

## REVISTA DIGITAL



# Clasificador de carne de res usando redes neuronales

## Beef classifier using neural networks

Rogelio García Rodríguez<sup>1</sup>, María Xóchitl Altamirano Herrera<sup>1</sup>,  
Armando Arrieta González<sup>1</sup>

---

<sup>1</sup> Instituto Tecnológico Superior de Tantoyuca, Veracruz, México.

---

Recibido: 10-11-2017  
Aceptado: 07-12-2017

Autor corresponsal: **María Xochitl Altamirano-Herrera** xochitl2422@gmail.com

## Resumen

En el presente trabajo se plantea tener un sistema de clasificación de carne de res, mediante un método inteligente de Redes Neuronales Artificiales (RNA) que permita clasificar basado en la normatividad mexicana NMX-FF-078-SCFI-2002, ademas de tomar en cuenta múltiples factores geográficos y de las características del las reses. La RNA usada se basa en el modelo de Perceptrón Multicapa y busca acercarse a exactitud de los métodos utilizados por los expertos. Esta red se entrenó con datos obtenidos de 673 animales, por lo que las características dadas para el entrenamiento se obtienen de cortes en la carne de diferentes partes de la res, los cuales, dado el método aplicado de normalización a estos datos, se escogieron los más relevantes por lo cual se obtuvo así una Red Neuronal Artificial con un 98.66% de exactitud, valor obtenido al comparar con la opinión de los expertos

## Palabras clave:

Red Neuronal Artificial, Clasificación de Carne de Ees, Perceptrón Multicapa.

## Abstract

In the present work it is proposed to have a beef classification system, using an intelligent Artificial Neural Networks (RNA) method that allows classification based on Mexican regulations NMX-FF-078-SCFI-2002, besides taking into account multiple geographical factors and the characteristics of the cattle. The RNA used is based on the Multi-layer Perceptron model and seeks to approximate the accuracy of the methods used by the experts. This network was trained with data obtained from 673 animals, so the characteristics given for training are obtained from cuts in the meat of different parts of the beef, which, given the applied method of normalization to these data, were chosen the more relevant for which an Artificial Neural Network was obtained with a 98.66% accuracy, value obtained when comparing with the opinion of the experts.

## Keywords:

Artificial Neural Network, Beef Classification, Multi-layer Perceptron.

## Introducción

Con el paso del tiempo, las empresas ganaderas mexicanas han desarrollado nuevas tecnologías y procesos internos con el fin de clasificar la carne de manera eficiente y eficaz, este proceso siempre ha estado bajo la supervisión de un experto capacitado, y con amplio conocimiento en la norma NMX-FF-078-SCFI-2002.

Esta norma surgió con la necesidad de proteger al pequeño y mediano productor de carne en los ranchos, dado esto por la caída del precio del ganado en pie y la disminución de la demanda de carne, generando cartera vencida del sistema bancario nacional, dada la falta de pagos (Chauvet, 1997)

En esta industria y para el consumidor uno de los factores más importantes en la compra de la carne es la terneza, este factor es uno de los más difíciles de calcular por su cierta proporción de origen genético. Por lo anterior, la búsqueda de especímenes o razas que potencialicen la producción de carne más tierna es muy importante y es un área de investigación en constante avance explica (Soria & Corva, 2004). En la búsqueda de estas razas existe un alto grado de exposición a infecciones, las cuales se pueden considerar como un alimento de riesgo potencial (Lora, y otros, 2007).

El pH del músculo de animales sanos y vivos es de alrededor de 7.04 (Johnson, 1994). Este valor se disminuye tras la muerte del animal, principalmente, debido a la degradación del glucógeno a ácido láctico, una reacción en la que el músculo trata de producir energía en ausencia de oxígeno. Esta reacción, depende importantemente de la actividad de una serie de enzimas que son sensibles a la temperatura, por lo que es relevante considerar la temperatura del músculo al momento de hacer la medición del pH.(Braña Varela 2011)

Una de las principales ventajas tecnológicas en la clasificación de la carne es la implementación de Redes Neuronales Artificiales con su capacidad para generalizar, en este escenario las acciones automáticas deben ser vigiladas y solo actuar dado el desempeño óptimo de la RNA (Henríquez y Palma, 2011). Por otra parte, las RNA de Kohonen son buenas herramientas para hacer comparaciones sensoriales (Almeida, Alves, Farias y Curvelo-Santana, 2012), del mismo modo existen varios algoritmos que ayudan a una buena clasificación de la carne.

