



Predicción mediante Redes Neuronales Artificiales (RNA) de la difusividad, masa, humedad, volumen y sólidos en yacón (*Smallantus sonchifolius*) deshidratado osmóticamente

Prediction by Artificial Neural Networks (ANN) of the diffusivity, mass, moisture, volume and solids on osmotically dehydrated yacon (*Smallantus sonchifolius*)

Julio Rojas Naccha¹, Víctor Vásquez Villalobos^{1,*}

¹ Departamento de Ciencias Agroindustriales, Universidad Nacional de Trujillo, Av. Juan Pablo II s/n. Ciudad Universitaria. Trujillo, Perú.

Recibido 10 diciembre 2011; aceptado 10 agosto 2012

Resumen

Se evaluó la capacidad predictiva de la Red Neuronal Artificial (RNA) en el efecto de la concentración (30, 40, 50 y 60 % p/p) y temperatura (30, 40 y 50°C) de la solución de fructooligosacaridos (FOS) en la masa, humedad, volumen y sólidos en cubos de yacón osmodeshidratados, y en el coeficiente de difusividad efectiva media del agua, con y sin encogimiento. Se aplicó la RNA del tipo *Feedforward* con los algoritmos de entrenamiento *Backpropagation* y de ajuste de pesos *Levenberg-Marquardt*, usando la topología: error meta de 10^{-5} , tasa de aprendizaje de 0.01, coeficiente de momento de 0.5, 2 neuronas de entrada, 6 neuronas de salida, una capa oculta con 18 neuronas, 15 etapas de entrenamiento y funciones de transferencia *logsig-purelin*. El error promedio global por la RNA fue 3.44% y los coeficientes de correlación fueron mayores a 0.9. No se encontraron diferencias significativas entre los valores experimentales con los valores predichos por la RNA y con los valores predichos por un modelo estadístico de regresión polinomial de segundo orden ($p > 0.95$).

Palabras clave: Red Neuronal Artificial (RNA), difusividad efectiva, yacón, deshidratación osmótica.

Abstract

The predictive ability of Artificial Neural Network (ANN) on the effect of the concentration (30, 40, 50 y 60 % w/w) and temperature (30, 40 y 50°C) of fructooligosaccharides solution, in the mass, moisture, volume and solids of osmodehydrated yacon cubes, and in the coefficients of the water means effective diffusivity with and without shrinkage was evaluated. The Feedforward type ANN with the Backpropagation training algorithms and the Levenberg-Marquardt weight adjustment was applied, using the following topology: 10^{-5} goal error, 0.01 learning rate, 0.5 moment coefficient, 2 input neurons, 6 output neurons, one hidden layer with 18 neurons, 15 training stages and logsig-pureline transfer functions. The overall average error achieved by the ANN was 3.44% and correlation coefficients were bigger than 0.9. No significant differences were found between the experimental values and the predicted values achieved by the ANN and with the predicted values achieved by a statistical model of second-order polynomial regression ($p > 0.95$).

Keywords: Artificial Neural Networks (ANN), effective diffusivity, yacon, osmotic dehydration.

1. Introducción

El yacón (*Smallanthus sonchifolius*) es un tipo de raíz, que ha sido utilizado durante siglos como un alimento básico en la

población andina y en Sudamérica es un alimento tradicional. En la Unión Europea se considera novedoso, debido a la larga historia de uso seguro en América del Sur y aún en otros lugares, por sus posibles

* Autor para correspondencia

Email: vvasquez@unitru.edu.pe (V. Vásquez)

propiedades que promueven la salud, incluidos los efectos prebióticos, antidiabéticos, antioxidantes y antimicrobianos. Debido a las exigencias, el yacón se ha evaluado en cuanto a su seguridad antes de ser introducido en el mercado europeo. En éste sentido debido a que últimamente las nuevas regulaciones de alimentos, aceptan el historial de datos de uso seguro fuera de Europa, se han realizado investigaciones para establecer si el yacón, satisface los requerimientos reglamentarios y que puede ser autorizado en Europa. Debido a que éste posee un historial bien documentado y sin ambigüedades, respecto a su uso seguro y composición, se ha llegado a la conclusión que no existe preocupación sobre posibles efectos perjudiciales, presencia de sustancias tóxicas o antinutrientes (Ojansivu *et al.*, 2010).

Manrique y Hermann (2003) le atribuyen un potencial efecto benéfico en la salud humana, debido a que las raíces de yacón contienen fructooligosacáridos (FOS), un tipo particular de azúcares de baja digestibilidad que aportan pocas calorías al organismo no elevando el nivel de glucosa en la sangre. Liboni y Park (2003) reportan que los FOS tienen características específicas en la prevención de caries dentarias, reduce los niveles séricos de colesterol total y lípidos del suero además de actuar como estimulantes del crecimiento de Bifidobacterias en el aparato digestivo. Los FOS prácticamente no son digeridos por metabolismo humanos y la mayoría de Bifidobacterias son capaces de fermentarlo en alguna extensión.

Existe el hecho que la mayoría de propiedades atribuidas a los FOS se han realizado en roedores y los estudios realizados en seres humanos son escasos y con resultados diferentes. Sin embargo la evidencia científica disponible sustenta el reconocimiento de los FOS como fibra dietética y como prebióticos. Algunos estudios revelan que el consumo de FOS y de inulina reduce considerablemente el

nivel de colesterol y triglicéridos, sin embargo otros estudios sugieren que el consumo de fructanos no tiene ningún efecto. Estos resultados lo atribuyen a que el nivel de tolerancia a los FOS es bastante bajo en humanos, por lo que se requiere investigación adicional. Se ha reportado que cuando se incluye 40 g de inulina en la dieta se produce un incremento en la absorción de calcio de 21 a 34%, pero en otros estudios no se han encontrado diferencias en hombres de 20 a 26 años alimentados con un suplemento de 15 g de FOS/día. Sin embargo cuando se ha ampliado el tiempo de medición de 24 a 36 horas para detectar los niveles de absorción de calcio en adolescentes de 14 a 16 años, los estudios demostraron un incremento significativo en dicha absorción. Los FOS asimismo son considerados como un tipo de fibra alimentaria, debido a que no pueden ser digeridos directamente por el aparato digestivo humano y deben ser fermentados directamente en el colón. Algunos estudios realizados en humanos han demostrado que el consumo de fructanos incrementa la frecuencia de deposiciones y el volumen de la masa fecal, ambos parámetros ligados a una disminución del estreñimiento; por esta razón se ha reconocido que los FOS pueden generar un efecto laxante que podría ayudar a las personas con estreñimiento. En este contexto se ha reportado que el consumo de raíces de yacón frescas tiene un efecto hipoglicemante en sujetos clínicamente sanos. Sin embargo los autores consideran que hace falta aún mucha investigación. Por ahora la investigación más prudente que se puede dar acerca del yacón es que los diabéticos pueden consumirlo en sustitución de otro tipo de alimentos, en especial de aquellos que son dulces e hipercalóricos (Seminario *et al.*, 2003). Se estima que en el oeste medio de Holanda se consume entre 2 a 12 g de FOS diarios per cápita. En Japón hay consumo diario estimado en 13.7 mg/kg.día. La aprobación de FOS en Japón estableció

