

Prediction of fresh milk quality by using Artificial Neural Network and Multivariate Regression

Jimy Oblitas-Cruz, M.Sc.¹  and Yuleyci Cieza-Rimarachin, Bach² 

¹ Universidad Privada del Norte., Perú, jimy.oblitas@upn.edu.pe

² Universidad Nacional de Cajamarca, Perú, yciezar16_1@unc.edu.pe

Abstract - The objective of this research was to compare the best structure of a Neural Network (ANN) with a multivariate nonlinear regression model (MNL) to predict the physicochemical quality parameters of milk. To create a predictor model for the livestock sector, 3 input and 6 output variables were used. To achieve this, a Feedforward ANN with Backpropagation training algorithms was applied. For the models, the Matlab 2020a software was used. The lowest mean absolute deviation (MAD) was found to be 0.00715952, corresponding to a Neural Network with 2 hidden layers (18 and 19), with Tansig and log sig type function, respectively. MNL models had R2 values greater than 0.9. Cross-Validation with 10 interactions was used for this purpose. For comparison, a Duncan test was used where it was found that there are no statistically significant differences between the real sample, the MNL, and the ANN, with a 95.0% confidence level.

Keywords: Artificial Neural Network, Nonlinear Multivariate Regression, Milk Quality.

Digital Object Identifier: (only for full papers, inserted by LACCEI).

ISSN, ISBN: (to be inserted by LACCEI).

DO NOT REMOVE

Predicción de la calidad en leche fresca usando Redes Neuronales artificiales y Regresión multivariable

Jimy Oblitas-Cruz, M.Sc.¹ and Yuleyci Cieza-Rimarachin, Bach²

¹ Universidad Privada del Norte., Perú, jimy.oblitas@upn.edu.pe

² Universidad Nacional de Cajamarca, Perú, yciezar16_1@unc.edu.pe

Resumen- El objetivo del trabajo fue comparar la mejor estructura de una Red Neuronal (RNA) con un modelo de regresión multivariable no lineal (RMNL) que permita predecir los parámetros de calidad fisicoquímica de la leche para generar un modelo predictor para el sector ganadero, se usaron 3 variables de entrada y 6 de salida, para lograrlo se aplicó una RNA del tipo Feedforward con los algoritmos de entrenamiento Backpropagation, para los modelos se usó el software Matlab 2020a. Se encontró que la desviación absoluta media (DAM) menor fue de 0.00715952 correspondiente a una Red Neuronal con 2 capas ocultas (18 y 19) con función de tipo Tansig y logsig respectivamente, los modelos RMNL tuvieron valores de R^2 mayores a 0.9, para ello su uso utilizó Cross Validation con 10 iteraciones. Para la comparación se usó una prueba de Duncan donde se encontró que no hay diferencias estadísticamente significativas entre la muestra real, el RMNL y el RNA, con un nivel del 95.0% de confianza.

Palabras Clave: Red Neuronal artificial, Regresión Multivariable no Lineal, Calidad de Leche

I. INTRODUCCIÓN

La leche y los productos lácteos son ricos en nutrientes y se consumen en todo el mundo. Mantener la calidad nutricional y garantizar la seguridad de estos productos se ha convertido en uno de los temas principales en la investigación láctea [1]. En los métodos tradicionales de control de calidad es necesario hacer diversos análisis, así como utilizar grandes cantidades de muestras para ensayarlos con el consecuente deterioro de estas. La leche contiene compuestos químicos que incluyen carbohidratos, lípidos, proteínas y componentes menores (vitaminas, minerales, etc.) que tienen funciones distintivas en los cuerpos humanos [2]

La grasa, la proteína, la lactosa y los sólidos totales se consideran los principales indicadores de calidad de la leche. Por lo tanto, el monitoreo de estos componentes se ha convertido en un trabajo rutinario en el procesamiento comercial de leche y el control de la calidad de la leche [3]. Métodos como Kjeldahl, la cromatografía líquida de alto rendimiento (HPLC) entre otros son métodos tradicionales para detectar estos componentes principales de la leche. Aunque estos métodos podrían ofrecer resultados de medición precisos, las deficiencias, como la operación de laboratorio que requiere mucho tiempo, la necesidad de un operador profesional e incluso el uso de productos químicos venenosos, hacen que estos métodos se utilicen en el laboratorio. Además, cada método solo podría usarse para medir un indicador de calidad. Por lo tanto, es necesario desarrollar sistemas o instrumentos de detección que puedan

ofrecer los resultados de detección de los principales componentes de la leche de forma rápida y simultánea [4]. Métodos como las redes neuronales artificiales (RNA) pueden ser una opción ya que son de bajo costo y se adapta bien a problemas no lineales, pudiendo aprender a través de ejemplos, analizar datos complejos que tienen muchas variables e incorporar otras si es necesario [5]. Esta puede ser una alternativa para la estandarización de la textura de los yogures, posibilitando la identificación de variables que inciden en la calidad esperada del producto.

