

Selección de una Arquitectura de Red Neuronal Artificial eficiente para predecir el coeficiente de difusividad másica del aguaymanto (*Physalis peruviana* L.) deshidratado osmoconvectivamente.

Mayra S. Bazalar Pereda¹ & Mario A. Tejerina² & José H. Paganini² & Soledad C. Gonzalez²

(1) *Sección de Postgrado, Universidad Nacional de Trujillo (Perú).*
mayrasbp@hotmail.com

(2) *Cátedra de Base de Datos, Facultad de Ingeniería, Universidad Nacional de Jujuy.*
mariotejerina@hotmail.com & joseh.paganini@gmail.com & scarolineg@gmail.com

RESUMEN: En el presente trabajo se investiga la selección de una arquitectura de Red Neuronal Artificial (RNA) que permita predecir de forma eficiente el efecto del tamaño del fruto, concentración y temperatura de jarabe de sacarosa en la difusividad másica del aguaymanto deshidratado osmoconvectivamente. El desarrollo se centra en el estudio y análisis del proceso de deshidratación osmoconvectiva de aguaymanto y la determinación de parámetros adecuados de la RNA con algoritmo de entrenamiento Backpropagation y ajustes de pesos Levenberg-Marquart. A partir de esto se determina el modelo neuronal para la predicción del coeficiente de difusividad que obtuvo un error promedio mínimo de 0.5392% al comparar los valores reales con los valores predichos por la red neuronal. De esta manera se concluye en validar la eficiencia de la arquitectura de la RNA estudiada en la predicción del coeficiente de difusividad en el deshidratado osmoconvectivo del aguaymanto, y se proponen trabajos futuros dentro de los dominios de las base de datos deductivas que permitan definir nuevas relaciones en términos de las relaciones bases y el procesamiento de consultas.

INTRODUCCIÓN

En la actualidad existe una amplia tendencia mundial por la investigación y desarrollo de técnicas de conservación de alimentos que permitan obtener productos de alta calidad nutricional, que sean muy similares en color, aroma y sabor a los alimentos frescos y que no contengan agentes químicos conservantes. Entre las técnicas que son objeto de investigación para su aplicación se halla la deshidratación osmótica. Esta técnica permite obtener productos que reúnen las características mencionadas y además los costos de producción son más bajos si se compara con técnicas que emplean calor o frío para los diferentes procesos de deshidratación (Empleo en la deshidratación osmótica en frutas, 2009).

La deshidratación osmótica consiste en la inmersión de un alimento ya sea entero o en piezas, en una solución acuosa de alta concentración de soluto. Esto provoca al menos dos flujos en contra corriente: un flujo de agua del alimento a la solución y una transferencia de

soluta desde la solución hacia el alimento. De manera general en función de los mecanismos de transporte de materia, las variables que afectan el proceso de deshidratación osmótica y que pueden manejarse operativamente son: temperatura del proceso, concentración de la solución osmótica, naturaleza del agente osmótico utilizado, presión, relación masa producto a volumen de solución osmótica y agitación.

El modelado predictivo de contenido de agua que permanece en la fruta, la reducción de peso, la pérdida de agua, la ganancia de sólidos que proviene del jarabe y la actividad del agua en alimentos sometidos a la deshidratación osmótica, reviste importancia para la exploración predictiva de condiciones no experimentadas, con el objeto de optimizar los fenómenos de transferencia de masa y reducir el costo del proceso. Son diversos los modelos matemáticos de naturaleza mecanicista o empírica, propuesta hasta el momento para modelar la deshidratación osmótica (Millán y Ostojich, 2006).

