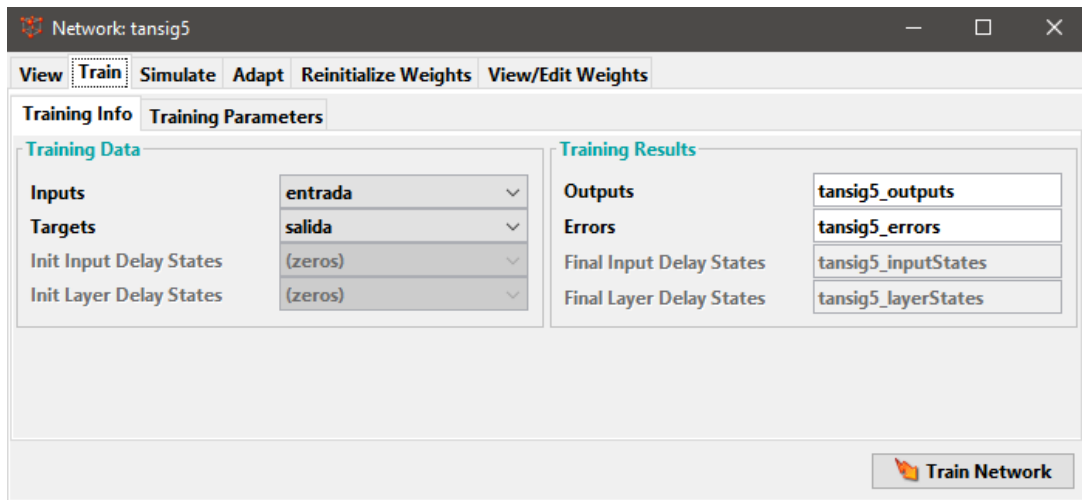
Paso 8. Red neuronal artificial creada



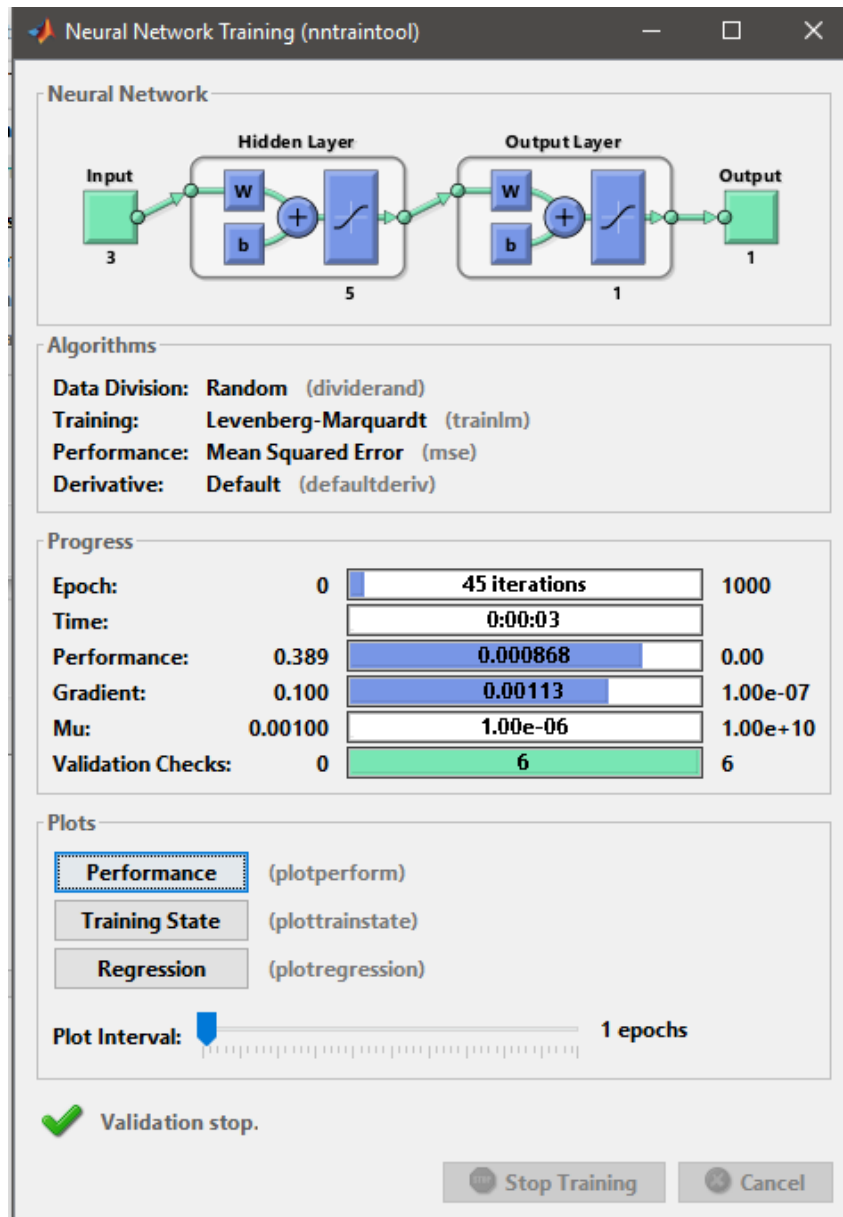
Paso 9. Cuadro para el entrenamiento de la red neuronal artificial creada (por defecto)