Se ha estudiado el modelado en base a redes neuronales artificiales (RNA) para obtener modelos predictivos de la calidad de los alimentos [6]. Hoy en día, las redes neuronales artificiales se utilizan para predecir algunas características mediante factores fáciles de medir. Las RNA son generalmente los sistemas informáticos que imitan algunas propiedades de las neuronas biológicas. La capa de entrada, la(s) capa(s) oculta(s) y una capa de salida de neuronas son las partes principales de cada estructura RNA. Las neuronas en las capas de entrada reciben los datos de entrada y los normalizan y los transmiten a la capa oculta (. Una combinación lineal de las salidas de todas las neuronas en la capa anterior se calcula por cada neurona de una capa posterior y luego se le agrega sesgo (valores de peso asociados con nodos individuales). Las neuronas en capas ocultas aplican una función no lineal específica (función de transferencia) a la colección de combinación lineal y sesgo, y finalmente brindan los modelos predichos para la salida [7].

Los modelos convencionales como la regresión lineal, la regresión lineal múltiple (MLR), la regresión lineal múltiple paso a paso, la regresión de mínimos cuadrados parciales, entre otros se han utilizado ampliamente como herramientas de predicción para diversas situaciones de producción [8]

Para abordar esta brecha, el objetivo de este estudio son evaluar y comparar las capacidades de RNA y regresiones no lineales múltiples (MNL) para obtener modelos predictivos de la calidad de la leche fresca.

II. MATERIALES Y MÉTODOS

A. Obtención de data de entrenamiento y validación

La data se obtuvo analizando 252 muestra (40 cc por muestra) de leche de vacas de razas Holstein colectadas en once centros ubicados en la campiña de Cajamarca en Perú (Figura 1).

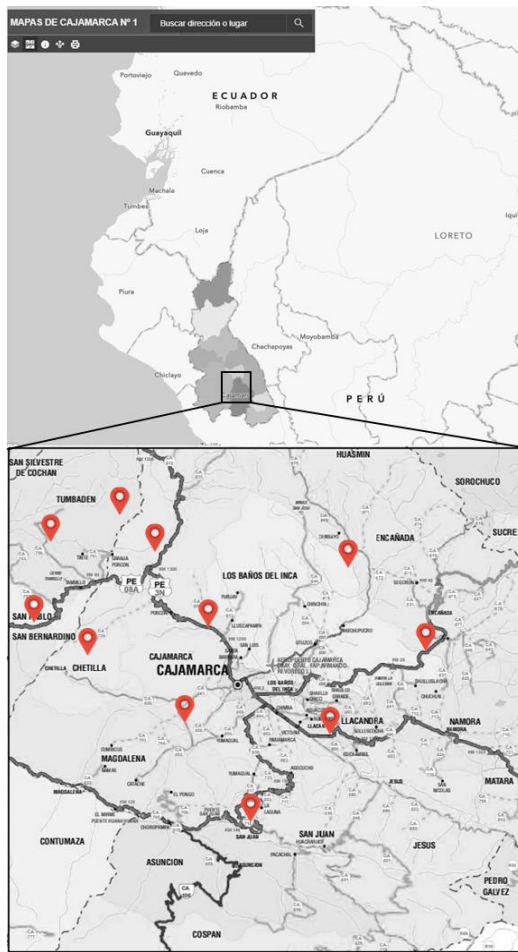


Fig. 1 Ubicación de toma de muestras

Las muestras se transportaron, en frascos de plástico con dicromato donde se analizaron mediante las técnicas detalladas en la Tabla I.

