



## Predicción por redes neuronales artificiales del peso corporal de *Capra hircus* en crianza semiextensiva

Prediction by artificial neuronal networks of *Capra hircus* body weight in semiextensive breeding

Miguel Callacná-Custodio<sup>1,\*</sup>; Joan Díaz-Huamanchumo<sup>1</sup>; Víctor Vásquez-Villalobos<sup>2</sup>

<sup>1</sup> Escuela Profesional de Zootecnia. Universidad Nacional de Trujillo, Av. Juan Pablo II s/n. Trujillo, Perú.

<sup>2</sup> Escuela de Postgrado. Universidad Nacional de Trujillo, Av. Juan Pablo II s/n. Trujillo, Perú.

### RESUMEN

Objetivo del presente trabajo fue predecir por redes neuronales artificiales (RNA) el peso corporal de caprinos en crianza semiextensiva. Se utilizó 40 caprinos criollos mejorados desde el nacimiento hasta las seis semanas de edad. El 80% de la data fue utilizada para entrenar la red y el 20% para validarla. El tipo de RNA usada fue del tipo feedforward (FF), con algoritmo de entrenamiento Backpropagation (BP) y ajuste de pesos Levenberg-Marquardt (LM), topología que presentó el mejor resultado: 3 entradas, seis salidas lineales (purelin), capa oculta con 42 neuronas, tasa de aprendizaje de 0,01, coeficiente de momento de 0,5, meta del error de 0,0001 y 100 etapas de entrenamiento. Comparativamente el error porcentual promedio de los valores predichos por la RNA fue de 7,51 y por la regresión múltiple de 7,80 no existiendo diferencia significativa entre ambos ( $p > 0,05$ ). Así mismo, el porcentaje de aciertos de la RNA fue de 50% y de la regresión múltiple de 50%, mostrando en ambos casos un rendimiento similar.

**Palabras clave:** Redes neuronales artificiales; caprinos criollos mejorados; sistema de crianza; peso corporal; regresión múltiple.

### ABSTRACT

Objective of the present work was to predict by artificial neural networks (RNA) the body weight of goats in semiextensive breeding. Forty improved Creole goats were used from birth to six weeks of age. 80% of the data was used to train the network and 20% to validate it. The type of RNA used was feedforward (FF), with Backpropagation (BP) training algorithm and weight adjustment Levenberg-Marquardt (LM), topology that presented the best result: 3 inputs, six linear outputs (purelin), hidden layer with 42 neurons, learning rate of 0,01, moment coefficient of 0,5, error goal of 0,0001 and 100 training stages. The average percentage error of the values predicted by the RNA was 7,51 and by the multiple regression of 7,80 there was no significant difference between both ( $p > 0,05$ ). Likewise, the percentage of hits of the RNA was 50% and the multiple regression of 50%, showing in both cases a similar performance.

**Keywords:** Artificial neural networks; Improved creole goats; System of breeding; body weight; Multiple regression.

### 1. Introducción

La predicción ha pasado a desempeñar un papel fundamental con el uso de diversas técnicas, como las que brinda la inteligencia artificial, con la cual es posible solucionar problemas que sean de interés, en aras de ahorrar tiempo y recursos. El sector agropecuario no es ajeno a este fenómeno y dentro de este los pastos y forrajes, pues debido a la naturaleza intrínsecamente compleja, dinámica y no lineal de sus procesos, han requerido de soluciones basadas en técnicas avanzadas, que proporcionen mejor exactitud y comprensión de los resultados (Pascual, 2016). El análisis predictivo se fundamenta en la identificación de relaciones entre

variables de eventos pasados, para luego explotar dichas relaciones y predecir posibles resultados (Espino *et al.*, 2017).

Mercado (2015) define a las Redes Neuronales Artificiales (RNA) como sistemas de procesamiento de la información, cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. En los últimos años se ha masificado su uso para la predicción de series temporales, gracias a su capacidad generalizadora, por el hecho de aprender a partir de ejemplos, tal y como lo hace el cerebro humano.