Paso 10. Cuadro para el entrenamiento de la red neuronal artificial creada (con la información cargada del ejemplo)



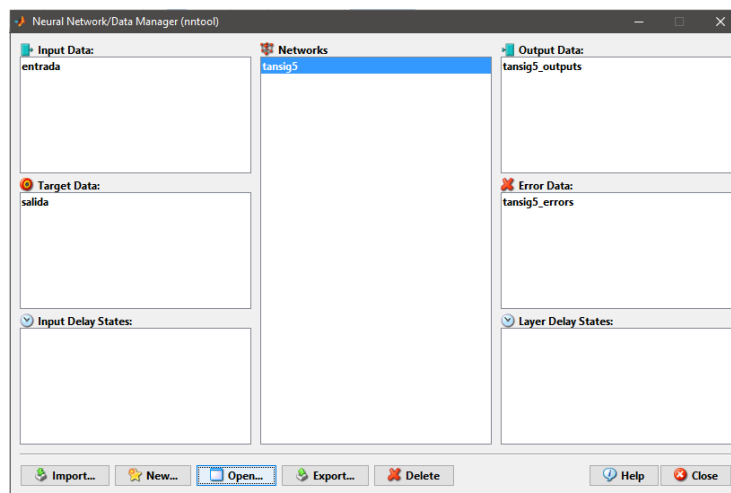
Paso 11. Cuadro de seguimiento del entrenamiento de la red neuronal artificial



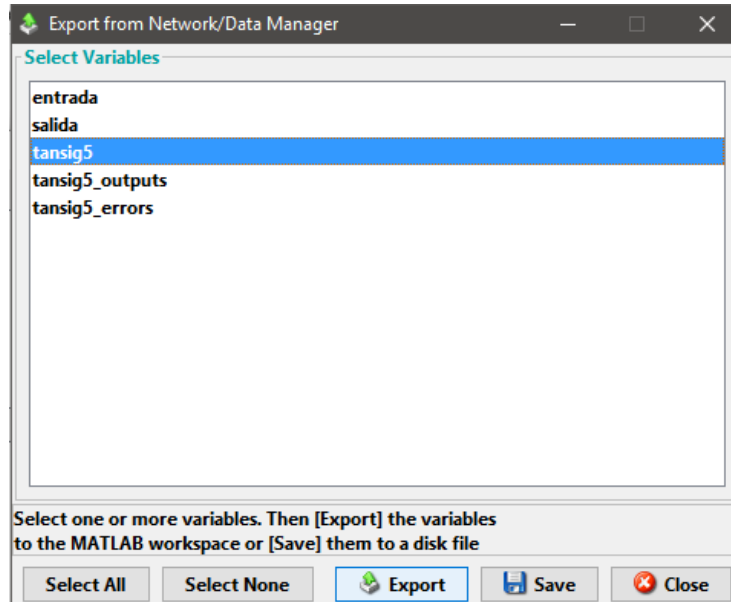
Paso 12. Gráfico de la evolución del error durante el entrenamiento de la red neuronal (ejemplo)



