

ESTUDIO DE LA VIABILIDAD DEL USO DE REDES NEURONALES ARTIFICIALES, COMO HERRAMIENTA PARA LA PREDICCIÓN DE PARÁMETROS SENSORIALES A PARTIR DE DATOS NIRS EN JAMÓN CURADO

Hernández-Ramos¹, P., Revilla², I., González-Martín³, M.I., Vivar², A.M. y Martínez-Martín², I.

¹ Expresión Gráfica en la Ingeniería, Universidad de Salamanca, E.P.S. de Zamora, Avda Requejo 33, 49022 Zamora. ²Tecnología de Alimentos, Universidad de Salamanca, E.P.S. de Zamora, Avda. Requejo 33. 49022 Zamora, ³Química Analítica, Nutrición y Bromatología, Universidad de Salamanca, Plaza de la Merced s/n, 37007 Salamanca; pedrohde@usal.es

INTRODUCCIÓN

El jamón ibérico es un producto cárnico alimenticio de alta calidad, especialmente valorado por los consumidores y particularmente sensible a las variaciones organolépticas y sensoriales que signifiquen grandes diferencias entre lo esperado y lo experimentado por los consumidores. La adquisición de productos cuyas características no cumplan con lo esperado, pueden suponer una pérdida en la imagen del producto y, por tanto, pérdidas económicas de difícil recuperación. Es por ello que el mercado impone garantizar la satisfacción de los consumidores, estimando estas características durante su elaboración y curado, de forma no destructiva, rápida y económica. Para ello, se han empleado técnicas analíticas convencionales y otras más novedosas como aquellas que se fundamentan en las narices y lenguas electrónicas (e-nose y e-tongue respectivamente), imágenes hiperespectrales, espectroscopía de infrarrojo cercano (NIRS). La aplicación de estas técnicas sobre productos alimenticios como carne y productos cárnicos (Górska-Horczyzak et al., 2017; Feng et al., 2018), queso (González-Martín et al., 2011) y productos lácteos (Hristova & Ahmad, 2015) han permitido una estimación previa de algunas de sus características sensoriales, proporcionando la posibilidad de aplicar estrategias durante el proceso de elaboración, curado o almacenamiento del mismo, que mejoren su posición en el mercado conforme a los estudios de intención de compra. Por otro lado, las Redes Neuronales Artificiales (ANN) han demostrado su utilidad en campos como la categorización de productos alimenticios como jamón curado (Górska-Horczyzak et al., 2017) (Prevolnik et al., 2014), o queso (Pillonel et al., 2005), etc; estableciéndose como una herramienta rápida, económica y no destructiva muy útil en la lucha contra el fraude. También han sido utilizadas, conjuntamente con las técnicas comentadas anteriormente, para el procesamiento de las nubes de datos obtenidas por técnicas analíticas. En este contexto, el presente trabajo pretende evaluar la capacidad de predicción de parámetros sensoriales de una ANN, tales como los relacionados con la textura, olor, sabor y color, a partir de datos obtenidos por NIRS y estudiar la influencia de la arquitectura de la red y el número de muestras sobre dicha capacidad.

MATERIAL Y MÉTODOS

Se parte de 3 lotes con 15, 28 y 50 muestras de jamón curado de la zona de la maza. Las muestras de jamón pertenecen a cerdos con genética 50% y 100% ibérico y con alimentación de montanera. La elaboración y curación (durante 24 meses) de las piezas ha sido realizada por Carrasco Ibéricos (Guijuelo, Salamanca) de manera tradicional. Los datos espectrales se han obtenido con el equipo FossNIRSystem 5000 acoplado a una sonda de fibra óptica de reflectancia remota con una ventana de medida de 5 cm². El espectro se registra, por triplicado, cada 2 nm en el intervalo entre 1100 a 2000 nm. Los datos sensoriales han sido obtenidos por medio de un panel de cata compuesto por 10 jueces entrenados en la metodología QDA que evaluaron los parámetros previamente acordados y definidos (Tabla 1) en una escala de 10 puntos. Los valores obtenidos han sido procesados con redes feedforward artificial neural networks (ANN) del tipo MLP (Multi Layer Perceptron) con una capa de entrada con 451 neuronas alimentada con los valores obtenidos en el NIRS, otra oculta con una configuración variable entre 1 y 30 neuronas y la de salida con una única neurona que nos mostrará el valor del parámetro sensorial en estudio estimado. Se realizaron pruebas con los algoritmos de entrenamiento Scaled Conjugate Gradient Backpropagation, Levenberg-Marquardt Backpropagation y Bayesian Regularization Backpropagation. Las funciones de transferencia empleadas han sido la Hyperbolic Tangent Sigmoid y la Linear para las neuronas de la capa oculta y de salida respectivamente. Los conjuntos de pares de datos entrada-salida esperada han sido divididos al 70% para el entrenamiento, 15% para la validación y 15% como conjunto de pares de datos independiente para el estudio de la

