



Redes neuronales artificiales para la modulación predictiva de la permeabilidad al vapor de agua de películas de quitosana con arcilla

Artificial neural networks for predictive modulation of water vapor permeability of clay-based chitosan films

Dairon Iglesias Guevara*, Maribel Pino Hernández, Alicia Casariego Año, Marcos A. González Correa, Maikel Negrín Hernández.

Universidad de La Habana. Instituto de Farmacia y Alimentos. La Habana, Cuba.

* daironig1993@gmail.com

(recibido/received: 22-agosto-2023; aceptado/accepted: 17-noviembre-2023)

RESUMEN

El objetivo de este trabajo es aplicar las Redes Neuronales Artificiales (RNA) para la modelación predictiva de la permeabilidad al vapor de agua de películas de quitosana con arcilla, siendo este uno de los factores más importantes en la caracterización de películas y recubrimientos comestibles. Para ello se tomaron 30 conjuntos de datos aleatorios de la base de datos obtenidos por Casariego y col. (2009), para el entrenamiento selección y validación; y 10, igualmente aleatorios con el objetivo de introducir valores ajenos al entrenamiento de la Red y comparar los valores predichos contra resultados reales obtenidos en la base de datos utilizada. El diseño, programación y validación de la red se realizó en el Software Informático Neural Designer (Versión 591). Se eligió como modelo, Perceptron Multicapa; y una arquitectura de 3:5:1 (Capa de entrada: Capa oculta: Capa de salida) utilizando Tangente Hiperbólica como función de activación y Levenberg-Marguardt como algoritmo de aprendizaje. Se obtuvo un EMC de 0.00046 y un R^2 de 0.9207 en la Regresión de los datos reales contra los datos simulados, siendo esto un resultado satisfactorio que demuestra el correcto entrenamiento de la Red y la eficacia de la predicción.

Palabras claves: Red Neuronal Artificial, Permeabilidad, película, quitosano.

ABSTRACT

The objective of this work is to apply Artificial Neural Networks (ANN) for the predictive modeling of water vapor permeability of chitosan films with clay, this being one of the most important factors in the characterization of edible films and coatings. For this, 30 random data sets were taken from the database obtained by Casariego et al. (2009), for training selection and validation; and 10, equally occasional with the aim of introducing values outside the training of the Network and comparing the expected values against real results obtained in the database used. The design, programming and validation of the network was carried out in the Neural Designer Computer Software (Version 591). It was replaced as a model, Perceptron Multilayer; and a 3:5:1 architecture (Input Layer: Hidden Layer: Output Layer) using Hyperbolic Tangent as activation function and Levenberg-Marguardt as learning algorithm. An EMC of 0.00046 and an R^2 of

0.9207 were obtained in the Regression of the real data against the simulated data, this being a satisfactory result that demonstrates the correct training of the Network and the effectiveness of the prediction.

Keywords: Artificial Neural Network, Permeability, film, chitosan.

1. INTRODUCCIÓN

La creación de las redes neuronales artificiales (RNAs) se inspiró en el funcionamiento de las neuronas biológicas, y es por lo que recibieron dicho nombre. Su aparición data de los años cuarenta, cuando McCulloch y Pitts en 1943 abrieron una nueva puerta hacia un gran campo de la inteligencia artificial. Desde entonces, las RNAs han ido evolucionado, pero no fue hasta los años ochenta, con el diseño de los primeros perceptrones multicapa (vide infra), que el interés y uso de esta tecnología creció exponencialmente y es hoy en día utilizada en una gran variedad de áreas de investigación, tales como la medicina, ciencia de los alimentos, química, bioquímica, física, etc (Aroca, 2018). Las Redes Neuronales Artificiales, constituyen una herramienta potente para modelación de datos. Dentro de sus principales ventajas se incluyen la capacidad de modelación sin tener que hacer suposiciones acerca de la naturaleza de los mecanismos fenomenológicos que describen el proceso, la capacidad de aprender relaciones lineales y no lineales entre las variables desde un conjunto de ejemplos, la capacidad de modelar múltiples salidas simultáneamente y la aplicación del modelo a datos nuevos con precisión razonable (Ochoa, 2016). También ahorran experimentos exploratorios de evaluación de condiciones, entre otras ventajas. Por lo tanto es una forma efectiva de modelar matemáticamente el proceso, eliminando la dificultad de las variaciones que presentan las propiedades físicas ante la variación de determinado parámetro.