Paso 13. Cuadro con la red neuronal artificial entrenada



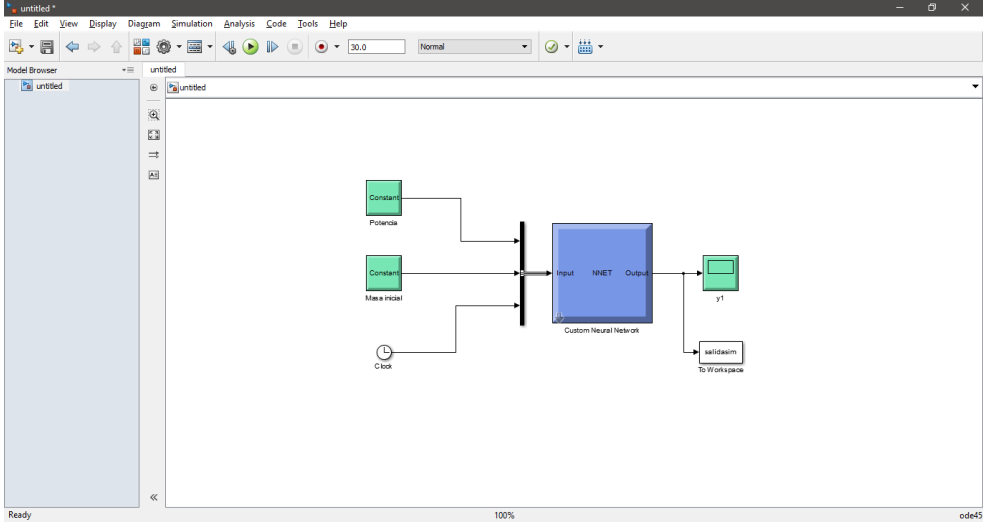
Paso 14. Cuadro para exportar la red neuronal artificial entrenada



Paso 15. Código usado para generar el modelo Simulink de la red neuronal artificial entrenada



```
Command Window
>> nntool
fx >> gensim(tansig5)|
```

Paso 16. Modelo simulink obtenido de la red neuronal artificial (modificado según las necesidades del caso)




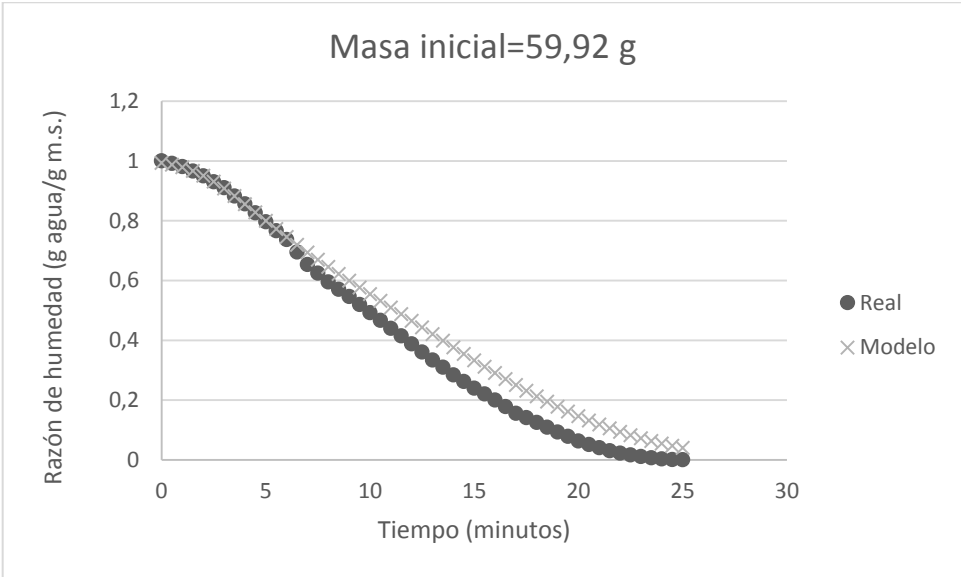
## Anexo 2 Curva de la razón de humedad versus tiempo y gráfica de valores reales