como ingesta diaria 0.8 g/kg de peso corporal por día. Encontrándose en este país el mayor mercado comercial de FOS, siendo uno de los más populares productos considerado como alimentos funcionales (Liboni y Park, 2003). Manifiestan que la ingestión de FOS, en dosis de 12.5 g por día, por 3 días (dosis clínicamente toleradas), producen efectos de caída significativa en el recuento de anaerobios totales en las heces, caída de PH, actividad de nitroreductasas, y beta glucuronidasas, caída en la concentraciones de ácido biliar y esterol neutro; es decir, conduce a un aumento en la colonización de Bifidobacterias. Indican que en un estudio que se administró FOS en pacientes diabéticos, se produjo un decrecimiento significativo de *Clostridium* y un aumento en el número de Bifidobacterias. Este estudio también reportó que los FOS promueven un alivio en el estreñimiento y malestar intestinal, así como disminuyen los niveles de triglicérido sérico y aumentan la producción de ácidos grasos volátiles.

Los FOS son oligómeros de la fructosa y puede ser preparado de la hidrólisis enzimática de la inulina la cual consiste en unidades lineales de fructosil con o sin una unidad final de glucosa. El grado de polimerización de estos FOS varía de 1 a 7 unidades de fructosil. Este proceso ocurre ampliamente en la naturaleza y estos oligosacáridos pueden ser encontrados en una gran variedad de plantas como el yacón. Madrigal y Sangronis (2007) refieren que en *Smallanthus sonchifolius* (yacón) se encuentran en un promedio de 27 g de inulina/100 g en base seca.

Cuando trozos de frutas y hortalizas se sumergen en una solución azucarada, o que tiene una presión osmótica mayor que la del alimento, el agua pasa del alimento a la solución osmótica, debido a la influencia del gradiente de la presión osmótica por la disminución de la actividad de agua del alimento. El producto final raras veces resulta estable y necesita un proceso posterior para alargar su vida útil y en este sentido se recomienda denominarle

producto deshidratado osmóticamente (Brennan, 2008).

La deshidratación osmótica es un proceso complejo de transferencia de masa en contracorriente entre los tejidos del vegetal y la solución hipertónica. La cual lleva a la deshidratación del producto y a cambios en su composición química, por lo tanto las propiedades del alimento así deshidratado diferirán sustancialmente del producto secado por convección. Estos alimentos contienen de 20 a 50 % de agua y son considerados alimentos de humedad intermedia (Casp y Abril, 2003).

Las variables que afectan el proceso de deshidratación osmótica y que pueden manejarse operativamente son: temperatura del proceso, concentración de solución osmótica, naturaleza del agente osmótico utilizado, presión, relación masa del producto-masa de solución o volumen de solución y agitación (Corzo y Centeno, 2003).

Una de las inquietudes de la ciencia e ingeniería es la predicción con un alto nivel de confianza, la cual está encaminada al control, la optimización y a la seguridad de las operaciones. Las técnicas usadas involucran en la mayoría de los casos, modelos formulados como ecuaciones matemáticas, los cuales permiten realizar predicciones a corto, mediano o largo plazo. Los modelos de caja negra, como las Redes Neuronales Artificiales (RNA), son esquemas capaces de representar cualquier sistema. Se trata en la mayoría de los casos de estructuras parametrizadas con suficiente flexibilidad como para poder acomodar los datos observados de una gran cantidad de sistemas diferentes (Arahal *et al.*, 2006).

Se define la RNA como sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. La RNA es una herramienta muy usada para predicciones en tiempos reales durante los procesos de secado y en el control de procesos en línea (Martín y De Paz, 2007).

Para procesos de manufactura, donde los modelos analíticos no son satisfactorios o donde los modelos polinómicos de bajo orden son inapropiados, la RNA es una buena alternativa debido a la capacidad de sus funciones de aproximación universal, igualmente también debido a la buena estabilidad de la RNA frente a las perturbaciones, datos mezclados y a su capacidad de acomodarse a variables múltiples no lineales con indeterminadas interacciones. En general la RNA es una herramienta muy usada para predicciones en tiempos reales, durante los procesos de secado y en el control de procesos en línea (Chegini *et al.*, 2008).

Existen redes de tipo supervisado, que son apropiados en procesos de predicción. En este sentido Lertworasirikul y Tipsuwan (2008) mencionan que los modelos supervisados, requieren un algoritmo de entrenamiento y datos de entrenamiento para ser ajustados a través de la modulación de pesos; asimismo que los modelos supervisados son muy usados en la clasificación, predicción y función de aproximación. Por otro lado también mencionan que para predecir y controlar operaciones relacionadas al procesamiento de alimentos, los modelos supervisados resultan ser los más adecuados.

Dentro de este panorama, el objetivo de la investigación fue evaluar la capacidad predictiva de la RNA, por el efecto de la concentración y temperatura de jarabe de yacón en las características fisicoquímicas de cubos de yacón: difusividad, masa, humedad, volumen y sólidos; para lo cual se determinó la arquitectura más adecuada de la RNA, comparándose su capacidad predictiva con modelos de regresión estadística.

2. Material y Métodos

Las raíces de yacón, adquiridas en el mercado de la ciudad de Trujillo, Región La Libertad - Perú, fueron lavadas, escaldadas (100°C, durante 25 minutos) y

peladas, posteriormente fueron cortadas en cubos de 1.16 cm de arista con un dispositivo metálico que permitió obtener medidas iguales. El jarabe de inmersión se preparó diluyendo FOS (5% de humedad) en agua destilada para obtener las concentraciones deseadas.

En un recipiente de 800 mL se colocaron los cubos de yacón y la solución de FOS a razón de 1/10 en peso. En el recipiente para osmodeshidratación (Figura 1) se colocó dentro de un termostato Memmert (0-100°C). En la parte superior se instaló un motor (140 rpm) unido a un agitador de paleta.

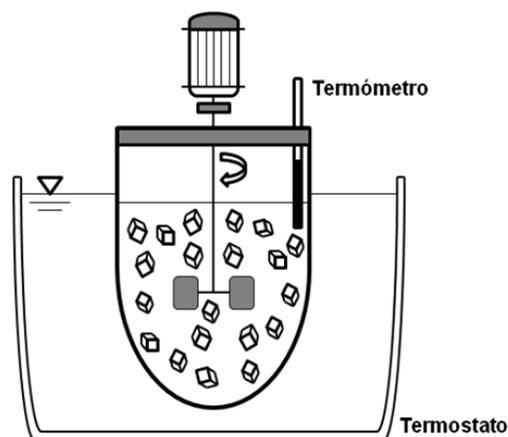


Figura 1. Esquema del sistema de osmodeshidratación.