La más reciente área de investigación en aplicación de nuevas técnicas de modelamiento y

simulación de procesos es el de redes neuronales artificiales (RNA). Con la disminución del coste de computación y aumento del poder de cálculo de las microcomputadoras, las RNA han sido blanco de un gran esfuerzo en el sentido de dominar la técnica y establecer procedimientos de uso. Las RNA son estructuras matemáticas basadas en el funcionamiento del cerebro humano, en una tentativa de imitar la inteligencia. Están formadas por unidades básicas, las neuronas, la estructura neuronal busca copiar la forma de conexión de una neurona con otro cerebro. La RNA es una estructura matemática capaz de aprender a través de experiencias pasadas, o sea, adaptativo, el cual no necesita de conocimiento primario relacionado con el proceso tecnológico en cuestión (De Moura, 2004).

Una característica de los procesos en ingeniería de alimentos es que la mayoría presenta fuertes no-linealidades que dificultan bastante la obtención de modelos fenomenológicos, a punto de conseguir en algunos casos sólo un modelo extremadamente simplificado de validez en condiciones específicas. Es exactamente en este campo que las redes neuronales surgen como una técnica interesante para ser empleada debido a su característica de aprender. Sin embargo, el éxito del modelamiento y control de procesos vía red neuronal depende fuertemente del conocimiento de las principales variables del proceso, además de tener una base de datos de buena calidad en el dominio deseado (Hilera, 2000).

De Moura (2004) señala que aunque existan muchos tipos de redes neuronales, la red más empleada en la tecnología e ingeniería de alimentos es la multicapa *Feedforward*, cuya información sigue una única dirección. Las etapas para el desarrollo de un modelo de red neuronal pueden ser descritas como: análisis del proceso y construcción de la base de datos; configuración de una estructura de red neuronal, entrenamiento o aprendizaje de la red y validación para verificar la eficiencia de la red con la presentación de nuevos datos experimentales. La metodología para la fase de entrenamiento de las redes neuronales es conocida como método de retropropagación (algoritmo *Backpropagation*).

El modelado predictivo de variables operacionales y difusividad en alimentos sometidos a la deshidratación osmótica, reviste importancia para la exploración predictiva de condiciones no experimentadas, con el objeto de optimizar los fenómenos de transferencia de masa y reducir el costo del proceso. El desarrollo de RNA surge como una metodología alternativa a las técnicas de predicción basadas en la estadística paramétrica, con amplias perspectivas

de aplicación en la caracterización de sistemas no lineales en tecnología de alimentos (Millán y Tapia, 2001).

En esta investigación, se buscó validar la metodología de Red Neuronal Artificial determinando su arquitectura a través del número de capas, número de neuronas, tasa de aprendizaje y coeficiente de momento que permitan predecir por efecto del tamaño del fruto (1.8 cm y 2.2 cm de diámetro), concentración (50°Brix y 70°Brix) y temperatura (40°C y 60°C) de jarabe de sacarosa, la difusividad másica de aguaymanto (*Physalis peruviana* L.) deshidratado osmoconvectivamente.

MATERIALES Y MÉTODOS

1.1 *Proceso de deshidratación osmoconvectiva*

El proceso de osmodeshidratación se realizó empleando un equipo de baño maría dentro del cual se colocó un recipiente de vidrio para contener el jarabe con los frutos, la temperatura estuvo controlada por un termómetro sujeto al recipiente. El jarabe se mantuvo agitado a una velocidad constante de 140 rpm.