Sus propiedades y características han hecho de ellas una herramienta usada con frecuencia en la

resolución con éxito de problemas reales de gran complejidad, como la predicción de datos de crecimiento microbiano (Vásquez *et al.*, 2013).

Sánchez *et al.* (2015) utilizaron una RNA para la predicción de la cinética de extracción de aceite de canola con hexano, con resultados que muestran la eficacia y la potencialidad de su uso.

Mehri (2014) Introdujo la función de deseabilidad como algoritmo multiobjetivo, para optimizar los modelos de respuesta de aves basados en la metodología de superficie de respuesta SR y RNA, concluyendo que la aplicación de la RNA junto con un algoritmo de optimización multiobjetivo, podría ser una herramienta útil para la optimización de aminoácidos dietéticos en experimentos factoriales fraccionados, en los cuales el uso de la función de deseabilidad global puede ser capaz de superar las subestimaciones de aminoácidos en la dieta que resulta del modelo SR.

Pascual *et al.* (2017) obtuvieron modelos de RNA para predecir indicadores productivos y de calidad de pastos de las especies *Megathyrus maximus*, *Brachiaria decumbens* y *Brachiaria brizantha* x *Brachiaria ruziziensis*, lográndose agilizar el proceso de caracterización de dichos pastos y evitar el uso de complejas técnicas de laboratorio.

Galeano-Vasco y Cerón-Muñoz (2013) modelaron la curva del crecimiento de aves de la línea Lohmann utilizando modelos no lineales (MNL), no lineales mixtos (MNLM) de Von Bertalanffy y RNA, concluyendo que el mejor modelo, fue el MNLM. La RNA presentó un desempeño superior al MNL.

Mehri (2013) Comparó la capacidad de predicción de la RNA con la de lógica difusa. Las evaluaciones estadísticas mostraron que el modelo RNA predijo la incubabilidad con mayor precisión que la lógica difusa, con un mayor coeficiente de determinación  $R^2 = 0,99$ .

Salawu *et al.* (2014) desarrollaron modelos de RNA y regresión lineal múltiple para predecir el peso corporal en conejos puros y cruzados de ocho semanas de edad de la raza blanca neozelandesa, concluyendo que los modelos RNA son más poderosos que los modelos de regresión lineal múltiple en la predicción del peso corporal de los conejos. Similares hallazgos han sido reportados por Felipe *et al.* (2015) en la predicción de la producción total de codornices tipo carne. Sin embargo, Gorgulu (2012) determinó que los valores predichos por la RNA estaban más cerca de los valores medios reales sin mostrar ninguna diferencia estadística con la regresión lineal múltiple.

Favaro *et al.* (2014) evaluaron la confiabilidad del perceptrón multicapa para automatizar el proceso

de clasificación de las llamadas, según la identidad individual, Los resultados demostraron que las RNA son una herramienta poderosa para estudiar las señales vocales según la identidad individual, la pertenencia al grupo y la maduración de la especie en las llamadas de contacto.

Vargas *et al.* (2017) reportaron que el Instituto Internacional de Investigaciones en ganadería estima una población mundial de 861 millones de caprinos, encontrándose la mayor parte en el mundo en desarrollo. Estos animales Toleran el calor y la falta de agua, y producen alimentos en climas y terrenos donde los vacunos y los ovinos no sobreviven, utilizan forraje de baja calidad, caminan mucho para encontrarlo y contribuyen a la seguridad alimentaria de poblaciones en áreas marginales, como fuente de nutrientes de alta calidad. Indican también que un 2% de la leche producida mundialmente es de cabra, del cual el 83% corresponde a países en desarrollo. La carne caprina es el 2% de la producción mundial de carne, y su consumo alcanza el 97% en países en desarrollo. En el mundo se ha duplicado la producción de carne caprina en los últimos 25 años. La población de ganado caprino al 2014 en el Perú fue de 1,910,708 cabezas siendo las unidades agrarias con mayor población caprina porcentual Piura (20,77%), Ayacucho (11,35%) Huancavelica (9,94%) Lima (9,68%), Ancash (8,90%), La Libertad (6,11%), Apurímac (5,59%), Huánuco (5,32%), las unidades agrarias restantes en el país muestran porcentajes inferiores (INEI, 2014).