Se trabajó con temperaturas de 30, 40 y 50°C y concentraciones de 30, 40, 50 y 60 % p/p de jarabe para cada temperatura, con 3 repeticiones, haciendo en total 36 unidades experimentales. Se determinaron la masa, humedad, volumen, sólidos, difusividad efectiva media con y sin encogimiento a las 30 horas de iniciada la experiencia. La humedad se calculó según el método de la A.O.A.C (1995) y la difusividad efectiva media con el método de Azuara *et al.* (1992) de acuerdo a:

$$\overline{D}_{ef} = \frac{\sum_{i=1}^{\infty} D_{ef(i)}}{N}$$

$$D_{ef} = \frac{\pi t}{4t^{1/2}} \left[\left(\frac{S_1 L^3}{1 + S_1 t} \right) \left(\frac{WL_{\infty}^{mod}}{WL_{\infty}^{exp}} \right) \right]^{2/3}$$

Donde:

\overline{D}_{ef} : Difusividad media efectiva;

$D_{ef(t)}$: Difusividades efectivas para cada tiempo (t);

N : Número de puntos experimentales utilizados para el cálculo;

D_{ef} : Difusividad efectiva;

S_1 : Constante de velocidad;

L : dimensión característica (arista del cubo $2L$);

WL_{∞}^{exp} : Pérdida de agua en el equilibrio;

WL_{∞}^{mod} : Pérdida de agua obtenida experimentalmente.

Determinación de la capacidad predictiva de la RNA

Se seleccionaron 2 variables de entrada (2 neuronas) y 6 variables de salida (6 neuronas). Las variables de entrada fueron la concentración y temperatura, mientras que las variables de salida fueron la masa, humedad, volumen, sólidos, difusividad efectiva media y difusividad efectiva media con y sin encogimiento. El criterio de la evaluación de los cubos al producirse encogimiento fue considerado por Amiel y Vásquez (2007), quienes observaron que cubos de yacón sumergidos en jarabe de FOS de 60°Brix entre temperaturas de 30 a 45°C, sufren una variación del volumen a las dos horas entre 43.8% y 56.3%, cuando la cinética de pérdida de agua supera el 45%, lo que ocasiona una variación de la difusividad efectiva entre 2.46% a 8.63% con respecto a la difusividad calculada sin encogimiento. En la presente investigación fue considerado 3 horas, tiempo en el que existe una pérdida de agua mayor al 50%. En este sentido se diluyó en realizar el cálculo de la difusividad efectiva sin encogimiento manteniendo fija la dimensión característica ($2L$) y con encogimiento. Con el fin de observar la deformación de los cubos de yacón, se calculó el volumen por desplazamiento de volumen de agua haciendo uso de dos probetas. A partir de este dato se determinó la arista aplicando la raíz cúbica.

De las 36 unidades experimentales se escogieron aleatoriamente 27 unidades

experimentales para el entrenamiento (75%) y 9 unidades para la validación (25%). Los datos de entrada para el entrenamiento fueron normalizados dividiendo entre 100 el valor de la humedad y los sólidos ganados, entre 10 el valor del volumen y multiplicando por 10^7 los valores de la difusividad efectiva media.

Se utilizó la RNA del tipo *Feedforward*, con los algoritmos de entrenamiento *Backpropagation* y de ajuste de pesos *Levenberg-Marquardt*. El criterio de evaluación de la eficiencia de la RNA fue el Error Cuadrático Medio (ECM).

Efecto del error meta, del número de neuronas y del número de etapas

Se probó la eficiencia de la RNA variando los errores meta de 10% hasta 0.000001% y el número de neuronas de 1 a 100 buscando los menores ECM. Utilizando las neuronas que tuvieron menor ECM y para el error meta escogido, se varió el número de etapas de 1 a 5000.

Evaluación de las funciones de activación y de transferencia

Con el número de etapas y neuronas escogidas se evaluó el efecto de las funciones de transferencia: tangente sigmoideal hiperbólica (*tansig*), logarítmica sigmoideal hiperbólica (*logsig*) y función puramente lineal (*purelin*); las que fueron combinadas de dos en dos. Con la combinación de funciones que tuvo menor ECM, se evaluó el efecto del incremento de número de neuronas para la etapa escogida.

Efecto de la tasa de aprendizaje, del coeficiente de momento y del número de capas ocultas

Con la combinación de funciones, etapas y neuronas escogidas se probó varias tasas de aprendizaje y de momento. Luego se probó con 1, 2 y 3 capas ocultas.

Con los resultados obtenidos se encontró la topología final, la que fue usada en el proceso de validación (Figura 2).

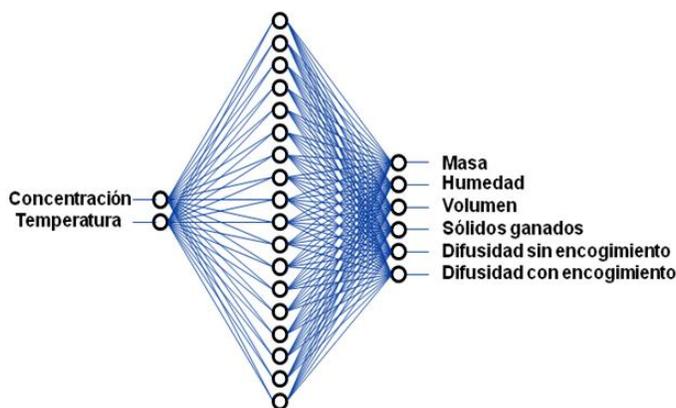


Figura 2. Esquema de la topología de la RNA.

Validación de la RNA

Usando el software MATLAB 7.0 se calcularon los valores predichos por la RNA y los coeficientes de correlación entre los valores predichos con los valores esperados en cada unidad de validación.

Se desnormalizaron los valores predichos en cada unidad de validación a fin de evaluar la capacidad predictiva y se volvieron a agrupar en función de las variables salida o variables dependientes, a fin de poder compararlos con los valores predichos por una ecuación ajustada de regresión de segundo orden completo: $y = a + bx_1 + cx_2 + dx_1^2 + ex_2^2 + fx_1x_2$, donde y = variables dependientes (masa, humedad, volumen, sólidos y difusividad efectiva media) y x = variables independientes (concentración y temperatura). Estos resultados se determinaron con el software DATA FIT 9.0 habiéndose probado cinco ecuaciones: primer orden, primer orden con iteración, primer orden logarítmico, segundo orden y segundo orden completo. Se usó el error porcentual como criterio de comparación entre los valores esperados con los valores predichos por la RNA y por la ecuación de regresión de segundo orden.