Con el avance del tiempo la arquitectura de RNA en el Perceptrón multicapa con retro propagación utilizado en este estudio, frente a otras técnicas de IA (Inteligencia Artificial) o métodos estadísticos, reduce la base de datos y sus combinatorias de un tamaño de varios megabytes a tan solo unos Kbyte en archivos de entrenamiento compuestos por los pesos de las RNA, lo cual se presenta una ventaja al momento de utilizar este esquema en computadoras promedio e incluso en dispositivos móviles (Henríquez y Palma, 2011)

La RNA Perceptrón es capaz de detectar y clasificar de manera correcta el comportamiento de una serie de datos, con algún tipo de relación entre ellos, nivelando diversas magnitudes para “predecir” su conducta (Rosas, López, Ripalda, González y Juárez, 2016)

## **Materiales y métodos**

De acuerdo con los diferentes tipos de la carne y factores que afectan al animal, se escogió un método de selección de datos. Seguido de esto, se procedió al análisis y selección de la regla de aprendizaje que más se adapta a los datos.

*Descripción capa de entrada RNA*

La Red Neuronal cuenta con 15 datos de entrada con carácter numérico, que se explican a continuación:

**Localidad:** Refiere a la zona geográfica de procedencia de la res, son 4 localidades del norte de Veracruz que se encuentra cerca del municipio de Tantoyuca. En la Tabla 1 se muestran los números de las localidades.

Tabla 1- Localidad (Elaboración propia)

Localidad	Número
Platón	1
Tempoal	2
Tantoyuca	3
El Higo	4

**Grupo Racial:** Refiere al grupo racial o cruzamiento al que pertenece la res. En la Tabla 2 se muestran los números que corresponden a cada grupo racial.

Tabla 2 - Grupo Racial (Elaboración propia)

Grupo Racial	Número
Cebú	1
Cebú-suizo	2
Suizo	3
Holstein	4

**Tipo:** Simplifica si es hembra o macho o novillo. En la Tabla 3 se muestran los números que corresponden al tipo de animal.

Tabla 3 - Tipo de animal (Elaboración propia)

Tipo	Número
Novilla	1
Vaca	2
Torete	3

**Sistema:** Refiere al sistema de alimentación con el que fue criado la res. En la Tabla 4 se muestra el número que corresponde al tipo de alimentación.

Tabla 4 - Sistema de Pastoreo (Elaboración propia)

Sistema	Número
Alimentación por concentrado	1
Alimentación por pastoreo	2

**Edad:** Edad a la que fue sacrificado el animal.

**KPV:** Kilogramo (Kg) por peso vivo de carne.

Los siguientes 5 datos se miden según su calidad establecida por expertos previamente. En la Tabla 5 se muestran los números que corresponden a las diferentes calidades de carne establecidas por las normas mexicanas.

Tabla 5 – Calidad de la carne (Elaboración propia)

Calidad	Número
Superior	1
Seleccionada	2
Estándar	3
Comercial	4

*Conformación de la canal:* Referencia al grosor de los músculos, grado de plenitud, espesor y partes del canal.

*Distribución de grasa subcutánea:* La grasa de cobertura se valora a nivel del ojo de la costilla.

*Cobertura de grasa perirrenal:* Referencia del grado de cobertura grasa de los riñones del animal.

*Color de la grasa:* Esta dada según el color de la grasa, entre más blanca tendrá una calidad superior.

*Color de la carne:* Esta dada por el color de la carne, si éste es rojo cerezo, se evaluará con mejor calidad.

*Peso Canal Frio Derecho:* En este campo se ingresa el peso del canal frío derecho de la carne en Kilogramos.

*Peso Canal Frio Izquierdo:* En este campo se ingresa el peso del canal frío izquierdo de la carne (Kg).

*Ojo de chuleta:* En este campo si ingresa el área del ojo de la chuleta la medida utilizada es  $cm^2$ .

*Grosor de grasa dorsal:* En este campo se ingresa el grosor de la grasa dorsal y la medida se da en  $ml$ .

### Arquitectura de la RNA

La RNA como podemos ver en la Figura 1 cuenta con 15 neuronas de entrada, figuradas con la letra  $x_i$ , 4 de capa oculta y 4 neuronas de salida que describen las posibles calidades. La representación de la calidad de la carne se muestra en la Tabla 6. En la figura 1, se visualizan con  $y_1, y_2, y_3, y_4$  respectivamente.