Por otro lado, el creciente interés por el desarrollo de películas y recubrimientos comestibles para incrementar la conservación de alimentos se debe fundamentalmente a las exigencias, cada vez mayores, de reducir el impacto en la contaminación ambiental que se ha producido con el incremento de desechos generados por el uso de envases y plásticos de origen sintético o no biodegradable para el empaque y distribución de alimentos (Bósquez, 2003). La alternativa más viable para solucionar esta problemática, la constituye el desarrollo de materiales biodegradables con propiedades funcionales como empaque y que ofrezcan costos competitivos a los materiales de empaque plásticos actuales (Bósquez, 2003).

Uno de los materiales biodegradables más usados para la formulación de recubrimientos comestibles, es la quitosana, polisacárido que ha tomado mucho auge por su poco impacto ambiental y su infinidad de aplicaciones, especialmente en la industria alimentaria (García y col., 2020). Ha demostrado poseer las características deseables para los productos frescos: buenas propiedades de barrera; insípido, transparente y posee además capacidad antioxidante y antimicrobiana (Fernández y col., 2015). Una de las dificultades que presentan las películas de quitosana está relacionada con su permeabilidad al vapor de agua (PVA), siendo esta una de las propiedades físicas más importantes. Para disminuir PVA de estas películas de naturaleza hidrofílica una de los métodos empleados es el aumento de la tortuosidad a la difusión mediante la adición de micro y nanopartículas como la zeolita y arcillas naturales (García y col., 2020). La eficiente barrera al vapor de agua de las películas es deseable para retardar la deshidratación de productos frescos (carnes, frutas y hortalizas), o congelados (García, 2008). La permeabilidad al vapor de agua (PVA) es una propiedad importante de películas comestibles, debido a que la mayoría de las películas a base de biopolímeros son propensas a plastificarse con agua, lo cual modifica las características de la matriz polimérica (Deng y col., 2009).

En este sentido sería de vital importancia la utilización de Redes Neuronales Artificiales en el modelado predictivo de la permeabilidad al vapor en películas biodegradables en condiciones no experimentadas, con el objeto de optimizar la permeabilidad al vapor, como parámetro de calidad indispensable en películas y recubrimientos biodegradables. Teniendo en cuenta esto se establece como objetivo general: aplicar las

redes neuronales para la modelación predictiva de la permeabilidad al vapor de agua de películas de quitosana con arcilla.

2. MATERIALES Y MÉTODOS

2.1 Caracterización de la permeabilidad al vapor de agua de las películas de quitosana con arcilla (PVA):

Se determinó gravimétricamente según el método ASTM E 96-92 (McHugh et al., 1993; Guillard et al., 2003). Las películas fueron colocadas en la parte superior de una celda de permeación conteniendo agua destilada (100 % HR) con valores de presión de vapor de agua en función de la temperatura. Las celdas fueron colocadas en un desecador entre 26 y 29 °C y 0 % HR (~ 0 Pa presión de vapor de agua) con sílica gel. El agua transferida a través de la película fue absorbida por el desecante y determinada por la pérdida de masa de la celda de permeabilidad. Las celdas fueron pesadas a intervalos de 2 h durante 12 h.

2.2 Diseño y validación de la Red Neuronal Artificial:

Para el desarrollo de la RNA se tomaron 30 conjuntos de datos aleatorios de la base de datos, realizando así el entrenamiento, aprendizaje y validación de la RNA (Tabla 1), y 10 igualmente aleatorios con el objetivo de introducir valores ajenos al entrenamiento de la Red y comparar los valores predichos contra resultados reales obtenidos en la base de datos utilizada (Tabla 2). El diseño, programación y validación de la red se realizó en el Software Informático Neural Designer (Versión 591), en el cual se crearon las diferentes estructuras de las redes en las que se varió el número de neuronas en la capa oculta y la función de transferencia de las mismas.

Para la selección de la mejor estructura se utilizó el Error Medio Cuadrático (EMC), número de iteraciones y el sobreentrenamiento de la red. Para la realización de cálculos necesarios y la obtención de gráficos se utilizó Microsoft Excel.

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

- Número de capas ocultas: 2
- Número de neuronas en la capa de entrada: 3
- Número de neuronas en la capa de salida: 1
- Estructura: Perceptrón.
- Algoritmo de aprendizaje: Levenberg-Marguardt

El siguiente gráfico circular (Figura 1) detalla los usos de todas las muestras del conjunto de datos. El número total de muestras es 30, el número de muestras de entrenamiento es 18 (60%), el número de muestras de selección es 6 (20%) y el número de muestras de prueba es 6 (20%).