Se utilizaron para el diseño experimental cuatro variables independientes que fueron el tamaño del fruto (2 niveles), tipo de jarabe (1 nivel), concentración del jarabe (2 niveles) y temperatura del jarabe (2 niveles), con los cuales se obtuvieron 8 tratamientos. Cada tratamiento con 3 repeticiones, siendo un total de 24 unidades experimentales. Cada unidad experimental estuvo conformada por una muestra de 50 frutos de aguaymanto los cuales se seleccionaron y clasificaron considerando el estado de madurez, tamaño y peso. Los frutos fueron sometidos a un previo lavado con agua y se tomaron muestras para determinar el contenido inicial de sólidos y contenido de agua inicial. Se realizó el pelado manual y se pesaron los frutos para conocer el peso inicial. Se prepararon soluciones de sacarosa a 50°Brix y 70°Brix de concentración y a temperaturas de 40°C y 60°C. La relación fruta-solución osmótica fue de 1:10. Se sumergieron los frutos y se mantuvo agitación constante. Las muestras inmersas en cada combinación concentración-temperatura se fueron retirando de la solución osmótica cada media hora durante las tres primeras horas de proceso y posteriormente cada hora hasta alcanzar el tiempo de equilibrio. Se determinaron la pérdida de agua, reducción de peso, agua contenida en cada una de las muestras para cada tiempo. El deshidratado osmótico se complementó con secado convectivo a 60°C hasta alcanzar humedad aproximada de 17%. El valor

de humedad final se consideró, teniendo en cuenta investigaciones realizadas anteriormente en deshidratación osmótica de frutas (Sousa y Maia, 2003).

1.2 Determinación del coeficiente de difusividad

Se determinó el coeficiente de difusividad con los datos de pérdida de agua con respecto al tiempo obtenidos durante el proceso de deshidratación osmótica. Se utilizó el método recomendado por Azuara y Berinstain (1992), citado por Azoubel y Murr (2000), para cuerpos esféricos y tiempos cortos sin deformación por lo que fue importante determinar hasta que tiempo considerar en la investigación para aplicar este modelo matemático. Según El-Aquar y Murr (2003), el tiempo considerado en la cinética de deshidratación osmótica es aquel en donde la pérdida de agua ocurre más intensamente, es decir el tiempo en donde la pérdida de agua alcanza más de la mitad del valor alcanzado en el equilibrio. Se consideró en esta investigación lo propuesto por estos autores. El coeficiente de difusividad para diferentes tiempos se determina con la ecuación (1).

$$D_t = \frac{\pi t}{36} \left[\left(\frac{S_1 r}{1 + S_1 t} \right) \left(\frac{WL_\infty^{\text{mod}}}{WL_\infty^{\text{exp}}} \right) \right]^2 \quad (1)$$

Donde D_t es el coeficiente de difusividad en el tiempo t ; WL_∞^{mod} es el valor en equilibrio obtenido de la ecuación (2); WL_∞^{exp} es el valor en equilibrio obtenido de la experimentación.

Los valores para S_1 y WL_∞ se calculan por regresión lineal, usando los datos experimentales de pérdida de agua (WL) obtenidos durante un corto periodo de tiempo. Estos valores se determinan con la ecuación (2).

$$\frac{t}{WL} = \frac{1}{S_1(WL_\infty)} + \frac{t}{WL_\infty} \quad (2)$$

Donde $1/WL_\infty$ puede ser determinado de la pendiente de graficar t/WL contra t .

1.3 Desarrollo del modelo neuronal

La Red Neuronal fue diseñada con el software Neuronal Network Tool Box de Matlab versión 6.5 para Windows. La arquitectura de la RNA se muestra en la Fig. 1.

De los 24 conjuntos de datos para obtener el coeficiente de difusividad se escogió el 75% (18 datos) para el entrenamiento de la red y el 25% (6 datos) para la validación. Para la selección de los datos se utilizó la función Aleatorio de Excel 2003 de Microsoft.

El entrenamiento de la red neuronal artificial se realizó utilizando el algoritmo Backpropagation que es una técnica de entrenamiento supervisado, donde los pesos y los sesgos se inician al azar al empezar el entrenamiento. Para un determinado conjunto de datos de entrada a la red se calcula una respuesta para cada neurona de salida y se compara con la respuesta deseada correspondiente. Para el entrenamiento de la RNA se usó la función del programa Matlab:

`[net,tr]= train (net,p,t)`

Donde p: matriz de datos de entrada, t: matriz de datos de salida.