Tabla 6 – Valores de la neurona de salida (Elaboración propia)

Calidad	Representación
Superior	{0,0,0,1}
Seleccionada	{0,0,1,0}
Estándar	{0,1,0,0}
Comercial	{1,0,0,0}

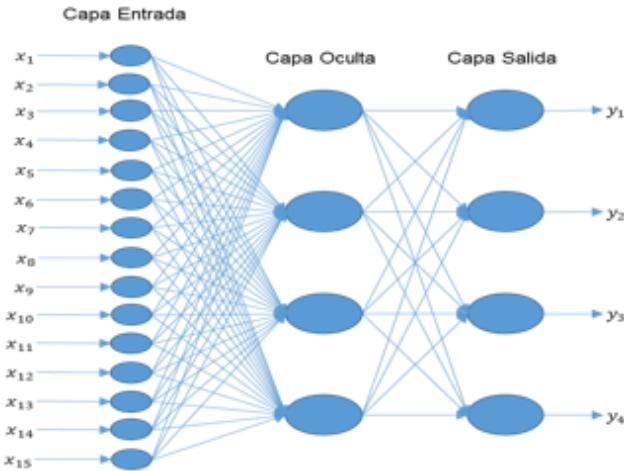


Figura 1- Estructura de la Red Neuronal Artificial Perceptrón Multicapa  
(Elaboración propia)

#### *Normalización y selección de datos*

El objetivo de obtener los datos más relevantes para ser usados en la fase de entrenamiento de la RNA, se realizó el proceso de normalización y selección de datos. En el procedimiento de normalización, por cada uno de los datos mencionados anteriormente, se halla el valor mínimo y máximo del conjunto al que pertenece, con el fin de hallar un equivalente entre 0 y 1 respectivamente, para esto se sigue la Ecuación 1.

$$f(x) = \frac{x - V_{min}}{V_{max} - V_{min}} \quad (1)$$

En la Ecuación 1 podemos observar, donde  $x$  es el valor del rasgo de la res, y el valor máximo y mínimo se representa con  $V_{max}$  y  $V_{min}$  respectivamente.

$$N = \sqrt{\sum_{i=1}^{15} f(C_i)^2} \quad (2)$$

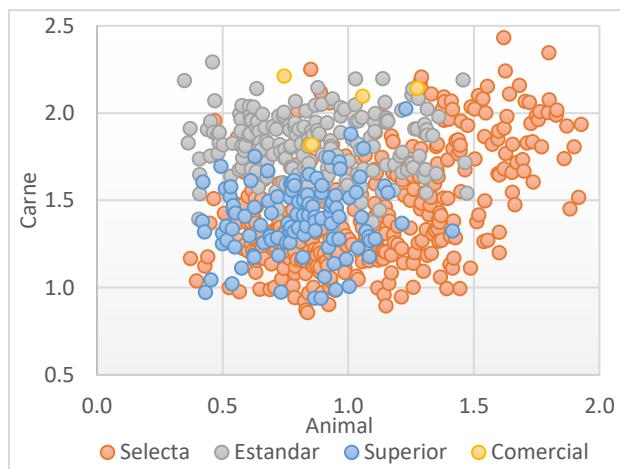
En la Ecuación 2, se halla un valor representativo del conjunto de datos de cada res, donde el parámetro  $C_i$  es el valor numérico de la capa de entrada.

Continuando con la selección, con el valor de  $N$  de cada conjunto de datos de las reses, se agrupan por conjuntos con rangos de 0.2, es decir, los valores normalizados entre 0 y 1 se clasifican en conjuntos entre  $\{[0, 0.2], (0.2, 0.4], (0.4, 0.6], (0.6, 0.8], (0.8, 1]\}$ . Para obtener datos de diferentes valores, evitar entrenar la RNA con valores iguales y garantizar una mayor exactitud, el algoritmo selecciona el mismo número de datos en cada uno de estos conjuntos, si son de diferentes tamaños selecciona el mismo número de los conjuntos y completa el porcentaje de entrenamiento con los conjuntos que aun tengan datos.