Figura 1. Uso de los datos para el diseño de la RNA

Tabla 1. Datos utilizados para el entrenamiento, selección y prueba de la Red Neuronal Artificial

Concentración de Quitosano (%)	Concentración de Arcilla (%)	Espesor	Permeabilidad (g/m día atm)
1.5	1	0.0435556	0.375772
1	3	0.0345556	0.26623
1	1	0.0354444	0.276417
1.5	0	0.0491111	0.357094
1.5	3	0.0656667	0.458917
2	1	0.0501111	0.278466
1	0	0.0344444	0.332204
1.5	3	0.0411111	0.321383
2	0	0.0685556	0.439073
1	0	0.0313333	0.23019
1.5	0	0.0492222	0.330086
1.5	3	0.0444444	0.31479
2	1	0.0505051	0.28915
1	3	0.0361667	0.293631
1.5	1	0.0452623	0.359413
2	3	0.0537778	0.306246
1.5	3	0.0491012	0.319365
2	0	0.0675556	0.421216
1.5	0	0.0535556	0.396492
1	1	0.0371111	0.275433
2	3	0.0544444	0.368183
1.5	3	0.0436667	0.282959
1.5	1	0.0501111	0.353982
2	1	0.0545556	0.299053
1.5	3	0.0537778	0.363796
2	0	0.0573333	0.389879
1	3	0.0377778	0.298883
1	1	0.0292222	0.236149
2	3	0.0553333	0.39504
1	0	0.0354444	0.371894

Tabla 2. Datos utilizados para la validación de la Red neuronal Artificial

Concentración de Quitosano (%)	Concentración de Arcilla (%)	Espesor	Permeabilidad (g/m día atm)
1.5	1	0.0477777	0.363599
1.5	1	0.0545556	0.393598
1.5	1	0.0542222	0.383022
1.5	3	0.0640839	0.357868
1	1	0.0233333	0.256283
1.5	1	0.0416667	0.306889
1.5	1	0.0398889	0.305066
1.5	1	0.0384444	0.29257
1	3	0.03511	0.399598
1.5	1	0.0545556	0.326067

La validación de la red neuronal seleccionada consistió en la simulación de la misma utilizando los 10 datos seleccionados aleatoriamente que se reservaron para este objetivo, esta simulación la provee la plataforma

de aprendizaje utilizada. Los valores simulados fueron contrastados con los valores reales. Se realizó una regresión lineal (Muñoz, 2015) y se determinó el CME y R2 para el conjunto de datos.

3. RESULTADOS Y DISCUSIÓN

3.1 Selección de la función de transferencia.

Los valores obtenidos de EMC fueron inferiores a 0,08 en todos los casos. Las funciones: lineal, logística y lineal rectificadas arrojaron valores de EMC entre 0,02 y 0,08, entre 0,02 y 0,03, y entre 0,02 y 0,07 respectivamente. El valor inferior de EMC se obtuvo con la función de transferencia tangente hiperbólica que presentó EMC de 0.0214886 a pesar de encontrarse los otros entre 0,02 y 0,04. En la Tabla 3 se puede observar los valores de EMC para cada una de las funciones de transferencia con las variaciones del número de neuronas en la capa oculta. El menor EMC lo obtuvo la función tangente hiperbólica para 5 neuronas en la capa oculta, a pesar que la función logística tiene un comportamiento más estable para mayor número de neuronas (Figura 2), pero 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. Otro criterio para la elección de 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.

Tabla 3. EMC de las RNAs evaluando las funciones de transferencia Tangente Hiperbólica, Lineal, Logística y Lineal Rectificada con diferente número de neurona en la capa oculta.

Número de neuronas en la capa oculta de la red	Función de transferencia			
	Tangente hiperbólica	Lineal	Logística	Lineal rectificadas
2	0.0305482	0.0258433	0.0307133	0.025396
5	0.0214886	0.0656141	0.0301684	0.0286648
10	0.0394145	0.0667452	0.0272396	0.0343715
15	0.0418192	0.0802356	0.0279556	0.0410457
20	0.0363488	0.0420891	0.0290682	0.070954
30	0.0459925	0.0810621	0.0255592	0.0267964