bonanza de la red. La determinación de la mejor arquitectura de la ANN para cada parámetro sensorial, ha exigido el entrenamiento de 30 redes para cada configuración diferente. Los entrenamientos se han realizado con valores semilla conocidos, necesarios para la asignación previa aleatoria de los pesos de las conexiones y de los valores umbrales de excitación de las neuronas, posibilitando la reproducción de los resultados. Como software se ha utilizado la Deep Learning Toolbox de MatLab (MathWorks®) en su versión R2018.

RESULTADOS Y DISCUSIÓN

En primer lugar, se procedió a realizar pruebas con los diferentes algoritmos de entrenamiento desestimándose el Bayesian Regularization Backpropagation por el elevado coste en tiempo de cómputo requerido. A continuación, y para cada uno de los algoritmos se procedió a entrenar las redes con un número de neuronas en la capa oculta entre 1 y 30. Para cada valor de número de neuronas en la capa oculta se realizaron 30 entrenamientos con asignación de diferentes valores aleatorios iniciales para los pesos de las conexiones y de los valores umbral de excitación de las neuronas (total 900 entrenamientos por parámetro, algoritmo y lote). Tras el entrenamiento se elige la mejor de las redes neuronales en función del Coeficiente de Determinación R^2 que da información sobre la bondad del ajuste de un modelo lineal a la variable que se pretende explicar, de modo que cuanto más próximo al valor 1 mejor es el ajuste. Para esta red se almacena el número semilla, de modo que los resultados puedan ser replicables. La tabla 1 muestra los valores alcanzados para R^2 de las mejores redes neuronales para los tres grupos de muestras ya que se quería saber de qué modo el número de muestras usadas en el entrenamiento influye sobre la capacidad de predicción de las ANN.

Tabla 1. Algoritmo de entrenamiento (Alg), nº de neuronas en la capa oculta (N) y valores del Coeficiente de Determinación R^2 estimados por las ANN con 15, 28 y 50 muestras.

Parámetro Sensorial	15 muestras			28 muestras			50 muestras		
	R^2	Alg.	N	R^2	Alg.	N	R^2	Alg.	N
Veteado	0,99	L	9	0,97	L	5	0,71	L	4
Color de la grasa	0,99	L	20	0,90	L	24	0,80	L	15
Homogeneidad del color	0,76	L	7	0,86	L	21	0,83	L	21
Intensidad de color	0,94	L	9	0,92	L	7	0,76	L	30
Sudado	0,99	L	8	0,89	L	28	0,79	L	7
Puntos blancos	0,98	L	17	0,90	L	18	0,77	L	5
Intensidad de olor	0,98	L	22	0,91	S	29	0,73	L	1
Olor a curado	0,97	L	3	0,84	L	11	0,75	L	13
Olor a cerdo	0,92	L	10	0,89	L	27	0,82	L	28
Olor a rancio	0,98	L	6	0,87	L	5	0,80	L	22
Olor extraño	0,84	S	16	0,82	L	25	0,72	L	1
Intensidad de sabor	0,99	L	27	0,84	L	14	0,64	L	1
Int. de sabor de la grasa	0,99	L	9	0,95	L	3	0,79	S	30
Sabor a curado	0,98	S	30	0,78	L	24	0,68	L	2
Sabor salado	0,98	L	22	0,87	L	21	0,80	L	19
Sabor dulce	1,00	L	16	0,91	L	5	0,81	L	26
Sabor ácido	0,98	L	19	0,84	L	13	0,83	L	6
Sabor rancio	0,95	L	16	0,89	L	6	0,69	L	26
Retrogusto	0,98	L	18	0,81	L	27	0,78	L	12
Sabor extraño	0,92	L	8	0,93	L	19	0,89	L	11
Dureza	0,99	L	26	0,88	L	22	0,85	L	18
Jugosidad	0,99	S	30	0,90	L	17	0,77	L	20
Grasosidad	0,96	L	19	0,90	L	11	0,82	L	22
Fibrosidad	0,99	L	30	0,94	L	22	0,86	L	16
Masticabilidad	0,98	S	19	0,76	L	15	0,73	L	5
Chiclosidad	0,99	L	29	0,92	L	12	0,79	L	11
Heterogeneidad	0,99	L	13	0,94	L	19	0,85	L	25
Residuo	0,98	L	15	0,90	L	11	0,72	L	13

L=Levenberg-Marquardt backpropagation / S=Scaled Conjugate Gradient Backpropagation