Una vez entrenada correctamente la red con el conjunto de datos de entrenamiento, se valida la red neuronal artificial con la siguiente instrucción: `a= sim(net,p)`

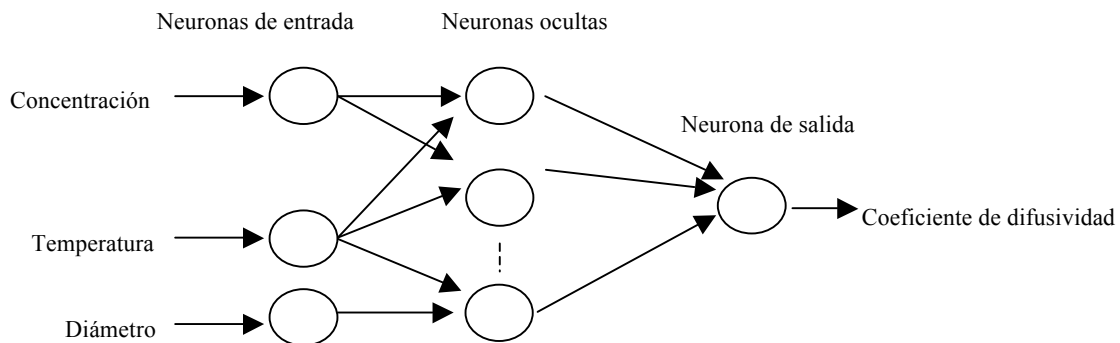


Figura1. Arquitectura de la RNA para la predicción del coeficiente de difusividad.

La topología básica de la RNA con la que se inició el entrenamiento fue la siguiente:

```
net = newff([50 70; 40 60; 1.8 2.2],[2,1],{'tansig','purelin'},'trainlm');
```

Donde: 50 y 70 representan el valor mínimo y máximo de las concentraciones del jarabe de sacarosa, 40 y 60 son los valores mínimo y máximo de la temperatura del jarabe de sacarosa, 1.8 y 2.2 son los valores mínimo y máximo del diámetro del fruto, 2 es el número de neuronas en la capa oculta, 1 es el número de variable de salida (Coeficiente de difusividad), Tansig es la función de transferencia sigmooidal de la capa oculta, Purelin es la función de transferencia lineal de la capa de salida, Trainlm es el algoritmo de entrenamiento Levenberg Marquardt.

La configuración inicial de la red neuronal en el lenguaje de programación de Matlab se estableció con los siguientes parámetros:

```
net.trainparam.epochs = 50;
```

```
net.trainparam.goal = 1e-4;
```

```
net.trainparam.lr = 0.01;
```

```
net.trainparam.mc = 0.5;
```

Con esta topología se entrenó la red para encontrar el error cuadrático medio de menor valor.

RESULTADOS Y DISCUSIONES

1.1 Coeficientes de difusividad

Los valores de coeficientes de difusividad que se obtuvieron en el proceso de deshidratación osmótica oscilaron entre $5.17E-10$ m²/s para el tratamiento que utilizaron frutos de 2.2 cm de diámetro en jarabe concentrado a 50°Brix y 40°C hasta $1.49E-09$ m²/s para el tratamiento que utilizaron frutos de 1.8 cm de diámetro en jarabe concentrado a 70°Brix y 60°C de temperatura.

1.2 Número de neuronas

El número de neuronas se varió de 1 en 1 en la capa oculta hasta llegar a 100 neuronas en la predicción del coeficiente de difusividad. Según Hilera y Martínez (2000), el número de neuronas ocultas intervienen en la eficacia del aprendizaje y generalización de la RNA. No hay ninguna regla que indique el número óptimo, en cada problema se debe ensayar con distintos números de neuronas para organizar la representación interna y escoger el mejor en función del error cuadrático medio. Con los resultados obtenidos para cada una de las 100 neuronas, se escogieron los que arrojaron los valores más bajos de error cuadrático medio.