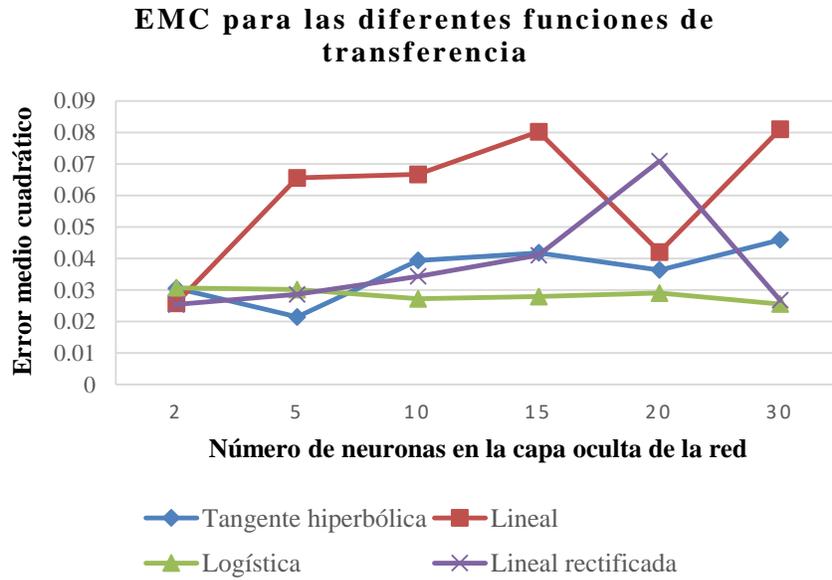


Figura 2. EMC para las funciones de transferencia: tangente hiperbólica, lineal, logística y lineal rectificada.

3.2 Selección del número de neuronas en la capa oculta.

En cuanto al número de neuronas en la capa oculta del modelo, es importante destacar que este número afecta a la calidad predictiva del modelo, y es por lo que debe controlarse y optimarse cuidadosamente. Si se utilizan demasiadas neuronas ocultas se puede producir un sobreajuste (vide supra) del modelo, mientras que, por el contrario, si se usa un número insuficiente de neuronas puede disminuir la capacidad de aprendizaje del modelo. En la capa oculta fueron seleccionadas 5 neuronas, con base en los valores obtenidos de EMC y número de iteraciones en el entrenamiento que pueden observarse en la Tabla 4, la cual evidencia que la variación del error de ajuste no es significativa, sin embargo, este es el menor obtenido, contrastando con el número de iteraciones que debe hacerse para alcanzar el estado óptimo de la configuración. Se evidencia una variación inestable del EMC para los diferentes números de neuronas, a pesar de esto sería factible además el empleo de 10 neuronas en la capa oculta, ya que el EMC de 5 a 10 neuronas aumentó solo en un 13.46%. Decantando la decisión de igual manera a 5 neuronas, ya que en diferentes bibliografías se ha comprobado que existe ajustes a modelos no lineales con pocas neuronas en la capa oculta, un ejemplo de ello fue la investigación realizada por Robles (2010) en el pronóstico para el rendimiento del trigo, también por Sánchez y Elanis (2006), aclarado anteriormente.

En la Figura 3 puede observarse la gráfica de la evaluación del EMC conforme aumenta el número de neuronas en la capa oculta. Otro criterio tenido en cuenta para la selección del número de neuronas corresponde al sobre entrenamiento 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.

Tabla 4. Error Medio Cuadrático y número de iteraciones de entrenamiento de las RNAs al variar el número de capas ocultas.

Número de Neuronas	Prueba	Número de Iteraciones de entrenamiento
1	0.0364208	21
2	0.0269007	68
3	0.0286442	44
4	0.0346982	133
5	0.0174589	97
6	0.0275189	147
7	0.0258423	148
8	0.0228850	125
9	0.0396007	201
10	0.0198082	195
20	0.0380404	209
30	0.0337255	213
40	0.0410595	181
50	0.0343227	192