Trabajando con un $\alpha=0.05$, se aplicó el ANVA para encontrar diferencias significativas entre los valores esperados y los valores predichos por ambos métodos predictivos.

3. Resultados y discusión

En la Tabla 1 se muestra las variables de entrada y salida utilizadas en el entrenamiento y validación de la RNA. Las variables de entrada o variables independientes fueron la concentración del jarabe y la temperatura y las variables de salida o variables dependientes fueron: la masa, humedad, volumen, sólidos, difusividad efectiva media sin encogimiento y la difusividad efectiva media (*) calculada considerando la disminución de volumen durante el proceso de osmodeshidratación (con encogimiento). Los datos sombreados (color verde) corresponden a las 9 unidades de validación que vienen a ser el 25 % del total de datos, los cuales fueron escogidos al azar. Puede observarse que a consecuencia de incrementarse la temperatura y concentración, los valores de la masa, humedad y volumen disminuyen, mientras que los valores de los sólidos y difusividad aumentan. Ochoa-Martínez y Ayala-Aponte (2005) mencionan que la pérdida de agua y la ganancia de sólidos son proporcionales a la concentración y a la temperatura. Ibarz y Barboza-Canovas (2005) indican que la temperatura es una de las variables que más afecta el proceso de deshidratación osmótica, ya que un aumento de la misma intensifica la eliminación del agua y la penetración de la sustancia osmótica en los tejidos.

Amiel y Vásquez (2007), trabajando con cubos de yacón de volumen inicial de 8 cm³ y con FOS (60 % p/p) como agente osmótico, encontraron valores de difusividad efectiva media sin encogimiento de 2.2x10⁻⁸ m²/s a 30°C; 2.4x10⁻⁸ m²/s a 40°C y 2.45 x10⁻⁸ m²/s a 45°C y con encogimiento: 2.12x10⁻⁸ m²/s a 30°C,

2.22x10⁻⁸ m²/s a 40°C y 2.28x10⁻⁸ m²/s a 45°C. Como puede observarse hay un incremento de las difusividades efectivas medias debido al aumento de la temperatura en ambas experiencias y los valores encontrados son similares a los reportados en el presente trabajo.

Tabla 1

Datos de entradas y salidas para el entrenamiento y validación de la RNA

Entradas		Salidas					
Concentración (% p/p)	Temperatura (°C)	Masa (g)	Humedad (%)	Volumen (cm ³)	Sólidos (%)	Difusividad efectiva media (m ² /s)	Difusividad efectiva media* (m ² /s)
30	30	1.1013	73.13	1.2	9.83	1.12E-08	1.08E-08
30	30	1.1174	73.61	1.2	9.74	1.13E-08	1.10E-08
30	30	1.1783	74.53	1.15	9.99	1.29E-08	1.26E-08
30	40	1.1041	71.89	1	10.34	1.28E-08	1.23E-08
30	40	1.1432	73.61	1.2	10.23	1.46E-08	1.42E-08
30	40	1.1044	72.69	1.1	10.4	1.23E-08	1.17E-08
30	50	0.9978	69.14	1	9.97	1.47E-08	1.32E-08
30	50	1.065	70.74	0.9	10.99	1.40E-08	1.28E-08
30	50	0.9989	68.88	1	10.91	1.39E-08	1.26E-08
40	30	0.8514	63.31	0.85	10.07	1.36E-08	1.26E-08
40	30	0.9062	64.19	0.88	10.73	1.22E-08	1.13E-08
40	30	0.9057	64.21	0.8	10.42	1.25E-08	1.17E-08
40	40	0.7218	57.84	0.8	10.88	1.33E-08	1.21E-08
40	40	0.7526	56.44	0.75	10.26	1.47E-08	1.34E-08
40	40	0.7422	56.13	0.77	10.53	1.13E-08	1.02E-08
40	50	0.6811	53.99	0.66	10.82	1.58E-08	1.42E-08
40	50	0.6984	54.51	0.7	10.98	1.49E-08	1.32E-08
40	50	0.6977	55.65	0.72	10.67	1.39E-08	1.24E-08
50	30	0.6105	47.65	0.56	10.5	1.40E-08	1.28E-08
50	30	0.6142	48.14	0.64	10.34	1.40E-08	1.27E-08
50	30	0.6248	48.98	0.6	10.22	1.42E-08	1.27E-08
50	40	0.5534	43.57	0.54	11.91	1.52E-08	1.35E-08
50	40	0.5611	44.59	0.55	10.93	1.61E-08	1.45E-08
50	40	0.5456	41.48	0.55	10.75	1.57E-08	1.39E-08
50	50	0.5212	38.51	0.4	11.09	1.51E-08	1.32E-08
50	50	0.5002	36.53	0.51	12.21	1.79E-08	1.55E-08
50	50	0.5106	36.45	0.5	12.06	1.73E-08	1.52E-08
60	30	0.5194	38.85	0.51	11.03	1.44E-08	1.24E-08
60	30	0.5129	38.55	0.5	11.14	1.47E-08	1.26E-08
60	30	0.4994	36.22	0.51	11.04	1.35E-08	1.17E-08
60	40	0.5015	29.89	0.5	12.29	1.63E-08	1.39E-08
60	40	0.4895	30.83	0.4	12.25	1.53E-08	1.33E-08
60	40	0.5012	30.51	0.45	12.62	1.59E-08	1.37E-08
60	50	0.4941	27.69	0.45	13.43	1.72E-08	1.41E-08
60	50	0.4839	26.51	0.33	13.24	1.70E-08	1.42E-08
60	50	0.4812	27.22	0.42	12.96	1.76E-08	1.44E-08

* Difusividad efectiva media calculada considerando la variación de volumen (con encogimiento).

Efecto del error meta, del número de neuronas y de etapas de entrenamiento

El criterio escogido para medir la eficiencia del proceso de entrenamiento fue el del menor error cuadrático medio (ECM), criterio escogido por algunos autores como Vásquez y Lescano (2010), Cueva y Vásquez (2009), Paredes *et al.* (2009), Aliaga *et al.* (2009) y Ochoa-Martínez *et al.* (2007 a,b). El ECM es el resultado de dividir la sumatoria de los cuadrados de la diferencia de los valores predichos menos los valores observados, entre el número total de datos y son determinados después de que los pesos son ajustados (Poonnoy *et al.*, 2007).

Trabajando con los datos no sombreados de la Tabla 1 (75%) y aplicando las funciones de transferencia *tansig-purelin*, se observó que a partir de un error de 10^{-5} , el ECM se hizo constante. Luego se observó que a partir de 14 neuronas y 18 etapas, el menor ECM obtenido (0.0000924691) se mantuvo constante, motivo por el cual se escogió 18 etapas con 14 neuronas para completar la topología de trabajo. Este último valor de ECM se aproximó más al deseado (10^{-5}). Saiedirad y Mirsalehi (2010) indican que el valor final del ECM debería ser lo más cercano a cero dentro de los rangos aceptados como predicción eficiente.