versus valores simulados. Masa inicial 50,9 g Potencia 420 W



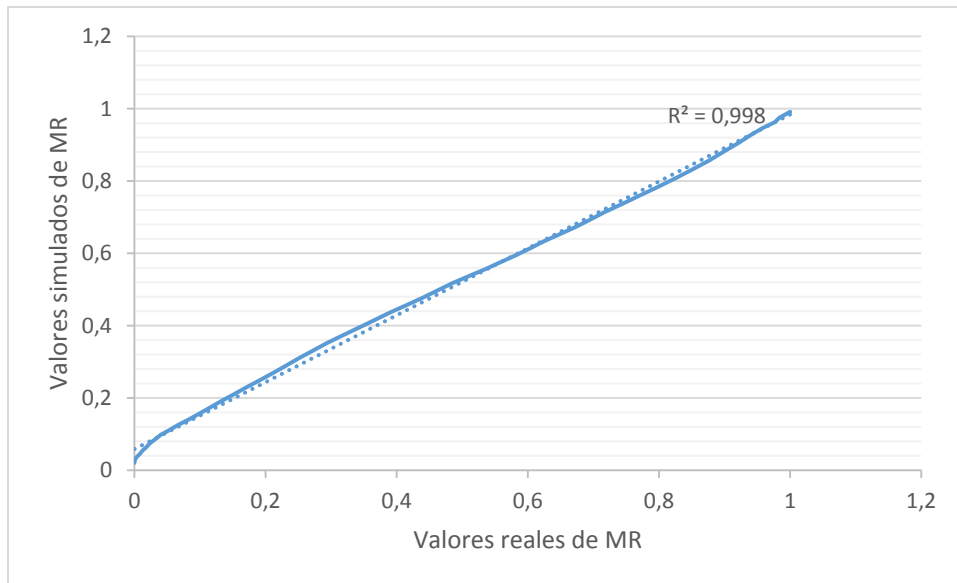



**Anexo 3 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 59,92 g Potencia 420 W**





#### Anexo 4 Curva de la razón de humedad versus tiempo y gráfica de valores reales

versus valores simulados. Masa inicial 72,23 g Potencia 420 W





**Anexo 5 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 50,84 g Potencia 560 W**





## Anexo 6 Curva de la razón de humedad versus tiempo y gráfica de valores reales

versus valores simulados. Masa inicial 61,83 g Potencia 560 W


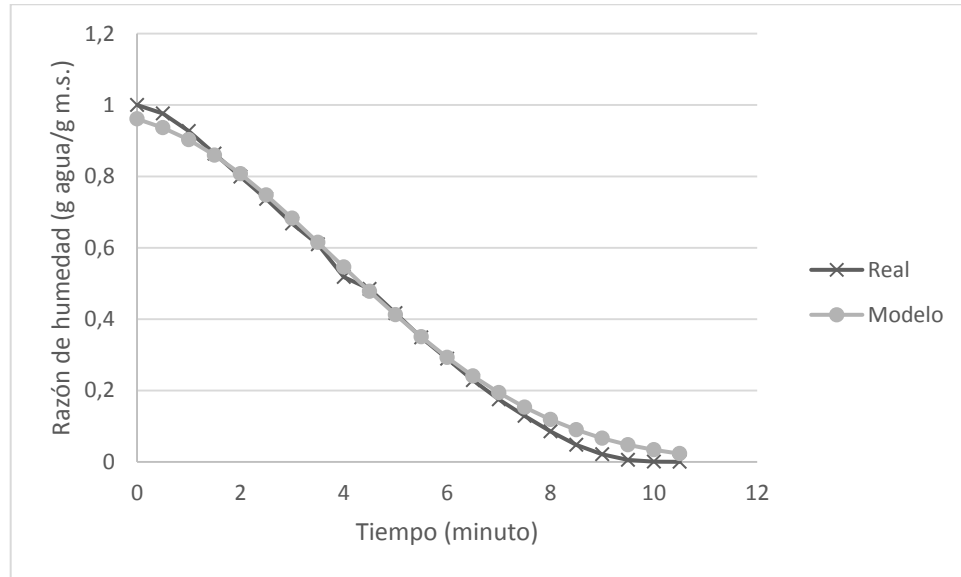


## Anexo 7 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 69,84 g Potencia 560 W

versus valores simulados. Masa inicial 69,84 g Potencia 560 W





**Anexo 8 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 52,54 g Potencia 700 W**



## Anexo 9 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 60,72 g Potencia 700 W

versus valores simulados. Masa inicial 60,72 g Potencia 700 W



## Anexo 10 Curva de la razón de humedad versus tiempo y gráfica de valores reales versus valores simulados. Masa inicial 69,69 g Potencia 700 W

versus valores simulados. Masa inicial 69,69 g Potencia 700 W