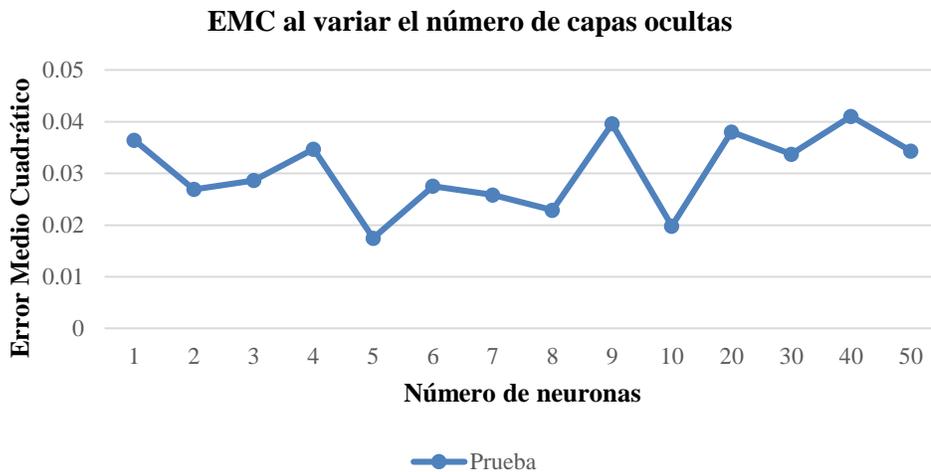


Figura 3. EMC al variar el número de capas ocultas.

En la Figura 4 se observa la comparación de los EMC de los datos usados para el Entrenamiento y de los datos usados como Prueba durante el aprendizaje de la red, en donde se aprecia una diferencia marcada entre los valores de EMC del entrenamiento y la prueba para un mismo número de neuronas ocultas, lo cual es indicio de sobre entrenamiento. Para 5 y 10 neuronas en la capa oculta este factor no es un inconveniente, ya que muestran un mejor acercamiento entre el EMC del entrenamiento y de la prueba, siendo necesario aclarar que a partir de 10 neuronas en la capa oculta se presenta una diferencia entre los valores de EMC de Entrenamiento y Test, sugiriendo que a partir de este valor se produce el sobre entrenamiento, esto también sucede para varios números de neuronas del 1 al 10, como sucede con 4 y 9 neuronas.

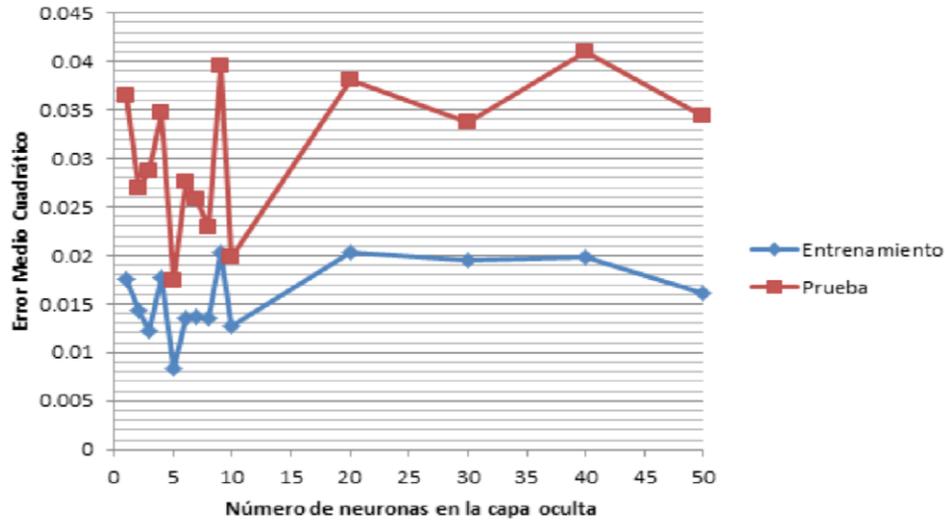


Figura 4. EMC de los datos de entrenamiento y test vs. Número de neuronas en la capa oculta.

La red fue generada por el mismo programa informático y las características seleccionadas fueron:

- Número de capas: 3
- Número de neuronas en la capa de entrada: 3 (Variables independientes: Concentración de quitosano, Concentración de arcilla y Espesor de la película)
- Número de capas ocultas: 1
- Número de neuronas en la capa oculta: 5
- Número de neuronas en la capa de salida: 1 (Variable dependiente: Permeabilidad al vapor)
- Función de transferencia de las neuronas: Tangente hiperbólica.

La red neuronal tiene 3 entradas (amarillo) y 1 salida (violeta). Consiste en una capa de entrada (amarillo), una capa de perceptrón con 5 neuronas (azul), la próxima neurona visible corresponde a la unión sumadora de estas, seguidamente se encuentra representada la función de activación y la neurona de la capa de salida (violeta).

La Figura 5 muestra la arquitectura de la Red Neuronal diseñada, imagen generada mediante Neural Designer.