Evaluación de la función de transferencia

Aplicando la topología encontrada se evaluó el efecto de incrementar el número de neuronas desde 1 hasta 100, usando otras combinaciones de funciones de transferencia (*tansig-purelin*, *tansig-logsig*, *tansig-tansig*, *logsig-purelin*, *logsig-logsig*, *logsig-tansig*, *purelin-purelin*.), cuyos resultados se observan en la Figura 3. Notándose que el menor ECM se consigue con la funciones de transferencia *logsig-purelin*, lo que lo calificaría como la combinación de funciones más apropiada para el proceso de entrenamiento y validación.

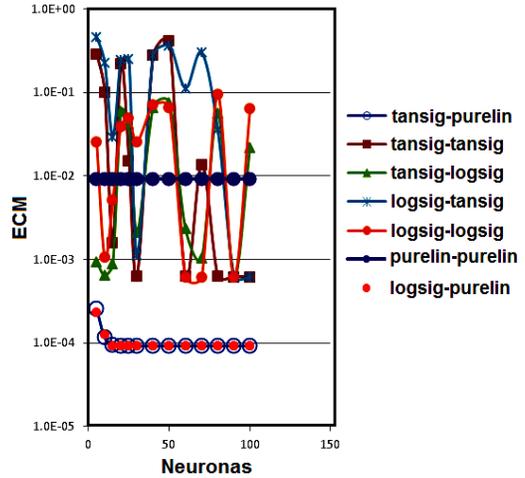


Figura 3. Efecto del número de neuronas en el ECM para las diferentes funciones de transferencia.

Similar comportamiento fue observado por Movagharnejad y Nikzad (2007) quienes también utilizaron la función de transferencia *logsig* con una capa oculta con 4 neuronas; cuyos resultados los compararon con datos experimentales, constatando que las predicciones del modelo RNA, concordaron con los datos experimentales con mayor precisión que diversas ecuaciones matemáticas. Sin embargo estos resultados no definen para todos los casos un patrón de comportamiento, el cual puede variar en función a la naturaleza del problema, Por ejemplo Ochoa-Martínez *et al.* (2007a) utilizaron el modelo perceptrón multicapa con la función de activación tangente hiperbólica (*tanh*) para las capas ocultas, por resultarle mejor que la función sigmoideal; pero si les resultó útil en la construcción de su topología el uso de la función lineal (*purelin*) en la capa de salida como en la presente investigación. Si resulta de interés mencionar las apreciaciones de Isasi y Galván (2004), quienes indican que las funciones de activación más usadas son la función sigmoideal y la tangente hiperbólica, en cuyo espectro se encuentra los resultados de la presente investigación.

Efecto de la tasa de aprendizaje, del coeficiente de momento y del número de capas ocultas

La variación de la tasa de aprendizaje y de la tasa de momento no produjo ningún efecto en el ECM. Vásquez y Lescano (2010), Cueva y Vásquez (2009) han venido observando que la variación de las tasas de aprendizaje y momento no influye en el valor del ECM cuando se usa el mismo procedimiento en la construcción de la topología de la red. Sin embargo existen otros autores como Chen *et al.* (2001) quienes encontraron que la variación de las tasas de aprendizaje de 0.1 a 0.7 no influye en el error, Martín y De Paz (2007) mencionan que las tasas de aprendizaje más usadas pueden estar en el rango de 0.05 a 0.5 y por otro lado Millan y Ostojich (2006) recomiendan tasas de 0.05 a 0.75.

Se ha observado asimismo que el incremento de capas ocultas no disminuye el ECM y se mantiene constante a partir de 18 neuronas y de 15 etapas. Isasi y Galván (2004) sostiene que el número de capas ocultas y el número de neuronas deben ser elegidos por el diseñador y que no existe regla que determine el número óptimo de neuronas ocultas para resolver un problema dado.

Concordando con esta apreciación Essen *et al.* (2007) mencionan que en la mayor parte de las aplicaciones prácticas, la determinación del número de etapas y neuronas se determina por prueba y error, como la realizada en la presente investigación.

Topología final de la RNA

De los resultados anteriores se obtuvo la siguiente arquitectura final de la RNA tipo *Feedforward* con aprendizaje supervisado, algoritmo de entrenamiento de retropropagación del error (*Backpropagation*) y algoritmo de ajuste de pesos *Levenberg-Marquardt*: error meta de 10^{-5} , tasa de aprendizaje de 0.01, coeficiente de momento de 0.5, 2 neuronas de entrada, 6

neuronas de salida, una capa oculta con 18 neuronas, 15 etapas de entrenamiento y funciones de transferencia *logsig-purelin*.

Validación de la RNA

En la Tabla 2 se observan los coeficientes de correlación entre valores esperados y valores predichos por la RNA, obtenidos con el software MATLAB 7.0, en cada unidad de validación. La evidente aproximación al valor 1 indica una fuerte asociación positiva entre lo esperado y lo predicho, lo que es indica un buen desempeño de la RNA.

Tabla 2

Coefficientes de correlación entre los valores esperados con los predichos.

Unidad de validación	R
1	0.99993615
2	0.99977189
3	0.99972062
4	0.99990081
5	0.99998296
6	0.99950545
7	0.99979101
8	0.99933308
9	0.99975323

Gutiérrez y De la Vara (2003) mencionan que el coeficiente de correlación mide la intensidad de la relación lineal entre dos variables X y Y, razón que justifica su inclusión en el criterio de comparación. En la Tabla 2 se observa que los coeficientes de correlación son superiores a 0.9, esto indica una asociación muy buena, tal como lo refieren los mencionados autores. Ochoa-Martínez *et al.* (2007a) predijo la pérdida de agua y ganancia de sólidos en la deshidratación osmótica de frutas, obteniendo valores de R mayores a 0.9; concluyendo que con la RNA se obtiene mejores resultados que los obtenidos por el análisis de regresión multivariado. Para la predicción de coeficientes de difusividad de agua encontraron valores de R cercanos a 0.98 (Ochoa-Martínez *et al.*, 2007b).

Tabla 3

Valores esperados y valores predichos por la RNA y por la regresión en cada variable de salida.