### *Regla de aprendizaje*

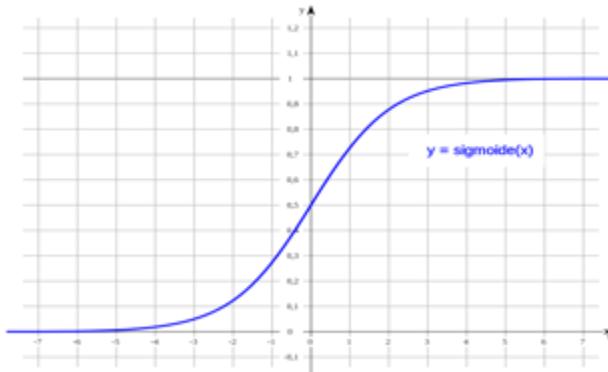
En la Gráfica 1 podemos observar la representación de los datos normalizados. Además, se observar la distribución del conjunto de datos relacionando las características de la res y de la carne. La regla de aprendizaje usada fue Sigmoidal, matemáticamente se representa en la Ecuación 3.

$$P(t) = \frac{1}{1 + e^{-t}} \quad (3)$$



Gráfica 1- Relación Características Animal – Carne (Elaboración propia)

Esta función tiene un rango 0–1 en el eje  $y$ , por lo cual potencializa la normalización realizada anteriormente. En la Gráfica 2 podemos observar su comportamiento en los ejes  $x$ ,  $y$ .



Gráfica 2 - Función Sigmoide

## Resultados y discusión

El lenguaje de programación para realizar la Red Neuronal fue JAVA y se utilizó la librería NEUROPH especializadas para el manejo de RNA. La base de datos se montó en un servidor de MySQL. También, se realizó una plataforma web para poder interactuar con la red neuronal.

Se cuenta con una Red Neuronal Artificial capaz de predecir la calidad de la carne tal como lo realiza un experto que conoce la norma mexicana. De esta manera, es más fácil brindar certeza a los productores y ganaderos de la zona sobre la calidad que tienen sus reses. De este modo, los productores y ganaderos tendrían herramientas para pedir el precio justo por sus reses.

### *Plan de experimentos*

Una vez establecido el conjunto de datos normalizados, el programa prueba varias combinaciones entre el porcentaje de entrenamiento y el número de neuronas en capa oculta; escogiendo un valor para el porcentaje de entrenamiento entre un 50 – 80 %, esto se debe a la cantidad de datos; la variable que modifica el número de neuronas en la capa oculta se establece entre 4 – 20 neuronas y por último el número de repeticiones se establece entre 1 – 10 veces, cada una de estas configuraciones se probaba con diferentes reglas de aprendizaje y se verificaba su efectividad.

### *Comparativa de entrenamiento*

La comparación de datos que veremos en la Tabla 7, se recreó con un número de 4 neuronas, dado que durante todo el proceso de entrenamiento fue la configuración con mayor efectividad.

Tabla 6- Tabla comparativa, por cada uno de los casos y reglas de aprendizaje  
(Elaboración propia)

Pct. Entrenamiento	Núm. Intento	Función	Pct. Eficiencia
50	1	TANH	64,095
		SIGMOID	94,659
55	2	TANH	85,526
		SIGMOID	90,789
60	4	TANH	67,279
		SIGMOID	90,441
65	3	TANH	69,328
		SIGMOID	91,176

Como observamos en la Tabla 7 el valor de exactitud de la RNA con la regla SIGMOID se mantuvo sobre el 90 %, el número en la columna de intento fue donde se obtuvo la mejor configuración de prueba.

#### *Configuración final del clasificador*

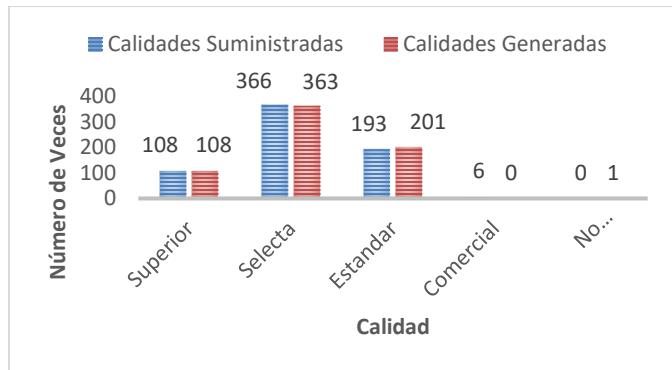
Finalmente, el programa encontró una configuración para la RNA final mostrada en la Tabla 8.