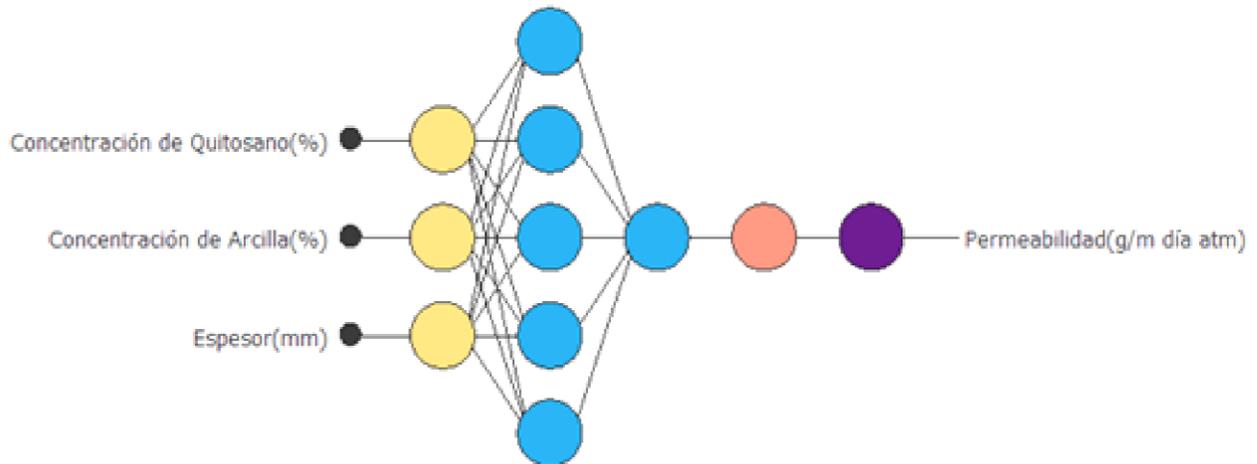


Figura 5. Arquitectura de la Red Neuronal Artificial generada por Neural Designer.

3.3 Validación.

Se habla de validación interna o externa según la procedencia de los datos necesarios para llevar a cabo la validación. En este apartado se describe únicamente la interna debido a que es la empleada en este trabajo. Cuando se habla de validación interna, se refiere a que los datos utilizados para validar el modelo pertenecen a la base de datos con la que se ha diseñado la red pero que en ningún momento han sido utilizados para el diseño de esta (ni siquiera para parar el aprendizaje como en el caso de la muestra de verificación). En este caso, se realizó la validación de la red neuronal con 10 muestras apartadas aleatoriamente de las 40 que conformaban la base de datos procesada. Al presentar datos desconocidos a la red neuronal con el fin de evaluar la capacidad de predicción, se evidenció una respuesta altamente satisfactoria a la hora de contrastar los datos reales y los obtenidos con la simulación de la red neuronal. En la Figura 6 se aprecia la obtención de un EMC de 0.00046 y un R^2 de 0.9207 en la comparación de los datos reales vs. los datos simulados. Se realiza una ecuación de regresión para validar si lo que se piensa de la relación entre dos variables, también es válido para la ecuación de regresión. El coeficiente de determinación es la proporción de la varianza total de la variable explicada por la regresión, refleja la bondad del ajuste de un modelo a la variable que pretende explicar. Cuanto más cerca de 1 se sitúe su valor, mayor será el ajuste del modelo a la variable que se intenta explicar.

En la Figura 7 se describe el comportamiento y comparación de los pares de datos utilizados para la validación, mostrando diferencias en la predicción principalmente para cuatro juegos de datos. Se observa un comportamiento similar, con valores de permeabilidad ligeramente superiores para los valores predichos y una coincidencia en el hecho de que el menor valor de permeabilidad se corresponde con la película de menor concentración de quitosana (% m/v) y 1 % de arcilla (m/m quitosana).