Variable	Valor esperado	Valor predicho			
		RNA	Error (%)	Regresión	Error (%)
Masa (g)	1.1041	1.1238	1.78	1.0888	1.39
	0.9978	1.0319	3.42	1.0131	1.53
	0.9062	0.8786	3.05	0.8313	8.27
	0.6984	0.6894	1.29	0.7044	0.86
	0.6248	0.6124	1.98	0.6148	1.6
	0.5106	0.5107	0.02	0.5231	2.45
	0.5129	0.5094	0.68	0.5258	2.52
	0.5015	0.4953	1.24	0.4922	1.85
	0.4812	0.489	1.62	0.4694	2.45
Error promedio (%)			1.68		2.55
Humedad (%)	71.89	73.15	1.75	71.85	0.06
	69.14	69.81	0.97	69.83	1
	64.19	63.76	0.67	61.6	4.03
	54.51	54.82	0.57	53.88	1.16
	48.98	47.89	2.23	49.06	0.16
	36.45	37.52	2.94	39.18	7.49
	38.55	37.54	2.62	37.75	2.08
	29.89	30.67	2.61	30.97	3.61
	27.22	27.1	0.44	25.71	5.55
Error promedio (%)			1.64		2.79
Volumen (cm ³)	1	1.15	15	1.09	9
	1	0.95	5	0.98	2
	0.88	0.825	6.25	0.84	4.55
	0.7	0.69	1.43	0.67	4.29
	0.6	0.6	0	0.61	1.67
	0.5	0.455	9	0.48	4
	0.5	0.51	2	0.5	0
	0.5	0.425	15	0.46	8
	0.42	0.39	7.14	0.4	4.76
Error promedio (%)			6.76		4.25
Sólidos (%)	10.34	10.32	0.19	10.35	0.1
	9.97	10.95	9.83	10.46	4.91
	10.73	10.24	4.57	10.03	6.52
	10.98	10.74	2.19	10.97	0.09
	10.22	10.42	1.96	10.42	1.96
	12.06	11.65	3.4	11.86	1.66
	11.14	11.04	0.9	11.19	0.45
	12.29	12.43	1.14	12.27	0.16
	12.96	13.34	2.93	13.15	1.47
Error promedio (%)			3.01		1.92
Difusividad efectiva media (m ² /s)	1.28E-08	1.35E-08	5.08	1.29E-08	0.78
	1.47E-08	1.40E-08	5.1	1.40E-08	4.76
	1.22E-08	1.31E-08	6.97	1.28E-08	4.92
	1.49E-08	1.49E-08	0.34	1.53E-08	2.68
	1.42E-08	1.40E-08	1.41	1.37E-08	3.52
	1.73E-08	1.65E-08	4.62	1.64E-08	5.2
	1.47E-08	1.40E-08	5.1	1.45E-08	1.36
	1.63E-08	1.56E-08	4.29	1.59E-08	2.45
	1.76E-08	1.71E-08	2.84	1.74E-08	1.14
Error promedio (%)			3.97		2.98
Difusividad efectiva media (con encogimiento) (m ² /s)	1.23E-08	1.30E-08	5.28	1.20E-08	2.44
	1.32E-08	1.27E-08	3.79	1.26E-08	4.55
	1.13E-08	1.22E-08	7.52	1.20E-08	6.19
	1.32E-08	1.33E-08	0.76	1.38E-08	4.55
	1.27E-08	1.28E-08	0.39	1.25E-08	1.57
	1.52E-08	1.44E-08	5.59	1.43E-08	5.92
	1.26E-08	1.21E-08	4.37	1.24E-08	1.59
	1.39E-08	1.35E-08	2.88	1.36E-08	2.16
	1.44E-08	1.42E-08	1.74	1.43E-08	0.69
Error promedio (%)			3.59		3.3
Promedio global			3.44		2.96

Por otro lado Kerdpiboon *et al.* (2006) prefirieron utilizar el coeficiente de determinación entre los valores predichos con los valores experimentales. Millán *et al.* (2001) comparó el coeficiente de determinación (R^2) y el error estándar de predicción de 4 modelos matemáticos de isotermas de adsorción con los de la RNA, encontrando mayor coeficiente de determinación y menor error estándar de predicción en la RNA que en los otros modelos.

Para la completar con la validación se agruparon los datos predichos en función de las variables dependientes por ser así factible de compararlos con los datos predichos por modelos de regresión estadísticos. Arahál *et al.* (2006) refieren que el objetivo de la validación es establecer la credibilidad de un modelo para un propósito específico y que ésta se realiza habitualmente mediante un análisis comparativo. El mismo autor refiere que la validación de modelos de caja negra se realiza habitualmente utilizando un conjunto separado de datos y obteniendo el error de predicción en dicho conjunto.

En la Tabla 3 se observa los valores esperados con los valores predichos por la RNA y predichos por la ecuación ajustada de regresión de segundo orden completo: $y = a + bx_1 + cx_2 + dx_1^2 + ex_2^2 + fx_1x_2$. También se observan los errores porcentuales absolutos entre los valores

predichos y valores esperados, así como sus respectivos errores porcentuales promedio obtenidos para cada variable dependiente. Puede observarse que el error porcentual global del modelo de regresión para la ecuación de segundo orden (2.96) es ligeramente inferior que el error porcentual global obtenido por la RNA (3.44). Ambos errores son considerados bajos y corroboran la eficiencia de ambos modelos predictivos. Moura *et al.* (2004) también comparó los errores porcentuales en forma absoluta y relativa de ambos modelos predictivos.

En la Tabla 4 se muestran los coeficientes estadísticos de la ecuación ajustada de regresión de segundo orden que fue usada para determinar los valores predichos. Así mismo los coeficientes de determinación de dichas ecuaciones. Puede observarse que el modelo estadístico explica bastante bien el compartamiento de la masa ($R^2= 0.9838$), humedad ($R^2= 0.992$) y volumen ($R^2= 0.9738$), mientras que en las variables sólidos y difusividad se puede mencionar que poseen un nivel de predicción aceptable. Al respecto, Gutierrez y De La Vara (2003) señalan que para modelos de predicción por ecuaciones ajustadas por regresión, pueden considerarse aceptables valores de coeficientes de determinación ajustadas mayores a 0.7.

Tabla 4

Coeficientes estadísticos de las ecuaciones ajustadas de regresión de segundo orden completo para la masa, humedad, volumen, sólidos y difusividad efectiva media.

Coeficiente	Masa	Humedad	Volumen	Sólidos	Difusividad efectiva media	Difusividad efectiva media (con encogimiento)
a	3.46E+00	1.34E+02	3.21E+00	1.26E+01	6.60E-09	-2.48E-09
b	-8.43E-02	-1.49E+00	-7.92E-02	-2.15E-01	1.00E-10	3.05E-10
c	-1.77E-02	-5.62E-01	-7.75E-03	2.42E-02	4.32E-11	3.03E-10
d	6.37E-04	6.20E-03	5.67E-04	1.95E-03	-5.83E-13	-2.91E-12
e	5.43E-05	7.60E-03	-9.58E-05	-1.00E-03	3.33E-13	-2.81E-12
f	1.76E-04	-1.08E-02	1.75E-04	2.56E-03	1.30E-12	2.83E-13
R^2	0.9838	0.992	0.9738	0.8907	0.7665	0.7562
R^2 (ajustado)	0.9811	0.9906	0.9694	0.8725	0.7276	0.711

Alvarado y Aguilera (2001) mencionan que la superficie tridimensional que proporciona el mejor ajuste a los puntos experimentales es la superficie de respuesta, que puede estar representada por la ecuación de segundo orden completo y que el procedimiento para hallarlo incluye el análisis de regresión polinomial.