La crianza de caprinos se realiza mayormente en un sistema productivo extensivo tradicional, con poca producción y bajos ingresos económicos, en el que los caprinocultores tienen un bajo nivel educativo y existe poca inversión en el sector por parte del gobierno, de los mismos productores, y ausencia de asistencia técnica Gómez-Urviola *et al.* (2016). Para asegurar la continuidad de los sistemas caprinos extensivos, los caprinocultores deben mejorar globalmente la genética, reproducción, alimentación, sanidad y comercialización (Sarria *et al.*, 2014).

Ivanović *et al.* (2016) en su revisión sobre calidad de la carne de cabra y su impacto en la salud humana, indican que contiene aproximadamente 75,42% de agua; 3,55% de grasa; 19,95% de proteína y 1,06% de materia mineral. El valor energético es de aproximadamente 580 kJ por 100 g, bajo contenido de ácidos grasos saturados, colesterol y tiene aminoácidos esenciales como lisina, treonina y triptófano.

Estudios sobre redes neuronales en ruminantes menores en general y en caprinos en particular son

muy escasos, Por lo que el objetivo de la investigación fue predecir por redes neuronales artificiales el peso corporal de caprinos en crianza semiextensiva y utilizar la información para facilitar la selección con fines de mejoramiento productivo.

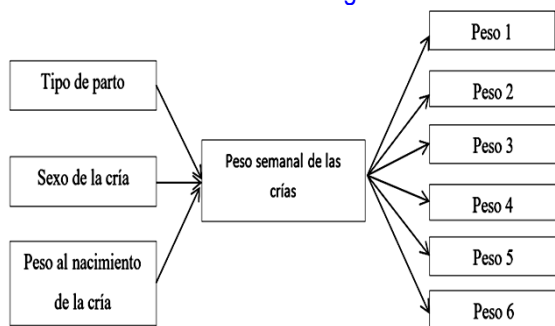
## 2. Material y métodos

### 2.1 Material de estudio

40 Caprinos criollos mejorados en sistema semiextensivo de crianza, localizado en el sector el Inca, distrito de Chao, provincia de Virú cuyas coordenadas de ubicación son 8°30'35.42"S 78°39'06.73"O a 117 metros de elevación. El periodo de estudio comprendió desde el nacimiento hasta el momento en que los animales son comercializados, es decir a las seis semanas.

### 2.2 Métodos

Para la determinación de la capacidad predictiva de la RNA se seleccionaron 3 variables de entrada: tipo de parto de la madre, sexo de la cría, peso al nacimiento de la cría y 6 variables de salida: peso a la primera, segunda, tercera, cuarta, quinta y sexta semana como se indica en la [Figura 1](#).



**Figura 1.** Variables de entrada y de salida para determinar la capacidad predictiva de la red neuronal artificial.

Se trabajó con el software MATLAB 7.0, operándose con una red alimentada hacia 3 adelante (Feedforward) con algoritmo de entrenamiento backpropagation y ajuste de pesos Levenberg-Marquardt. Se determinó la arquitectura adecuada, ajustando las neuronas en las capas ocultas, cambiando las funciones de transferencia, etapas de entrenamiento con el fin de buscar la disminución del error cuadrático medio (ECM). Se ajustó la meta del error, el coeficiente de momento, la tasa de aprendizaje, validándose finalmente la red entre los valores esperados y predichos.

De las 40 unidades experimentales se seleccionaron aleatoriamente 32 unidades para el entrenamiento (80%) y 8 unidades para la validación (20%).

Para determinar el efecto del error meta, del número de neuronas y de etapas de entrenamiento se ensayó varios números de neuronas (del 1 al 50).


Se evaluó el efecto de la variación de los ciclos de entrenamiento (50, 100, 150, 200, 250, 300 y 350), buscando el menor error cuadrático medio (ECM).

Se evaluó el efecto de las funciones de transferencia: tangente sigmoide hiperbólica (tansig), logarítmica sigmoide hiperbólica (logsig) y función lineal (purelin); las que fueron combinadas de dos en dos. Se evaluó la combinación con la cual se obtuvo menor ECM.