TABLA I
ANÁLISIS REALIZADOS SOBRE LAS MUESTRAS DE LECHE

Parámetro		Método
Entrada	Densidad (D)	Lactodensímetro (AOAC 925.22)
	Potencial de oxidación-Reducción (OX)	Tiempo de reacción al azul de metileno
	pH	Potenciométrico
Salida	Proteínas (P)	Método espectroscópico infrarrojo medio (NTP 202.130:1998)
	Lactosa (L)	
	Sólidos totales (ST)	
	Sólidos grasos (SG)	
	Sólidos no grasos (SNG)	
	Minerales (M)	

Se propuso una arquitectura resumida para perceptrones multicapa, Figura 2, a partir de las usadas en trabajos previos usando Redes neuronales artificiales [9]–[11]

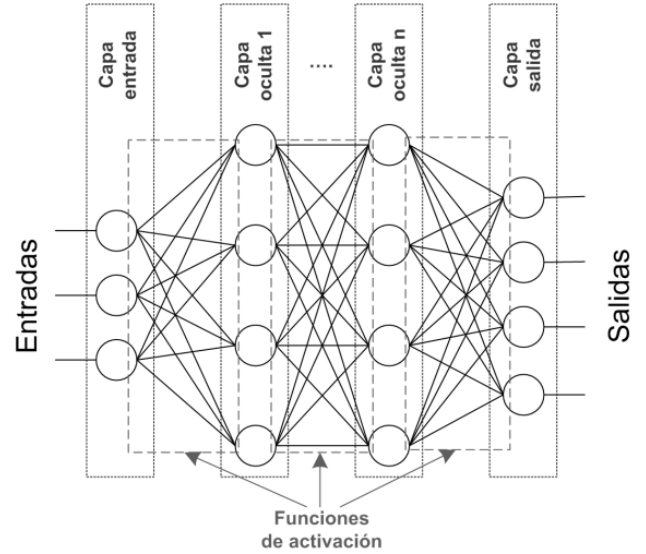


Fig. 2 Arquitectura resumida para perceptrones multicapa

Los parámetros estructurales a evaluar y sus rangos se establecieron en concordancia con investigaciones como las de Geng [12] y Mercier [13], véase Tabla 2.

TABLA II
RANGOS EN LOS PARÁMETROS ESTRUCTURALES

Parámetros	Rango
Neuronas capa de entrada (NE)	3
Neuronas capa de salida (NS)	6
Numero de Capas ocultas (CO)	[1-3]
Neuronas por capa por capa oculta (NCO)	[3 - 27]
Funciones de activación* (FA)	[1-3]

* Las funciones de activación se codifican como 1= tansig, 2= logsig y 3 = lineal

Las combinaciones de valores que asumieron los elementos estructurales por cada arquitectura se generaron mediante una secuencia lógica implementada en el software matemático Matlab 2020^a.

Como se deduce a medida que incrementamos el número de capas y las neuronas en estas se eleva sensiblemente el número de arquitecturas posibles, dificultando el proceso de establecimiento de los parámetros que optimizan la predicción y necesitando en tal sentido implementar secuencias lógicas de optimización

B. Modelamiento de regresión estadística

Se usó un modelo de regresión multivariable no lineal del tipo:

$$Y = f(x, \Phi) + \varepsilon$$

Basado en datos multidimensionales “x” y “y” donde “f” es alguna función no lineal respecto a algunos parámetros desconocidos (Φ). Como mínimo, se pretende obtener los valores de los parámetros asociados con la mejor curva de ajuste.

III. RESULTADOS

A. Determinación de parámetros fisicoquímicos de leche cruda de la Microcuenca de Cajamarca

Se realizaron en el punto de recojo las pruebas de Tiempo de Reducción de Azul de Metileno (TRAM), densidad y pH y los demás parámetros se analizaron llegando al laboratorio, estos datos se muestran en la Tabla 3.

Los resultados mostrados son similares a los reportados en los trabajos de Brousett [14] quienes analizaron la composición y calidad microbiológica en ganadería lechera del norte y sur del Perú respectivamente.