A fin de comprobar si existen diferencias significativas entre los valores esperados con los valores predichos por la RNA y por el modelo estadístico, se aplicó el análisis de varianza, cuyos resultados se muestran a continuación en la Tabla 5.

El resultado del análisis estadístico indicó que no hay diferencia significativa entre los valores esperados, valores predichos por la RNA y predichos por la ecuación de segundo orden ajustada por regresión ($p > 0.05$). Estos resultados permitirían confirmar la eficiencia de la RNA en capacidad predictiva, trabajando por igual que los métodos predictivos de regresión estadística. Al respecto Pitarque *et al.*

(2000) mencionan que en tareas de predicción las RNA no superan nunca la efectividad de los métodos estadísticos y que por el contrario, en las tareas de clasificación las RNA superan a los métodos estadísticos.

Por otro lado, Chen *et al.* (2001) utilizaron la RNA para predecir cambios cualitativos durante el secado osmoconvectivo de arándanos y compararon la predictibilidad de la RNA con el modelo de regresión lineal múltiple, encontrando que la RNA tuvo mejor desempeño. Pitarque *et al.* (1998) compararon mediante simulación, redes neuronales del tipo perceptrón multicapa con modelos estadísticos (regresión múltiple, análisis discriminante y regresión logística) en tareas de predicción y clasificación. Los resultados muestran que en tareas de predicción la RNA y modelos de regresión múltiple tienden a rendir por igual.

Tabla 5

Análisis de varianza entre los valores esperados con los valores predichos por la RNA y por la ecuación de segundo orden ajustado por regresión.

Variable	Origen de variación	SC	gl	CM	F	p	Crítico
Masa	Entre grupos	1.40E-05	2	7.00E-06	0.0001	0.9999	3.4028
	Dentro de los grupos	1.370173	24	0.05709			
	Total	1.370187	26				
Humedad	Entre grupos	0.3318	2	0.1659	0.0006	0.9994	3.4028
	Dentro de los grupos	6873.653	24	286.4022			
	Total	6873.984	26				
Volumen	Entre grupos	0.000635	2	0.00032	0.0053	0.9948	3.4028
	Dentro de los grupos	1.451594	24	0.06048			
	Total	1.45223	26				
Sólidos	Entre grupos	0.014022	2	0.00701	0.0065	0.9936	3.4028
	Dentro de los grupos	26.07904	24	1.08663			
	Total	26.09307	26				
Difusividad efectiva media	Entre grupos	3.15E-19	2	1.58E-19	0.0597	0.9422	3.4028
	Dentro de los grupos	6.33E-17	24	2.64E-18			
	Total	6.36E-17	26				
Difusividad efectiva media (con encogimiento)	Entre grupos	9.85E-20	2	4.93E-20	0.0508	0.9505	3.4028
	Dentro de los grupos	2.33E-17	24	9.69E-19			
	Total	2.34E-17	26				

4. Conclusiones

Con la RNA del tipo *Feedforward*, con los algoritmos de entrenamiento *Backpropagation* y de ajuste de pesos *Levenberg-Marquardt* y con una topología final de aplicación de: 2 neuronas de entrada (concentración y temperatura), 6 neuronas de salida (masa, humedad, volumen, sólidos y la difusividad efectiva media con y sin encogimiento), 1 capa oculta, 18 neuronas en la capa oculta, 15 etapas o ciclos de entrenamiento, tasa de aprendizaje 0.01, coeficiente de momento 0.5 y un error meta de 10^{-5} , se logró predecir satisfactoriamente los valores correspondientes a las variables salida, obteniendo un error global promedio de 3.44% y coeficientes de correlación mayores a 0.99 en la comparación de los valores experimentales con los valores predichos. Las mejores predicciones, representadas por el coeficiente de correlación (R) y el error porcentual promedio, se consiguieron para la variable masa (0.9977 y 1.68%) y para la variable humedad (0.9988 y 1.64%). Las otras predicciones encontradas fueron: volumen (0.9723 y 6.76%), sólidos (0.9071, 3.01%), difusividad efectiva media (0.9623 y 3.97%) y difusividad efectiva media con encogimiento (0.9009 y 3.59%).

El menor error cuadrático medio conseguido en el entrenamiento de la RNA escogida y con la topología mencionada fue de 9.247×10^{-5} .

No se encontraron diferencias significativas entre los valores experimentales esperados con los valores predichos por la RNA y con los valores predichos por la ecuación ajustada de regresión de segundo orden completo.

Referencias bibliográficas

Alvarado, J. D.; Aguilera, J. M. 2001. Métodos para medir propiedades físicas en industrias de alimentos. Edit. Acribia S.A. Zaragoza. p. 394.

Aliaga, E.; Vásquez, V.; Rojas, J. 2009. Estudio comparativo de la capacidad de predicción por Redes Neuronales Artificiales, Modelos de Regresión Estadística y Métodos Matemáticos del efecto de la temperatura y tiempo de esterilización en el valor F_0 de un enlatado de cabrito (*Capra hircus*) a la norteña. Tesis para optar el Título Profesional de Ingeniería

Agroindustrial. Universidad Nacional de Trujillo. Facultad de Ciencias Agropecuarias. p. 162-164.

Amiel, R.; Vásquez, V. 2007. Influencia de la temperatura en la difusividad efectiva y características sensoriales de cubos de yacón (*Smallantus sonchifolius*) deshidratado osmóticamente. Tesis para obtener el Título de Ingeniero Agroindustrial. Universidad Nacional de Trujillo. Facultad de Ciencias Agropecuarias. p. 76-77.

A.O.A.C. – Association of Official Analytical Chemist. 1995. Official Methods of Analysis Chemist. 16 Edition. Arlington.

Arahal, M. R.; Berenguel, M.; Rodríguez, F. 2006. Técnicas de predicción con aplicaciones en Ingeniería. Edit. Secretariado de publicaciones de la Universidad de Sevilla. p. 19, 88.

Azuara, E.; Cortez, R.; García, H. S.; Beristain, C. I. 1992. Kinetic model for osmotic dehydration and its relationship with Fick's second law. International Journal of Food Science and Technology 27 (4): 409-418.

Brennan, J.G. 2008. Manual del procesado de los alimentos. Edit. Acribia. S.A. Zaragoza. p. 104.