Para determinar el efecto de la tasa de aprendizaje y del coeficiente de momento, con la combinación de funciones, etapa y neurona escogida se ensayó varias tasas de aprendizaje (0,001; 0,01; 0,1; 0,2; 0,4; 0,6; 0,8; 1) y de momento (0,2; 0,4; 0,6; 0,8; 1; 1,5; 2).

## 3. Resultados y discusión

En la [Tabla 1](#) se muestra la base de datos utilizada para determinar la capacidad predictiva de la RNA. La [Tabla 2](#) indica el 20% de los valores de la base de datos que fueron seleccionados aleatoriamente y utilizados para la validación de la RNA.



**Figura 2.** Variación del error cuadrático medio (ECM) de 50 neuronas con una capa oculta.

Datos seleccionados aleatoriamente y utilizados para el entrenamiento y validación de la red en este trabajo correspondieron a 80% y 20% respectivamente. Porcentajes de 80%, 10% y 10% para el entrenamiento, validación y prueba han sido reportados por [Salawu \(2014\)](#) en su estudio sobre uso de RNA para predecir el peso vivo de conejos. [Ferrero \(2014\)](#) en la generación de un modelo mediante el uso de RNA para la detección de mastitis en vacas lecheras utilizó el 75% de los datos para el entrenamiento y 25% para la validación.

**Tabla 1**

Base de datos para determinar la capacidad predictiva de la red neuronal artificial

N°	Tipo de parto de la madre	Sexo de la cría	Peso al nacimiento de la cría (kg)	Pesos semanales de las crías					
				peso 1	peso 2	peso 3	peso 4	peso 5	peso 6
1	1	1	3,70	5,00	6,15	7,45	8,25	9,10	10,65
2	1	1	3,15	4,75	5,80	6,45	7,30	8,40	9,10
3	1	2	3,55	4,70	5,90	6,70	8,15	9,55	11,15
4	1	2	3,65	4,85	5,70	6,65	7,65	9,50	10,50
5	1	2	3,75	5,00	6,15	7,30	7,85	9,60	10,70
6	1	2	4,25	5,35	6,35	8,00	9,40	11,45	12,70
7	1	1	4,45	6,00	7,30	8,50	10,35	11,95	13,65
8	2	1	4,10	5,50	6,70	7,90	9,00	10,00	10,85
9	2	2	4,20	5,75	6,80	7,80	8,80	9,70	10,60
11	2	1	3,75	4,90	5,50	6,30	7,15	8,25	9,75
14	2	2	3,85	5,25	6,50	7,35	8,05	9,35	11,70
18	2	2	4,25	5,45	6,50	6,85	7,40	8,35	10,45
19	2	2	3,75	4,60	5,75	6,25	6,70	7,75	9,55
20	2	2	3,30	4,75	5,65	6,65	7,35	8,40	9,45
21	2	1	3,40	4,75	5,30	6,05	7,20	8,55	9,50
22	2	2	3,25	4,95	6,05	7,75	8,25	9,30	10,25
23	2	1	4,50	6,00	7,15	8,70	10,25	11,3	12,50
25	2	1	4,45	5,75	6,70	7,55	8,45	9,05	9,85
26	2	2	3,60	5,05	6,00	6,95	8,00	8,85	9,75
27	2	2	3,00	3,90	4,70	5,70	6,60	7,50	8,35
28	2	1	4,15	5,80	6,85	7,80	8,60	9,40	10,25
29	2	2	4,45	5,75	6,15	7,35	8,30	9,20	10,10
30	2	1	3,70	4,80	5,65	6,55	7,70	8,90	9,80
32	3	2	3,70	4,90	5,85	7,10	8,35	10,70	11,50
33	3	2	3,05	4,40	5,70	6,90	8,00	8,80	9,70
34	3	1	4,00	5,75	6,00	7,25	8,30	9,25	10,45
35	3	1	3,00	4,10	5,00	5,25	6,35	7,20	8,15
36	3	1	3,50	4,60	5,50	6,40	7,25	8,05	8,90
37	3	2	3,25	4,75	6,00	6,90	8,00	10,00	11,30
38	3	1	3,25	4,50	5,45	7,00	8,50	9,75	11,10
39	3	2	3,7	4,85	6,00	7,70	9,45	10,65	11,80
40	3	2	2,65	3,50	4,70	5,65	6,45	7,50	8,60