TABLA III
RESUMEN ESTADÍSTICO DE PRUEBAS S DE CALIDAD DE LA LECHE

	Parámetro	Promedio	Desviación Estándar
Input	Densidad	1.02826	0.00112
	pH	6.63550	0.04973
	Reductasa	6.72751	0.65321
Output	Minerales	0.69873	0.01518
	Proteína	2.98344	0.13642
	Lactosa	4.84148	0.19264
	S. No graso	8.52360	0.31261
	Sólido graso	3.58688	0.18146
	Sólidos totales	12.11130	0.43602

B. Entrenamiento de arquitecturas neuronales

Según la arquitectura planteada en la metodología se entrenaron 9 combinaciones de funciones tomando desde 1 a 200 neuronas en una capa, seguido se evaluó de 1 a 20 neuronas en cada capa oculta y se calculó su error medio cuadrático (MSE) para cada uno. Se puede observar que a diferencia de cuando se probó con una sola capa oculta los valores de MSE son muy erráticos y no siguen ningún orden específico. En la Figura 3, se presenta los más bajos MSE de acuerdo con el tipo de función y número de neuronas por capa, con esta información obtenida seleccionamos las funciones más adecuadas y el número de neuronas necesarios para la

topología de la red predictiva de parámetros fisicoquímicos de la leche cruda.

De acuerdo con los datos presentados en la Figura 3 la Red Neuronal artificial con menor valor de MSE fue la que tenía 2 capas ocultas con 18 y 19 neuronas respectivamente y con las funciones de transferencia Tansig – Logsig (Tangente sigmoide hiperbólico y logarítmica sigmoide).




Fig. 3 Mejores combinaciones ordenadas de menor a mayor MSE

En cuanto a los resultados obtenidos muestran que incrementar capas ocultas reduce la dispersión de las error generando perceptrones multicapa más robustos lo cual es coherente con lo propuesto por investigaciones preliminares [10] sobre la relación entre el número de capas y la eficiencia de la red y los resultados obtenidos en los trabajos de [15] que evaluaron diferentes estructuras hasta determinar las óptimas para sus condiciones de estudio.

En la Figura 4 se observa la regresión arrojada de la relación entre los datos reales y los datos predichos por la red entrenada con menor MSE. Se puede observar que tiene un índice de correlación de $R=0.99837$ lo cual indica un muy buen ajuste entre datos predichos y reales.

Al utilizar una red neurona del tipo Backpropagation no se analiza los pesos y bias ya que está a través de la Técnica del Gradiente Descendente ajusta los pesos y bias tratando de minimizar la suma del error cuadrático. Esto lo realiza de forma continua, cambiando dichas variables en la dirección contraria a la pendiente del error.

Aunque existe ciertas dudas en las etapas de aprendizaje pues no existe literatura sobre utilidades de estas Redes en la industria de procesos, Angeles [16] plantea que el error medio cuadrático (MSE) de entrenamiento disminuye de forma monótona con el incremento del número de neuronas de las capas ocultas, esto se pudo evidenciar en el entrenamiento de las redes aunque en el caso de dos capas ocultas se evidencio al realizar el entrenamiento que el error comienza a aumentar

debido al sobreentrenamiento, al alcanzar el número de neuronas de las capas ocultas un cierto valor.

Finalmente, se tomó la red que proporcione el menor error cuadrático medio (MSE) el cual se muestra en la Figura 3, encontrándose que la MSE más bajo fue de 0.00715952 correspondiente a la red neuronal con una estructura de 2 capas ocultas con 18 y 19 neuronas respectivamente y con las funciones de transferencia Tansig – Logsig (Tangente sigmooidal hiperbólico y logarítmica sigmooidal).

C. Ajuste con Regresión Multivariable No Lineal (RMNL)

Se buscó la mejor RMNL para cada parámetro obteniendo las siguientes ecuaciones predictivas mostradas en la Tabla 4. Los valores de R^2 para todas las características evaluadas son mayores a 0.956, lo cual muestra un buen ajuste para todos los modelos RMNL evaluados.

La eficiencia de la técnica estadística RMNL de clasificación utilizada en este estudio se ve afectada por la redundancia de información, es decir controles de producción utilizados como predictores altamente colineales.

Sin embargo, obtener altos valores de R^2 , en matrices alimentarias complejas y variables, como la leche, a menudo surgen problemas con la solidez de los modelos de calibración [17] esto está relacionado con la gran variabilidad de las propiedades propias de las zonas de recolección, raza de vacunos, etc.