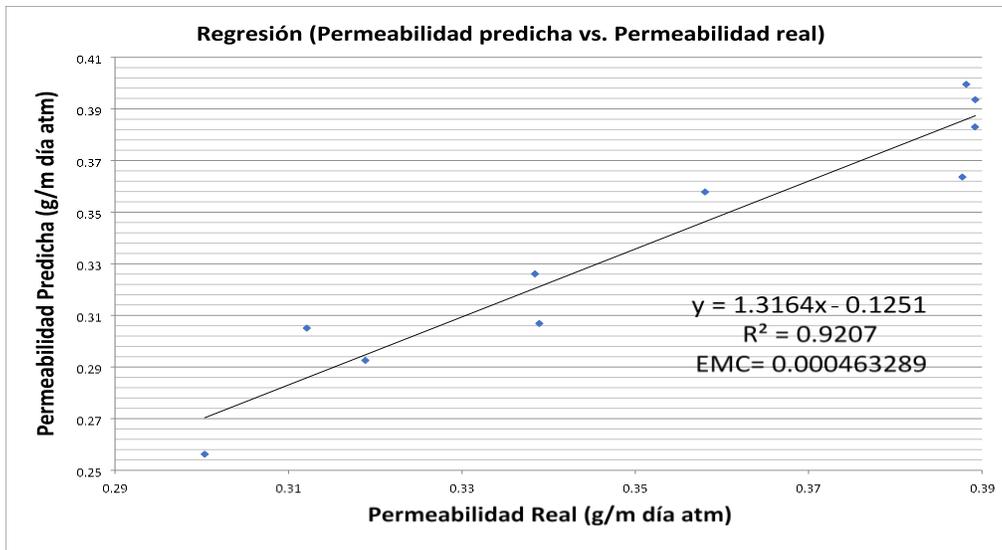


Figura 6. Regresión lineal de la Permeabilidad Real vs. Permeabilidad Predicha por la Red Neuronal Artificial.

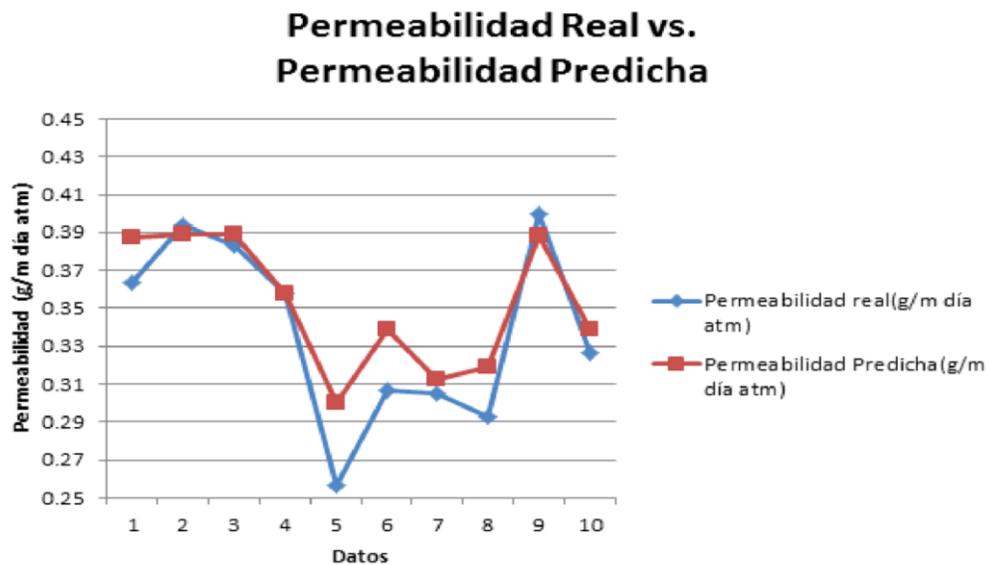


Figura 7. Comparación de pares de valores: Permeabilidad real (g/m día atm) contra Permeabilidad Predicha (g/m día atm).

4. CONCLUSIONES

Para la selección del tipo de red, la arquitectura de esta y el programa informático para su entrenamiento, se deben considerar las problemáticas en cuestión, las herramientas que permitan explorar de forma rápida y gráfica las distintas arquitecturas de RNA hasta encontrar la que mejor se adapta al problema. Perceptrón Multicapa es uno de los modelos de RNA más usados en el campo de los alimentos.

La modelación predictiva de la permeabilidad al vapor de agua de películas de quitosana con arcilla se llevó a cabo en la plataforma de aprendizaje Neural Designer, se eligió como modelo Perceptrón Multicapa, y una arquitectura de 3:5:1 (Capa de entrada: Capa oculta: Capa de salida) utilizando Tangente Hiperbólica

como función de activación y Levenberg-Marguardt como algoritmo de aprendizaje. Se obtuvo un EMC de 0.00046 y un R^2 de 0.9207 en la Regresión de los datos reales contra los datos simulados, resultado satisfactorio, lo que demuestra el correcto entrenamiento de la Red y la eficacia de la predicción.

5. REFERENCIAS

Aroca, R. (2018). *Redes Neuronales para el análisis y control de calidad del aceite de oliva virgen extra*. Madrid: Universidad Complutense de Madrid.

Bósquez, E. (2003). *Elaboración de recubrimientos comestibles formulados con goma de mezquite y cera de candelilla para reducir la cinética de deterioro en fresco del limón persa (Citrus latifolia Tanaka)*. México: Universidad Autónoma Metropolitana campus Iztapalapa.