**Tabla 2**

Valores de la base de datos utilizados para la validación de la red neuronal artificial

N°	Tipo de parto de la madre	Sexo de la cría	Peso al nacimiento de la cría (kg)	Pesos semanales de las crías					
				Peso 1	Peso 2	Peso 3	Peso 4	Peso 5	Peso 6
10	2	2	3,75	4,80	5,45	6,20	7,10	8,00	8,85
12	2	1	4,10	5,40	6,30	7,50	7,80	9,10	9,09
13	2	2	3,60	4,80	5,25	5,85	6,55	7,60	8,60
15	2	1	3,90	5,10	6,20	7,55	8,65	10,10	12,15
16	2	1	3,95	5,15	6,30	7,60	8,60	9,80	10,85
17	2	2	3,25	4,50	5,85	6,90	7,85	9,15	10,10
24	2	2	3,30	4,75	5,70	7,05	8,80	9,70	10,60
31	2	1	3,90	5,00	5,80	6,50	7,80	8,70	9,50

La [Tabla 3](#) muestra la variación del número de neuronas de la capa oculta y del error cuadrático medio, observándose que con 34, 41, 42, 46, 48, 49 neuronas se encontró un error cuadrático medio

mínimo de 0,00718, 0,00564, 0,00439, 0,00541, 0,00453, 0,00451 respectivamente. El mínimo error cuadrático medio de 0,00449 se obtuvo con la neurona 42 y se observa en la [Figura 2](#).



**Tabla 3**

Numero de neuronas que mostraron el mínimo error cuadrado medio

Error deseado	Número de neuronas					
	34	41	42	46	48	49
1,00E-01	0,097	0,0847	0,0863	0,0465	0,0962	0,0738
1,00E-02	0,00981	0,00984	0,0089	0,00941	0,00988	0,00909
1,00E-03	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-04	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-05	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-06	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-07	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-08	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-09	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451
1,00E-10	0,00718	0,00564	0,00439	0,00541	0,00453	0,00451

En la [Tabla 4](#) se muestra la variación de los ciclos de entrenamiento de la neurona N° 42. Se observa que al aumentar los ciclos de entrenamiento de 50 a 100, 150, 200, 250, 300 y 350 el ECM se mantuvo en 0,00439. La [Tabla 5](#) muestra la variación de las funciones de transferencia en la capa oculta y capa de salida, observándose que el cuadrado medio del error de 0,00439 correspondió a la función tansig-purelin.

**Tabla 4**

Variación de las etapas de entrenamiento de la neurona 42

Ciclos de entrenamiento	Neurona N°42
50	0,00449
100	0,00439
150	0,00439
200	0,00439
250	0,00439
300	0,00439
350	0,00439

**Tabla 5**

Cuadrado medio del error al variar las funciones de transferencia

Función de transferencia		MSE
Capa oculta	Capa salida	
Tansig	Purelin	0,00439
Logsig	Purelin	0,00624
Purelin	Purelin	0,437
Tansig	Tansig	47,800
Logsig	Tansig	47,800
Purelin	Tansig	47,800
Tansig	Logsig	47,800
Logsig	Logsig	47,800
Purelin	Logsig	47,800

Con respecto al número de capas ocultas y neuronas, [Chaturvedi et al. \(2013\)](#) indican que normalmente, una o dos capas ocultas dentro de un

gran número aleatorio de neuronas pueden ser suficientes para estimar cualquier función.

Las [Tablas 6 y 7](#) muestra el error cuadrático medio al variar las tasas de aprendizaje y el coeficiente de momento de 0,001 a 1 y de 0,2 a 2 respectivamente, observándose que la variación de dichas tasas no produce cambios en el ECM, manteniéndose el valor de 0,00439.