TABLA IV
RESUMEN PARA MODELOS RMNL DE CALIDAD DE LA LECHE

MODELO RMNL	VALORES DEL MODELO DE RMNL			
	a	b	c	d
Sólido Graso = $a*x1+b*x2+c*x3+d$	-0.072	-0.257	-3.316	9.185
Proteína = $a*x1+b*x2+c*x3+d$	-0.032	-0.212	-5.738	10.509
Lactosa = $\exp(a*x1+b*x2+c*x3+d)$	-0.004	-0.074	-5.651	7.906
Sólidos totales = $\exp(a*x1+b*x2+c*x3+d)$	-0.010	-0.067	-3.004	6.093
Sólidos no Grasos = $\exp(a*x1+b*x2+c*x3+d)$	-0.006	-0.065	-3.918	6.642
Minerales = $\exp(a*x1+b*x2+c*x3+d)$	-0.002	0.026	-0.227	-0.282

D. Comparación Red Neuronal vs RMNL

Usando una nueva data de 50 valores se probó la eficiencia de las predicciones usando el modelo de Redes Neuronales se comparó con los modelos RMNL obtenidos, en la figura 5 se muestra las comparaciones de los valores obtenidos por predicción con Redes neuronales (RNA) comparados con los valores contenidos por RMNL y con los valores reales de la data de validación. De acuerdo con el análisis realizado los parámetros de Sólidos Grasos, lactosa, sólidos totales, sólidos no grasos y minerales no tienen diferencias significativas entre los valores de predicción y los valores reales ($p > 0.05$), solo el valor de proteínas obtuvo un valor $p < 0.05$ mostrando una mejor predicción a los valores arrojados por la Red Neuronal.

Si se analiza todas las predicciones en función al error promedio veremos que los valores dados por la RNA son en todos los casos superiores a los de RMNL, a excepción de los minerales. Torkshvan [6] comparó las RNA con técnicas estadísticas y concluyó que aunque ambos métodos ofrecen resultados similares en el análisis de predicción, los RNA tendrían ventajas cuando el conjunto de datos de entrenamiento se encuentra entre 200 y 2.000 casos, que es el caso de la presente investigación.

En la Figura 6 se muestran las correlaciones lineales usando todos los parámetros para la predicción por RNA y RMNL, donde se muestran los valores de Coeficiente de Correlación y R^2 . Se observa que el coeficiente de correlación para la regresión con RNA es 0.999243 y su $R^2=99.85\%$ mientras que el coeficiente de correlación para RMNL es 0.992172 y su $R^2=98.44\%$, comprobamos con ello que la RNA presenta una mejor correlación con respecto al RMNL.

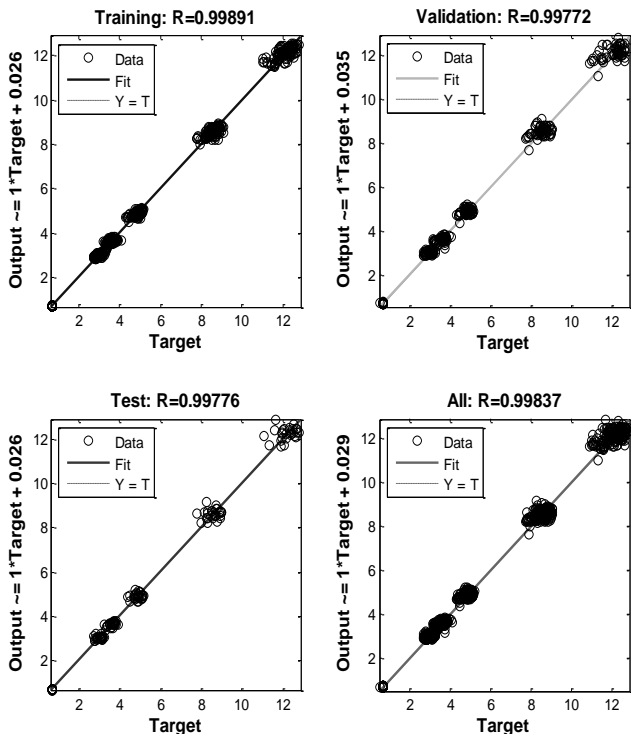


Fig. 4 Comparación con métodos de regresión estadística.