1.3 Variación del error deseado (goal)

Según el número de neuronas en las que se obtuvieron los valores más bajos de error cuadrático medio, se varió el error deseado (goal) obteniéndose un valor de $2.65700E-22$ para 53 neuronas en una capa oculta. El error deseado (goal) escogido de 10^{-21} se obtuvo luego de probar con errores de 10^{-4} hasta 10^{-25} para el coeficiente de difusividad, encontrándose que a partir de 10^{-21} el error se hace constante, tal como se observa en la Tabla 1. Autores como Cueva (2009) y Bazán (2008) también encontraron el error deseado utilizando esta metodología.

1.4 Variación de los ciclos de entrenamiento

Los ciclos de entrenamiento se variaron para 53 neuronas y error (goal) de $1.00E-21$ hasta obtener error mínimo de $2.65700E-22$ para 6 ciclos de entrenamiento, a partir de este ciclo el error se mantiene constante como muestra la Tabla 2.

1.5 Variación de las funciones de transferencia

La variación de las funciones de transferencia se realizó combinando las funciones tansig, logsig y purelin. Se analizó las diferentes funciones de transferencia, como se observa en la Tabla 3, determinándose que la combinación tansig – purelin arrojó el error más bajo de $2.657003E-22$ para la predicción del coeficiente de difusividad. Según Hilera y Martínez (2000), para determinar la función de transferencia se debe tener en cuenta que para aprovechar la capacidad de la red neuronal de aprender relaciones complejas no lineales entre variables, es absolutamente imprescindible la utilización de funciones no lineales al menos en las neuronas de la capa oculta. Por otra parte, la función de transferencia en las neuronas de la capa de salida en tareas de predicción, generalmente toman la función lineal (purelin).

1.6 Variación de la Tasa de Aprendizaje

Se varió la tasa de aprendizaje de 0.001 a 1.0 manteniéndose constante el error cuadrático medio en $2.65700E-22$.

La tasa de aprendizaje escogida fue de 0.01, valor usado por Bazán (2008) y Cueva (2009). Martín y De Paz (2007) indican que la tasa de aprendizaje tiene un papel crucial en el proceso de entrenamiento de una RNA, ya que controla el tamaño del cambio de los pesos en cada interacción. Ambos autores señalan que las tasas de aprendizaje más usadas están en el rango de 0.01 a 0.5.

1.7 Variación de la Tasa de Momento

Al variar la tasa de momento de 0.2 a 2.0 el error cuadrático medio no varía y se mantiene constante en 2.65700E-22. Para la simulación se utilizó la tasa de aprendizaje de 0.5, valor usado por Chen y otros (2001). Este valor se encuentra dentro del rango establecido por ellos, ya que concluyeron que variando la tasa de momento de 0.2 a 0.8 no afectaba el error. Millan y Ostojich (2006) trabajaron con un coeficiente de momento de 0.5 señalando que el momento actúa como un amplificador de tasas de aprendizaje pequeñas, pues garantizan tasas de aprendizaje eficientes.

1.8 Topología y configuración final de la RNA

Los diseños de la topología y configuración final de la RNA en el lenguaje Matlab fueron:

```
net = newff([50 70; 40 60; 18 2.2],[53,1],{'tansig','purelin'},'trainlm');
net.trainparam.lr= 0.01;
net.trainparam.goal=1e-21;
net.trainparam.epochs= 6;
net.trainparam.mc= 0.5;
```

1.9 Entrenamiento y Validación de la RNA

Se entrenó la red neuronal artificial con el diseño de la topología y configuración final utilizando los datos de entrada y salida. Con los datos separados para la validación se realizó la comparación entre los valores esperados o reales y los valores predichos por la red neuronal artificial, obteniéndose 0.5392% de error promedio. Los resultados se muestran en la Tabla 4.

Tabla 1. Variación del error deseado con una capa oculta en la predicción del coeficiente de difusividad.