**Tabla 6**

Cuadrado medio del error al variar la tasa de aprendizaje

Tasa de aprendizaje	MSE
0,001	0,00439
0,01	0,00439
0,1	0,00439
0,2	0,00439
0,4	0,00439
0,6	0,00439
0,8	0,00439
1	0,00439

**Tabla 7**

Cuadrado medio del error al variar la tasa de momento

Tasa de momento	MSE
0,2	0,00439
0,4	0,00439
0,6	0,00439
0,8	0,00439
1	0,00439
1,5	0,00439
2	0,00439

El valor de la tasa de aprendizaje  $\alpha$  tiene un papel crucial en el proceso de entrenamiento de una red neuronal, ya que controla el tamaño de cambio de los pesos en cada iteración. En el presente trabajo se evaluaron tasas de aprendizaje que variaron de

0,01 a 1 observándose un cuadrado medio del error similar en todas las tasa evaluadas, al respecto Quintin y De Paz (2007) indican que en general, el valor de la tasa de aprendizaje suele estar comprendido entre 0,05 y 0,5; y que se deben evitar dos extremos: un ritmo de aprendizaje demasiado pequeño puede ocasionar una disminución importante en la velocidad de convergencia y la posibilidad de quedar atrapado en un mínimo local; en cambio, un ritmo de aprendizaje demasiado grande puede conducir a inestabilidades en la función del error, lo cual evitará que se produzca la convergencia debido a que se darán saltos en torno al mínimo sin alcanzarlo. Un método para evitar la inestabilidad en el algoritmo de aprendizaje debido a  $\alpha$ , es mediante la inclusión del término "momento". Gómez (2014) utilizó valores para la tasa de entrenamiento de 0,01; 0,05 y 0,1, para el momento 0,9 y 0,5. Según el autor, estos valores permiten la evaluación de diferencias en el comportamiento de la red, lo que hace que el entrenamiento sea más robusto. La variación de la tasa de momento de 0,2 a 2 en la presente investigación no influyó en el ECM, manteniéndose igualmente constante.

En la Figura 3 se muestra que el error cuadrático medio desciende al variar las etapas de entrenamiento de la red, observándose, que el descenso comienza a estabilizarse a un valor de 0,00439, a partir de los 50 ciclos de entrenamiento.

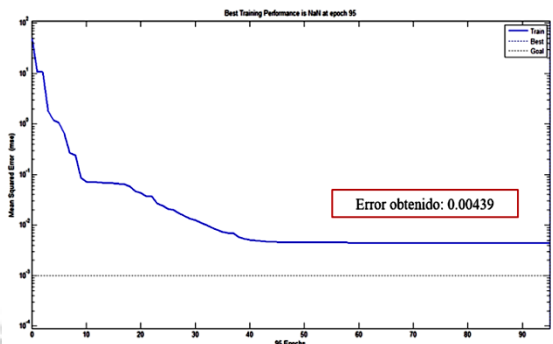


Figura 3. Variación del error cuadrático medio al variar los ciclos de entrenamiento de la red neuronal artificial.

Los ciclos de entrenamiento de la red variaron de 50 a 350 y al obtenerse un error cuadrático medio de 0,00439 en 100 ciclos y mantenerse el error constante hasta 350 ciclos de entrenamiento ya no fue necesario aumentarlos. Galeano-Vasco y Ceron-Muñoz (2013) señalan que, en su estudio, La RNA se programó para que la red pudiese generar relaciones lineales con la neurona de salida, con la posibilidad de crear conexiones directas entre la neurona de entrada con un número mínimo de 1000 iteraciones.

La Figura 4 muestra los valores predichos por la RNA con respecto a los valores deseados, observándose que dichos valores durante la fase de entrenamiento se superponen en una sola línea, obteniéndose un R de 0,99948.