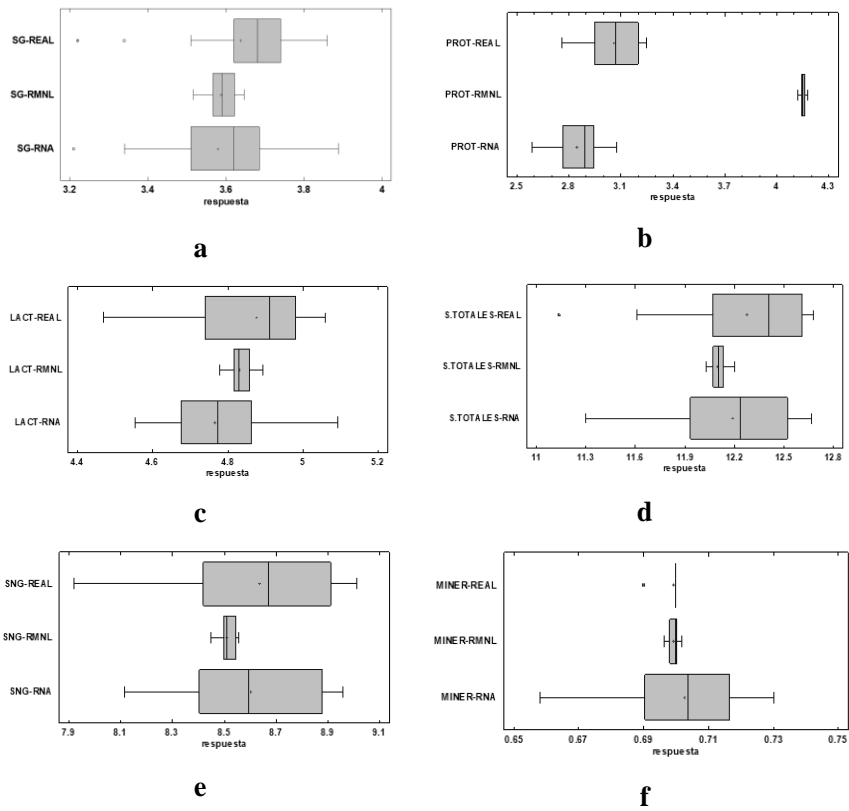


Fig. 5 Gráfico de Caja y Bigote para las medias de valores RNA y RMNL

Al analizar todas las variables al mismo tiempo se puede observar en la Figura 6 las correlaciones de la RNA con la RMNL, se mostró que la predicción arrojada por la RNA es superior demostrándose de esta manera lo que Batista [9] manifiesta de las ventajas principales de las RNA sobre los Métodos estadísticos siendo esta la capacidad que tienen para detectar relaciones complejas no lineales entre variables independientes y variables dependientes y confirmando lo estipulado por Castro [18] en referencia a la potencia de la RNA para la predicción y la imperfección de los modelos matemáticos regresionales.

La RNA entrenada demuestra la aplicabilidad a un campo como el del control de calidad en productos Lácteos. Particularmente, la RNA entrenada logra ser de suma utilidad para el productor lácteo y el acopiador, que, a través de un software en base a la mejor red encontrada, podrá predecir valores que demoran más de tres días en conocerse disminuyendo el tiempo y aumentando la eficiencia y eficacia del trabajo al disponer de un modelo de razonamiento automático.