Se aprecia que en general el algoritmo que condujo a una mejor capacidad de predicción de la red fue el de Levenberg-Marquardt y que el número de neuronas en la capa oculta fue muy variable entre 3 y 29 dependiendo del parámetro sensorial analizado. En todos los casos a excepción del parámetro relacionado con la homogeneidad del color, se aprecia un descenso en la bonanza de las redes a medida que se incrementa el tamaño muestral. Ello se puede deber a una alta homogeneidad de los resultados de las catas, es decir, que productos que presentan espectros en el NIR diferentes recibieron puntuaciones muy próximas en la cata. Este hecho podría estar influyendo en la convergencia de la red hacia la solución óptima estimativa del parámetro estudiado. Los resultados muestran que en todos los casos considerados el valor de dicho coeficiente R^2 se situó por encima de 0,7, salvo para los parámetros de Intensidad de sabor ($R^2=0,64$), Sabor a curado ($R^2=0,68$) y Sabor a rancio ($R^2=0,69$) cuando se calcularon las redes para 50 muestras. A pesar de ello, estos valores pueden considerarse como buenos. En algunos casos, incluso, se llegan a obtener valores próximos a 0.90 (Sabor Extraño) lo que se puede considerar como excelente. Esto demuestra que a pesar de las limitaciones encontradas usando la Red Neuronal Artificial adecuada es posible predecir todos los parámetros sensoriales de muestras de jamón curado.

REFERENCIAS BIBLIOGRÁFICAS

- Feng, C.-H. H., Makino, Y., Oshita, S., & García Martín, J. F. (2018). Hyperspectral imaging and multispectral imaging as the novel techniques for detecting defects in raw and processed meat products: Current state-of-the-art research advances. *Food Control*, 84, 165-176.
- González-Martín, M. I. I., Severiano-Pérez, P., Revilla, I., Vivar-Quintana, A. M., Hernández-Hierro, J. M. M., González-Pérez, C., & Lobos-Ortega, I. A. (2011). Prediction of sensory attributes of cheese by near-infrared spectroscopy. *Food Chemistry*, 127(1), 256-263.
- Górska-Horczyzak, E., Horczyzak, M., Guzek, D., Wojtasik-Kalinowska, I., & Wierzbicka, A. (2017). Chromatographic fingerprints supported by artificial neural network for differentiation of fresh and frozen pork. *Food Control*, 73, 237-244.
- Hristova, V. K., & Ahmad, M. A. (2015). Estimating dairy product's viscosity with artificial neural networking (ann) model. En F. of S. C. D. University. (Ed.), *PIRM-V'2015. El Jadida, Morocco*.
- Pillonel, L., Bütikofer, U., Schlichtherle-Cerny, H., Tabacchi, R., & Bosset, J. O. (2005). Geographic origin of European Emmental. Use of discriminant analysis and artificial neural network for classification purposes. *The Fourth IDF Symposium on Cheese: Ripening, Characterization and Technology*, 15(6-9), 557-562.
- Prevolnik, M., Andronikov, D., Zlender, B., Font-i-Furnols, M., Novič, M., Škorjanc, D., & Čandek-Potokar, M. (2014). Classification of dry-cured hams according to the maturation time using near infrared spectra and artificial neural networks. *Meat Science*, 96(1), 14-20.

Agradecimientos: Los autores agradecen a la Junta de Castilla y León la financiación a través del proyecto SA039P17.

STUDY OF THE FEASIBILITY OF USING ARTIFICIAL NEURAL NETWORKS AS A TOOL FOR PREDICTING SENSORY PARAMETERS USING NIR SPECTRA IN CURED HAM

ABSTRACT: Spanish Iberico dry-cured ham is a very popular meat product owing to its sensory profile, so the sensory analysis is a cornerstone to assure the quality of these products. Some instrumental techniques such as NIRS technology has been studied to predict sensory attributes but this technique needs chemometric tools such as MPLS or ANN. The aim of this work was to study of the feasibility of using artificial neural networks for predicting sensory parameters of cured ham, because they have been hardly used for meat products. Several algorithms, number of neurons in the hidden layer and initial configurations have been tested in order to find the best ANN architecture for predicting the sensory parameters for three groups with different number of samples 15, 28 and 50. Results show that the Levenberg-Marquardt backpropagation was the best training algorithm and the number of neurons in the hidden layer depended on the sensory parameter. The predicting capacity of the ANNs decreased when the number of samples increased. However, the determination coefficient R^2 was higher than 0.7 in almost all the parameters so it was possible to predict all the sensory parameters analysed.

Keywords: cured ham, Near Infrared Spectroscopy, Sensory Analysis, Neural Networks