En la Figura 5 se observa que la primera capa de neuronas corresponde a las variables de entrada, el segundo nivel de neuronas a la capa oculta y la tercera capa de neuronas a la variable de salida. La mejor topología seleccionada para el modelo neuronal fue de tres entradas, seis salidas purelin, capa oculta con 42 neuronas, variación de la tasa de aprendizaje de 0,001 a 1, variación de la tasa de momento de 0,2 a 2, meta del error 0,0001 y 50 a 350 etapas de entrenamiento, utilizando el algoritmo de entrenamiento BackPropagation y el algoritmo de ajuste de pesos Levenberg-Marquardt. El desempeño del aprendizaje, no llegó al error meta de 0,0001; pero produjo un ECM mínimo de 0,00439.




Figura 4. Valores predichos por la red neuronal artificial con respecto a valores deseados.

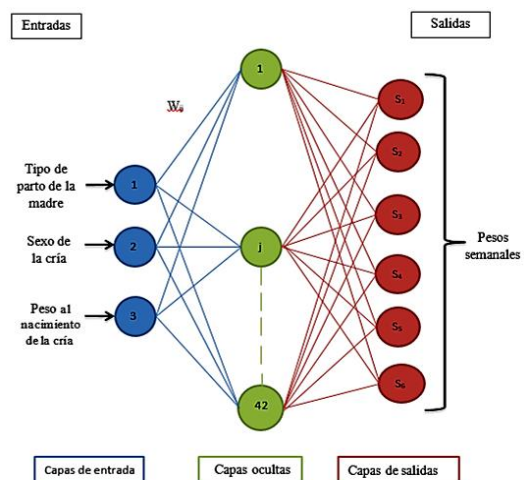


Figura 5. Topología de la red neuronal artificial.

El algoritmo de ajuste de pesos de Levenberg - Marquardt es un método más sofisticado que el gradiente descendente que proporciona, entre otras mejoras, menor tiempo de entrenamiento. Al respecto, [Díaz-González et al. \(2013\)](#) concluyeron que después de probar un número significativo de técnicas de entrenamiento, el algoritmo de optimización Levenberg-Marquardt es el algoritmo más rápido, dado que converge con menos iteraciones que cualquier otro algoritmo probado. Asimismo, destacan que sus resultados de entrenamiento fueron más consistentes usando dicho algoritmo que usando otros algoritmos, con los cuales observaron que los parámetros de pesos y bias presentaban cierta oscilación. Señalan, además, que la literatura reporta que el algoritmo Levenberg-Marquardt es ineficiente para entrenar grandes RNA, debido a su alto costo computacional.

En la [Tabla 8](#) se muestra el promedio de los valores semanales esperados y el promedio de los valores predichos por la RNA y regresión múltiple, observándose similitud entre los promedios de los valores esperados y el promedio de los valores predichos por la Red Neuronal.

**Tabla 8**

Promedio de los valores semanales esperados y promedio de los valores predichos por la red neuronal artificial y regresión lineal múltiple

Semana	Promedio de los valores esperados	Promedio de los valores predichos	
		RNA	Regresión
1	4,9375	4,9753	5,0309
2	5,8563	5,8179	6,0111
3	6,8938	6,8667	7,0414
4	7,8938	7,7755	8,0715
5	9,0188	8,8613	9,2467
6	10,0688	10,1836	10,3801
Promedio	7,4448	7,4134	7,6303

El promedio del error porcentual de los valores predichos por la RNA y la regresión múltiple, se presenta en la [Tabla 9](#).

**Tabla 9**

Error porcentual promedio de los valores predichos por la red neuronal artificial y la regresión lineal múltiple

Semana	Error porcentual promedio (%)	
	RNA	Regresión
1	3,5141	3,2756
2	6,8513	5,0660
3	7,1558	8,2885
4	9,9956	9,8067
5	8,4430	9,6874
6	9,1152	10,6539
Promedio	7,5125	7,7964