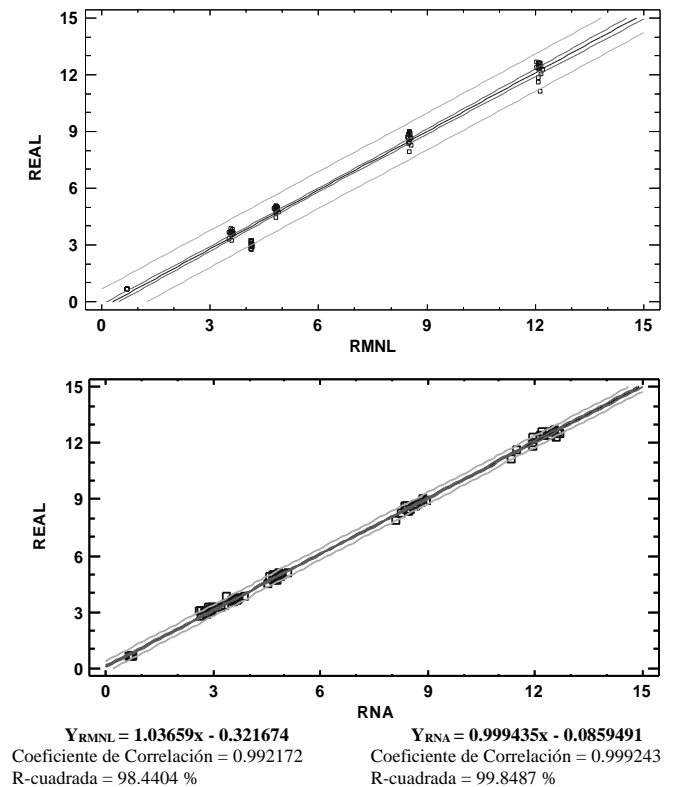


Fig. 6 Modelos de Regresión

Finalmente se generó un script usando Matlab 2020a para pruebas con un nuevo conjunto de datos y a cargo de usuarios en centros lecheros de la ciudad, el script se muestra en la figura 7, en total se probó con un ingreso de 80 nuevas pruebas, dando un nivel de precisión de 91.4% con la red entrenada, estos cambios fueron debido a que en algunos casos los usuarios tomaron los datos en leche con un periodo de más de 4 horas después de la recepción.

Esto muestra que los modelos empleados pueden ser utilizados en la predicción de aplicaciones ganaderas con el objetivo de tener un dato previo al análisis de laboratorio y se pueda hacer estimaciones rápidas de carácter tecnológico y/o económico.




Fig 7. Script para predicción de datos

IV. CONCLUSIÓN

Se determinó que la mejor estructura de la Red Neuronal que permite predecir los parámetros de calidad a partir de propiedades fisicoquímicas es una de tipo Backpropagation con una topología final de 2 capas ocultas con 18 y 19 neuronas respectivamente y con las funciones de transferencia Tangente sigmooidal hiperbólico y logarítmica sigmooidal, con un error promedio final de 0.000256 %. Se comparó la eficiencia de predicción de parámetros de calidad de la red neuronal con un modelo de regresión estadístico donde se observó similitud. predictiva de la RNA ($R^2=99.92\%$) con respecto al modelo RMNL ($R^2=98.44\%$) y con los valores deseados ($p>0.05$) de Grasa, proteína, lactosa, sólidos no grasos, sólidos totales y minerales; mostrando que la RNA tiene ventajas sobre los modelos estadísticos.

Finalmente, aunque la RNA entrenada en la presente investigación demostró ventajas con respecto a los modelos regresionales multivariantes convencionales de predicción, se

tuvo el inconveniente de la falta de reglas definitorias que ayuden a construir una red para un problema dado, hay muchos factores a tomar en cuenta: el algoritmo de aprendizaje, la arquitectura, el número de neuronas por capa, el número de capas, la representación de los datos que pueden generar el hecho de operar con una caja negra. El problema es que cuando se modela estadísticamente se es capaz de ver que variables forman parte del modelo o cuales de las que finalmente se utilizaron para modelar fueron seleccionadas por los algoritmos para predecir o clasificar, se puede igualmente observar sus pesos y la ecuación final, cosa que no es posible en las redes neuronales.

Sin embargo, pese a los problemas encontrados, la RNA demostró ser una herramienta alternativa y atractiva para predicciones multivariantes que con métodos tradicionales serían muy complejos y de baja eficiencia.