Casariego, A., Souza, B.W.S., Cerqueira, M.A., Texeira, J.A., Cruz, L., Díaz, R. & Vicente, A.A. (2009). *Chitosan/clay films' properties as affected by biopolymer and clay micro/nanoparticles' concentrations*. *Food Hydrocolloids*, 23, 1895-1902.

Deng, Y., Zhu, L., Luo, W., Xiao, C. L. y Chen, J.S. (2009). *Changes in physical properties of chitosan films at subzero temperatures*. *Food Science*, 21(4), 487-497.

García, M. A. (2008). *Películas y cubiertas de quitosana en la conservación de vegetales*. *Ciencia y Tecnología de Alimentos*, 71-76.

García, M. A., y col. (enero-abril de 2020). *Influencia de la adición de mezclas de zeolita y bentonita en la permeabilidad al vapor de agua de película de quitosana*. *Ciencia y Tecnología de Alimentos*, 30(1), 48-55.

Guillard, V., Broyart, B., Bonazzi, C., Guilbert, S. y Gontard, N. (2003). *Prevención de la transferencia de humedad en un alimento compuesto utilizando películas comestibles: estudio experimental y matemático*. *Revista de ciencia de los alimentos*, 68 (7), 2267-2277. <https://doi.org/10.1111/j.1365-2621.2003.tb05758.x>

Fernández, D., Bautista, B., Ocampo, A., García, A., y Falcón, A. (julio, agosto, septiembre de 2015). *Películas y recubrimientos comestibles: una alternativa favorable en la conservación poscosecha de frutas y hortalizas*. *Revista Ciencias Técnicas Agropecuarias*, 24(3), 52-57.

McHugh, T. H., Avena-Bustillos, R., & Krochta, J. M. (1993). *Hydrophilic edible films: modified procedure for water vapor permeability and explanation of thickness effects*. *Journal of food science*, 58(4), 899-903. <https://doi.org/10.1111/j.1365-2621.1993.tb09387.x>

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).

Ochoa, C. M. (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), 318-325. Disponible en: <http://www.redalyc.org/articulo.oa?id=169945826002>.

Sánchez, M. & Alanis, A. (2006). *Redes neuronales Conceptos fundamentales y aplicaciones a control automático*, Madrid, España: Pearson Prentice Hall.

SEMBLANZA DE LOS AUTORES

Alicia Casariego Año: Licenciada en Ciencias Alimentarias, Máster en Ciencia y Tecnología de los Alimentos, Doctora en Ciencia de los Alimentos. Profesora titular del Instituto de Farmacia y Alimentos de la Universidad de La Habana, Cuba. Su trabajo va dirigido al estudio de la conservación de los alimentos, específicamente al empleo de métodos emergentes. Presenta una notable trayectoria en el ámbito investigativo, ejerciendo como tutora a un gran número de tesis y proyectos de investigación.

Dairon Iglesias Guevara: Máster en Ciencias Alimentarias y Premio al Mérito Científico por la Universidad de La Habana (2019). Actualmente es profesor del Instituto de Farmacia y Alimentos de la Universidad de La Habana en la disciplina Ciencia y Tecnología de los Alimentos. Ha desarrollado una estancia de investigación en el IATA con académicos reconocidos dentro de su campo de especialización y forma parte de varios proyectos de investigación relacionados con el desarrollo de nuevos productos alimentarios y el empleo de extractos vegetales antioxidantes en la formulación de alimentos.

Maribel Pino Hernández: Estudiante de Cuarto año de la Licenciatura en Ciencias Alimentarias del Instituto de Farmacia y Alimentos de la Universidad de la Habana. Durante sus primeros años de carrera ha alcanzado disímiles logros en la investigación científica y académica junto a la ayuda de sus tutores.

Marcos Antonio González Correa: Estudiante de Tercer año de la Licenciatura en Ciencias Alimentarias del Instituto de Farmacia y Alimentos de la Universidad de la Habana. Durante sus primeros años de carrera ha alcanzado disímiles logros en la investigación científica y académica junto a la ayuda de sus tutores.

Maikel Negrín Hernández: Estudiante de Tercer año de la Licenciatura en Ciencias Alimentarias del Instituto de Farmacia y Alimentos de la Universidad de la Habana. Durante sus primeros años de carrera ha alcanzado disímiles logros en la investigación científica y académica junto a la ayuda de sus tutores.