Tabla 7 - Información final de la RNA (Elaboración propia)

Porcentaje de efectividad	98,66%
Función de transferencia	TransferFunctionType. SIGMOID
Núm. de datos de entrada	15
Núm. de datos de salida	4
Núm. de neuronas en la capa oculta	4

#### *Comparación de resultados*

La comparación de resultados (ver gráfica 3) se realizó entre el resultado suministrado por expertos (*Etiqueta Calidades Suministradas*), y los resultados obtenidos por la RNA (*Etiqueta Calidades Generadas*). Para este grupo de datos que se evaluaron tenemos un 1.34 % de error en general, al igual podemos observar la exactitud del 100% en la calidad Superior, calidad Selecta con un 99%, calidad Estándar obtuvo un error del 4%, en cuanto a la calidad Comercial se obtuvo un 0 % de exactitud, esto se debe a la cantidad de datos obtenidos de esta calidad y por último un conjunto de datos el cual la Red Neuronal Artificial clasificó de forma errónea.



Gráfica 3 - Comparativa de resultados de la RNA

## Conclusiones

Por medio de esta investigación, se estableció otro uso para las Redes Neuronales Artificiales con el cual se puede beneficiar el sector ganadero no solo de México, si no que también el de diferentes países, con una normativa similar. La Red Neuronal Artificial Perceptrón Multicapa como la que se utilizó en esta investigación es capaz de detectar y clasificar de manera correcta el patrón de clasificación de la carne de una res de un conjunto de datos previamente evaluados por expertos, demostrando así su capacidad de predicción.

La siguiente etapa en este trabajo es poder tener la red neuronal artificial en la palma de la mano, es decir, contar con una app que permita usar la red neuronal en cualquier dispositivo móvil con android. De esta manera, se pondría al alcance de todos poder usar la red neuronal desarrollada.

## Referencias bibliográficas

- Almeida, P. F., Alves, W. A., Farias, T. M., & Curvelo-Santana, J. C. (2012). Elaboración y Clasificación Sensorial de Gelatinas de Patas de Pollos: Correlación usando Redes Neuronales Artificiales. *Información tecnológica*, 23(6), 129-136. doi:<https://dx.doi.org/10.4067/S0718-07642012000600014>
- Chauvet, M. (1997). *La Ganadería Mexicana frente al fin de siglo*. Guadalajara, México: Departamento de Sociología Universidad Autónoma Metropolitana Azcapotzalco.
- Fornias, O. V., & Díaz, C. V. (1998, Octubre 7). Clasificación de los productos cárnicos. *Cubana Aliment Nutr*, 18(1), 63-7.
- Gallo, C., Caro, M., Villarroel, C., & Araya, P. (1999). Características de los bovinos faenados en la Xa Región (Chile) según las pautas indicadas en las normas oficiales de clasificación y tipificación. . *Archivos de medicina veterinaria*, 31(1), 81-88. doi:<https://dx.doi.org/10.4067/S0301-732X1999000100008>
- Henríquez, M. R., & Palma, P. A. (2011). Control Automático de Condiciones Ambientales en Domótica usando Redes Neuronales Artificiales. . *Información tecnológica*, 22(3), 125-139. doi:<https://dx.doi.org/10.4067/S0718-07642011000300014>
- JALISCO, U. D. (2012). *AUMENTÓ 89.5% EL CONSUMO DE CARNE POR PERSONA EN JALISCO*. San Pedro Tlaquepaque: Gobierno Federal.

- Lora, F., Aricapa, H. J., Pérez, J. E., Arias, L. E., Idarraga, S. E., Mier, D., & Gómez, J. E. (2007). Detección de Toxoplasma gondii en carnes de consumo humano por la técnica de reacción en cadena de la polimerasa en tres ciudades del eje cafetero. *Infectio*, 11(3), 117-123.
- Rosas, P. G., López, J. V., Ripalda, M. H., González, S. H., & Juárez, I. L. (2016). Uso de la red neuronal Perceptrón para detección de cambios pequeños en la media en los gráficos de control. *10th Latin American and Caribbean Conference for Engineering and Technology* (pp. 1-10). Panama City: 1 st LACCEI International Symposium on Software Architecture and Patterns.
- Soria, L. A., & Corva, P. M. (2004, Mayo-Agosto). Factores genéticos y ambientales que determinan la terneza de la carne bovina. *Archivos Latinoamericanos de Producción Animal*, 12(2), 73-88.
- Wikipedia. (2016, Abril 20). *Clasificación De La Carne*. Retrieved from [https://es.wikipedia.org/wiki/Clasificaci%C3%B3n\\_de\\_la\\_carne](https://es.wikipedia.org/wiki/Clasificaci%C3%B3n_de_la_carne)
- Wikipedia. (2016, Abril 20). *Red Neuronal Artificial*. Retrieved from [https://es.wikipedia.org/wiki/Red\\_neuronal\\_artificial](https://es.wikipedia.org/wiki/Red_neuronal_artificial)