Casp, A.; Abril, J. 2003. Procesos de conservación de alimentos. Ediciones Mundi Prensa. Madrid. p. 384-385

Corzo, O.; Centeno, A. E. 2003. Superficies de respuesta de la transferencia de masa durante la deshidratación osmótica del melón (*Cucumis melo*) variedad Edisto. Revista de la Facultad de Farmacia de la Universidad de Oriente 45 (1): 54-55.

Cueva, J. A.; Vásquez V. 2009. Predicción mediante Redes Neuronales Artificiales de sacarosa de caña de azúcar (*Saccharum officinarum*) a partir de sólidos solubles y humedad. Tesis para optar el Grado de Maestro. Escuela de Postgrado. Universidad Nacional de Trujillo. p. 90.

Chegini, G.R.; Khazaei, J.; Ghobadian, B.; Gourdarzi, A.M. 2008. Prediction of process and product parameters in an orange juice spray dryer using artificial neural networks. Journal of Food Engineering 84: 534-543.

Chen, C.R.; Ramaswamy, H.S.; Alli, I. 2001. Prediction of quality changes during osmo-convective drying of blueberries using neural network models for process optimization. Drying Technology 19: 515.

Esen, H.; Inalli, M.; Sengur, A.; Esen, M. 2007. Forecasting of a ground-coupled heat pump performance using neural networks with statistical data weighting pre-processing. International Journal of Thermal Sciences 2007: 1-11.

Gutiérrez, H.; De La Vara, R. 2003. Análisis y diseños de experimentos. Edit. McGraw-Hill Interamericana. México. p. 430.

Ibarz, A.; Barbosa-Canovas, G. V. 2005. Operaciones unitarias en la Ingeniería de Alimentos. Ediciones Mundi Prensa. Madrid. p. 621.

Isasi, P.; Galván, I. M. 2004. Redes Neuronales Artificiales. Un enfoque práctico. Edit. Pearson Educación S.A. Madrid. p. 90.

Kerdpiroon, S; Kerr, W. L.; Devahastin, S. 2006. Neural network prediction of physical property changes of dried carrot as a function of fractal dimension and moisture content. Food research international 39: 1110-1118

Lertworasirikul, S.; Tipsuwan, Y. 2008. Moisture content and water activity prediction of semi-finished cassava crackers from drying process with Artificial Neural Network. Journal of food Engineering 84: 65-74.

- Liboni, L.; Park, Y. 2003. Frutooligosacarídeos: implicações na saúde humana e utilização em alimentos. *Ciência Rural*, Santa Maria, 33(2): 385-390.
- Madrigal, L.; Sangronis, E. 2007. La inulina y derivados como ingredientes claves en alimentos funcionales. *Archivos Latinoamericanos de Nutrición* 57: 387-396.
- Manrique, I.; Hermann, M. 2003. El potencial del yacón en la salud y la nutrición. XI Congreso Internacional de Cultivos Andinos. Cochabamba. p. 1.
- Martín, Q.; De Paz, Y. R. 2007. Aplicación de las Redes Neuronales Artificiales a la regresión. Edit. La muralla S.A. Madrid. p. 52.
- Millan, F.R.; Ostojich, Z. 2006. Predicción mediante redes neuronales artificiales de la transferencia de masa en frutas osmóticamente deshidratadas. *Ciencia y Tecnología de América* 31 (03): 206-210.
- Millan, F.R.; Roa, V.; Tapia, M.S. 2001. Modelado matemático de isotermas de adsorción de humedad en alimentos usando redes neuronales artificiales. *Ciencia y Tecnología de América* 26(05): 191-193.
- Moura, C. P.; Mason, M. L.; Yamamoto, C.I. 2004. Prediction of osmotic pretreatment parameters using neural networks models for process optimization. *Drying 2004-Proceeding of the 14th International Drying Symposium* 1: 589-596.
- Movagharnjad, K.; Nikzad, M. 2007. Modeling of tomato drying using Artificial Neural Network. *Computers and electronics in agriculture* 59: 78-85.
- Ochoa-Martínez, C. I.; Ayala-Aponte, A. 2005. Modelos matemáticos de transferencia de masa en deshidratación osmótica. *Ciencia y tecnología Alimentaria* 4 (5): 334.
- Ochoa-Martínez, C. I.; Ramaswamy, H. S.; Ayala-Aponte, A. 2007,a. Artificial Neural Network modeling of osmotic dehydration mass transfer kinetics of fruits. *Drying Technology* 25: 85-95.
- Ochoa-Martínez, C. I.; Ramaswamy, H. S.; Ayala-Aponte, A. 2007,b. ANN-Bassed models for moisture diffusivity coefficient and moisture loss at equilibrium in osmotic dehydration process. *Drying Technology* 25: 775-783.
- Ojansivu, I.; Ferreira, C. L.; Salminen, S. 2010. Yacon, a new source of prebiotic oligosaccharides with a history of safe use. *Trends in Food Science & Technology* 22 (1): 40-46.
- Paredes, H.; Vásquez, V.; Rojas, J. 2009. Predicción del azúcar recuperable en caña de azúcar (*Saccharum officinarum*) a partir de la concentración de sólidos solubles y contenido de humedad empleando redes neuronales artificiales. Informe de capacidad profesional para obtener el Título de Ingeniero Agroindustrial. Universidad Nacional de Trujillo. Facultad de Ciencias Agropecuarias. p. 31.
- Pitarque, A.; Ruiz, J.C.; Roy, J.F. 1998. Redes Neuronales versus modelos estadísticos. Simulaciones sobre tareas de predicción y clasificación. *Psicológica* 19: 387-388.
- Pitarque, A.; Ruiz, J. C.; Roy, J. F. 2000. Las redes neuronales como herramientas no paramétricas de clasificación. *Psicothema* 12 (2): 459-463.
- Poonnoy, P.; Tansakul, A.; Chinnan, M. 2007. Artificial Neural Network Modeling for Temperatura and Moisture Content Prediction in Tomato Slices Undergoing Microwave-Vacuum Drying. *Journal of Food Science* 72 (1): 42-47.
- Saiedirad, M.H.; Mirsalehi, Y. 2010. Prediction of mechanical properties of cumin seed using artificial neural networks. *Journal of Texture Studies* 41: 34-48.
- Seminario, J.; Valderrama, M.; Manrique, I. 2003. El yacón: fundamentos para el aprovechamiento de un recurso promisorio. Centro Internacional de la Papa (CIP), Universidad Nacional de Cajamarca. Agencia Suiza para el Desarrollo y la Cooperación (COSUDE), Lima, Perú. p 1-60.
- Vásquez, V.; Lescano, C. 2010. Predicción por redes neuronales artificiales de la calidad fisicoquímica de vinagre de melaza de caña por efecto de tiempo-temperatura de alimentación a un evaporador destilador-flash. *Scientia Agropecuaria* 1(1): 63-73.