Error deseado	N° de Neuronas					
	4	13	25	53	78	96
1.00E-04	1.10303E-09	6.62469E-09	8.35591E-09	4.34213E-10	8.92151E-10	1.65576E-09
1.00E-09	1.74386E-12	4.55136E-17	1.54841E-17	4.34213E-10	8.92151E-10	8.63025E-20
1.00E-11	2.61953E-13	4.55136E-17	1.54841E-17	7.82073E-21	1.52901E-19	8.63025E-20
1.00E-13	3.68307E-14	4.55136E-17	1.54841E-17	7.82073E-21	1.52901E-19	8.63025E-20
1.00E-15	6.91628E-16	4.55136E-17	1.54841E-17	7.82073E-21	1.52901E-19	8.63025E-20
1.00E-17	1.81175E-18	2.95900E-21	2.95900E-21	7.82073E-21	1.52901E-19	8.63025E-20
1.00E-19	3.19995E-19	2.95900E-21	2.95900E-21	7.82073E-21	2.95900E-21	8.63025E-20
1.00E-21	3.19995E-19	2.95900E-21	2.95900E-21	2.65700E-22	2.95900E-21	2.95900E-21
1.00E-23	3.19995E-19	2.95900E-21	2.95900E-21	2.65700E-22	2.95900E-21	2.95900E-21
1.00E-25	3.19995E-19	2.95900E-21	2.95900E-21	2.65700E-22	2.95900E-21	2.95900E-21

Tabla 2. Variación de los ciclos de entrenamiento con una capa oculta en la predicción del coeficiente de difusividad.

Ciclos de Entrenamiento	Neurona N° 53
4	4.3421E-10
5	7.82073E-21
6	2.65700E-22
15	2.65700E-22
25	2.65700E-22
50	2.65700E-22
100	2.65700E-22
150	2.65700E-22

Tabla 3. Variación de las funciones de transferencia con una capa oculta en la predicción del coeficiente de difusividad.

Capa oculta	Capa de salida	Error cuadrático medio
tansig	purelin	2.65700E-22
logsig	purelin	2.65700E-22
purelin	purelin	8.3661E-21
tansig	tansig	2.7702E-22
logsig	tansig	2.6612E-22
purelin	tansig	-
tansig	logsig	1.09365E-06
logsig	logsig	8.50887E-07

Tabla 4. Comparación de los valores esperados (reales) y los valores predichos por la RNA en la predicción con una capa oculta del coeficiente de difusividad en la deshidratación osmoconvectiva.

Tratamiento	Valor esperado (real)	Valor predicho (RNA)	Error (%)
70°Brix-40°C-1.8 cm	1.3218E-09	1.3406E-09	1.4223
70°Brix-40°C-2.2 cm	1.0183E-09	1.0198E-09	0.1473
50°Brix-40°C-1.8 cm	5.9437E-10	5.9537E-10	0.1682
50°Brix-40°C-2.2 cm	5.3241E-10	5.2941E-10	0.5635
50°Brix-60°C-1.8 cm	1.1396E-09	1.1296E-09	0.8775
50°Brix-60°C-2.2 cm	9.2305E-10	9.2357E-10	0.0563
Error Promedio (%)			0.5392

CONCLUSIÓN

El estudio y análisis del proceso de deshidratación osmoconvectiva de aguaymanto junto a los resultados obtenidos en los experimentos realizados permitió determinar que la arquitectura de la RNA que arrojó porcentaje de error de 0.5392 al comparar los valores reales con los predichos por la red en la predicción del coeficiente de difusividad para la deshidratación osmoconvectiva de aguaymanto utilizando jarabe de sacarosa, es la red del tipo feedforward con algoritmo de entrenamiento Backpropagation y de ajuste de pesos Levenberg-Marquart, con 6 ciclos de entrenamiento, topología constituida por tres neuronas (concentración, temperatura y diámetro) en la capa de entrada, 53 neuronas en la capa oculta y una neurona de salida (coeficiente de difusividad), función de transferencia en la capa oculta tansig y en la capa de salida purelin, el coeficiente de momento de 0.5, tasa de aprendizaje de 0.01 y error de 10^{-21} , que permitió predecir satisfactoriamente los valores correspondientes a la variable de salida.