REFERENCIAS

- [1] J. Hyuk Suh, «Critical review: metabolomics in dairy science - evaluation of milk and milk product quality», *Food Research International*, p. 110984, feb. 2022, doi: 10.1016/j.foodres.2022.110984.
- [2] «Chemical Composition of Commercial Cow's Milk | Journal of Agricultural and Food Chemistry». <https://pubs.acs.org/doi/abs/10.1021/acs.jafc.9b00204> (accedido 14 de febrero de 2022).
- [3] A. Villar, E. Gorritxategi, E. Aranzabe, S. Fernández, D. Otaduy, y L. A. Fernández, «Low-cost visible-near infrared sensor for on-line monitoring of fat and fatty acids content during the manufacturing process of the milk», *Food Chemistry*, vol. 135, n.º 4, pp. 2756-2760, dic. 2012, doi: 10.1016/j.foodchem.2012.07.074.
- [4] B. Yang, W. Guo, W. Liang, Y. Zhou, y X. Zhu, «Design and evaluation of a miniature milk quality detection system based on UV/Vis spectroscopy», *Journal of Food Composition and Analysis*, vol. 106, p. 104341, mar. 2022, doi: 10.1016/j.jfca.2021.104341.
- [5] V. Mohammadi y S. Minaei, «2 - Artificial Intelligence in the Production Process», en *Engineering Tools in the Beverage Industry*, A. M. Grumezescu y A. M. Holban, Eds. Woodhead Publishing, 2019, pp. 27-63. doi: 10.1016/B978-0-12-815258-4.00002-0.
- [6] A. M. Torkashvand, A. Ahmadi, y N. L. Nikraves, «Prediction of kiwifruit firmness using fruit mineral nutrient concentration by artificial neural network (ANN) and multiple linear regressions (MLR)», *Journal of Integrative Agriculture*, vol. 16, n.º 7, pp. 1634-1644, jul. 2017, doi: 10.1016/S2095-3119(16)61546-0.
- [7] J. Zhang y G. Su, «Chapter 22 - Artificial neural network introductions», en *Nuclear Power Plant Design and Analysis Codes*, J. Wang, X. Li, C. Allison, y J. Hohorst, Eds. Woodhead Publishing, 2021, pp. 515-541. doi: 10.1016/B978-0-12-818190-4.00022-X.
- [8] W. Castro, *The Use of Correlation, Association and Regression Techniques for Analyzing Processes and Food Products*. CRC Press, 2020, pp. 51-67. doi: 10.1201/9780429436963-5.
- [9] L. F. Batista, C. S. Marques, A. C. dos S. Pires, L. A. Minim, N. de F. F. Soares, y M. C. T. R. Vidigal, «Artificial neural networks modeling of non-fat yogurt texture properties: effect of process conditions and food composition», *Food and Bioprocess Processing*, vol. 126, pp. 164-174, mar. 2021, doi: 10.1016/j.fbp.2021.01.002.
- [10] W. Castro *et al.*, «Microstructural analysis in foods of vegetal origin: an approach with convolutional neural networks», en *2019 8th International Conference On Software Process Improvement (CIMPS)*, oct. 2019, pp. 1-5. doi: 10.1109/CIMPS49236.2019.9082421.
- [11] J. Gonçalves Neto, L. Vidal Ozorio, T. C. Campos de Abreu, B. Ferreira dos Santos, y F. Pradelle, «Modeling of biogas production from food, fruits and vegetables wastes using artificial neural network

- (ANN)», *Fuel*, vol. 285, p. 119081, feb. 2021, doi: 10.1016/j.fuel.2020.119081.
- [12] Z. Geng, D. Shang, Y. Han, y Y. Zhong, «Early warning modeling and analysis based on a deep radial basis function neural network integrating an analytic hierarchy process: A case study for food safety», *Food Control*, vol. 96, pp. 329-342, feb. 2019, doi: 10.1016/j.foodcont.2018.09.027.
- [13] S. Mercier y I. Uysal, «Neural network models for predicting perishable food temperatures along the supply chain», *Biosystems Engineering*, vol. 171, pp. 91-100, jul. 2018, doi: 10.1016/j.biosystemseng.2018.04.016.
- [14] M. B. Minaya, A. Torres, A. Chambi, B. Mamani, y H. Gutiérrez, «Physicochemical, microbiological and toxicological quality of raw milk in cattle basins of the region Puno-Peru», *Scientia Agropecuaria*, vol. 6, n.º 3, pp. 165-176, 2015.
- [15] J. Mohd Ali, M. A. Hussain, M. O. Tade, y J. Zhang, «Artificial Intelligence techniques applied as estimator in chemical process systems – A literature survey», *Expert Systems with Applications*, vol. 42, n.º 14, pp. 5915-5931, ago. 2015, doi: 10.1016/j.eswa.2015.03.023.
- [16] J. C. Angeles-Hernandez, A. J. Chay-Canul, F. A. Castro-Espinoza, M. Benaouda, B. Castro-Hernández, y J. A. Salinas-Martinez, «147 Estimation of milk yield based in udder measures of Pelibuey sheep using artificial neural networks (ANN)», *Animal - science proceedings*, vol. 12, n.º 1, p. 117, abr. 2021, doi: 10.1016/j.anscip.2021.03.148.
- [17] Y. Liu, X. Sun, J. Zhou, H. Zhang, y C. Yang, «Linear and nonlinear multivariate regressions for determination sugar content of intact Gannan navel orange by Vis-NIR diffuse reflectance spectroscopy», *Mathematical and Computer Modelling*, vol. 51, n.º 11, pp. 1438-1443, jun. 2010, doi: 10.1016/j.mcm.2009.10.003.
- [18] W. Castro, J. Oblitas, R. Santa-Cruz, y H. Avila-George, «Multilayer perceptron architecture optimization using parallel computing techniques», *PLOS ONE*, vol. 12, n.º 12, p. e0189369, dic. 2017, doi: 10.1371/journal.pone.0189369.