Se propone como trabajo futuro el uso de una base de dato deductiva que permita realizar estudios y pruebas para adaptar las relaciones de base obtenidas a un esquema de base de datos lógica. De esta manera se lograría inferir resultados a partir del mapeo de relaciones sobre hechos almacenados en una base de datos relacional, para su posterior conversión a vistas o consultas SQL que puedan ser ejecutadas sobre cualquier sistema informativo.

REFERENCIAS

- Azoubel, P. & F. Murr, Mathematical Modelling of the Osmotic Dehydration of Cherry Tomato, *Ciência e Tecnologia de Alimentos*, 20, 228 – 232, 2000.
- Azuara, E. & C.I. Berinstain, Development of a mathematical model to predict kinetics of osmotic dehydration, *Journal of Food Science Technology*, 29, 239-242, 1992.
- Bazán, J.A., *Predicción por Redes Neuronales Artificiales del efecto de la nebulización de los insecticidas Solfac (Cyfutrín) y Knockdown (Cipermetrina-Tetrametrina-Butóxido de Piperonilo) en la desinsectación de áreas de procesamiento de una empresa cervecera*, Facultad de Ciencias Agropecuarias, Universidad Nacional de Trujillo, Perú, 2008.
- Chen, C.R., H.S. Ramaswamy & I. Alli, Prediction of quality changes during osmoconvective drying of blueberries using neural network models for process optimization, *Drying Technology*, 19, 507-523, 2001.
- Cueva, J.A., *Predicción mediante Redes Neuronales Artificiales de sacarosa de caña de azúcar (Saccharum officinarum) a partir de sólidos solubles y humedad*, Escuela de Postgrado, Universidad Nacional de Trujillo, Perú, 2009.
- De Moura, C., *Aplicação de redes neuronais para a predição e otimização do processo de secagem de yacon (Polymnia sonchifolia) com pré-tratamento osmótico*, Universidade Federal do Paraná, Curitiba, Brasil, 2004.
- Empleo en la deshidratación osmótica en frutas, Link:<http://www.virtual.unal.edu.co/cursos/agronomia/2006228/teoria/obfrudes/p3.htm>, 2009, Fecha de Adquisición de la Información: 22/01/2011.
- El-Aquar, A. & F. Murr, Estudio e modelagem da cinética de desidratação osmótica do mamão formosa (Carica papaya L.). *Ciência e Tecnologia de Alimentos*, 23, 69 – 75, 2003.
- Hilera, J.R. & V.J. Martínez, *Redes Neuronales Artificiales. Fundamentos. Modelos y Aplicaciones*, Alfa omega Ra-Ma, Madrid, España, 2000.
- Martin, Q. & Y.R. De Paz, *Aplicación de las Redes Neuronales Artificiales a la regresión*, La Muralla S.A., Madrid, 2007.
- Millán, F. & Z. Ostojich, Predicción mediante redes neuronales artificiales de la transferencia de masa en frutas osmoticamente deshidratadas, *Interciencia*, 31, 206-210, 2006.
- Millán, F., V. Roa & M. Tapia, Modelado matemático de isoterma de adsorción de humedad en alimentos usando redes neuronales artificiales, *Interciencia*, 26, 190 -194, 2001.
- Neural Networks data analysis using Simulnet, <http://www.psiquiatria.com/psicologia/revista>, Marzo 2009.
- Sousa, P. & G. Maia, Influência da concentração e da proporção fruto:xarope na desidratação osmótica de bananas procesadas. *Ciência e Tecnologia de Alimentos*, 23, 126-130, 2003.