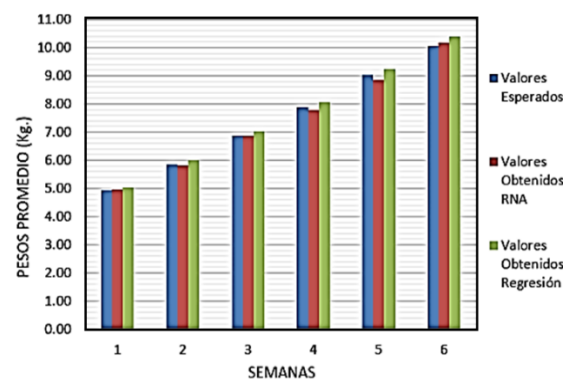
Se obtuvo menor error porcentual con la RNA respecto a la regresión. No se encontró diferencias significativas ( $p > 0,05$ ) entre los valores esperados y los valores predichos, y el porcentaje de aciertos fue similar en la RNA y en la regresión múltiple. Este hallazgo último, difiere de lo señalado por [Morales-Tamayo et al. \(2018\)](#) quien encontró mejores porcentajes de acierto con las RNA que con la regresión. [Ahmad \(2012\)](#), desarrollando modelos matemáticos o estadísticos y de inteligencia artificial para comparar los pronósticos de producción de huevos en ponedoras comerciales, concluyo que en general los modelos de redes neuronales son eficientes, fáciles de usar, requieren menos datos y son prácticas para pronosticar la producción de huevos bajo las condiciones de manejo de granjas. Estudios más recientes de [Sheta et al. \(2015\)](#) reportan que los modelos de Maquinas de Vectores de Soporte (SVM), complemento a los modelos de redes neuronales y el modelo de Funciones de Base Radial (RBF) proporcionan buenas capacidades de predicción. No existe diferencia estadísticamente significativa entre los valores esperados o reales y los valores obtenidos por la regresión y RNA ([Tabla 10](#))

**Tabla 10**

Análisis de varianza de valores obtenidos por regresión y red neuronal artificial

	Suma de cuadrados	GL	Media cuadrática	F	Sig.
Inter-grupos	1,309	2	0,655	0,185	0,831
Intra-grupos	499,395	141	3,542		
Total	500,704	143			

En la [Figura 6](#) se muestra un comparativo de los valores reales promedio semanal y los valores promedio semanal obtenidos, empleando la RNA y la Regresión Lineal Múltiple, observándose que existe similitud entre ambas.



**Figura 6.** Comparativo de los valores reales promedio semanal obtenidos empleando la red neuronal artificial y la regresión lineal múltiple.

En la [Tabla 11](#) se observa los porcentajes de aciertos de la RNA y la regresión lineal múltiple para pesos semanales, observándose similitud porcentual entre ambas.

**Tabla 11**

Porcentaje de aciertos de la red neuronal artificial y regresión lineal múltiple para pesos semanales

Semanas	% de aciertos	
	RNA	Regresión
1	75	25
2	50	50
3	50	50
4	37,5	62,5
5	50	50
6	37,5	62,5
TOTAL (%)	50	50

En la [Tabla 12](#) se muestran la comparación entre los coeficientes de correlación (R) y determinación (R<sup>2</sup>) de los valores esperados con los predichos por la RNA y regresión lineal múltiple según las unidades de validación.

**Tabla 12**

Comparación de los coeficientes de correlación y determinación de los valores esperados con los predichos por la red neuronal artificial y regresión lineal múltiple según las unidades de validación

Unidad de validación	RNA		Regresión	
	r	R <sup>2</sup>	r	R <sup>2</sup>
1	0,974	0,949	0,999	0,998
2	0,991	0,982	0,991	0,982
3	0,984	0,968	0,993	0,986
4	0,999	0,998	0,995	0,990
5	0,992	0,984	0,998	0,996
6	0,989	0,978	0,998	0,996
7	0,988	0,976	0,988	0,976
8	0,991	0,982	0,998	0,996
Promedio	0,989	0,977	0,995	0,990

La RNA resulto ser ligeramente más adecuada que la regresión múltiple en la predicción del peso vivo de caprinos. Es importante indicar que en el entrenamiento de la red no se utilizaron patrones normalizados, sin embargo, [Hulya y Akilli \(2015\)](#) sometieron sus datos a un procesamiento previo de normalización con la finalidad de reducir las dificultades durante el aprendizaje y agilizar el proceso de entrenamiento de la red. Así mismo [Vega et al. \(2015\)](#) con el fin de obtener datos más relevantes para ser usados en la fase de entrenamiento de la RNA, realizaron el proceso de normalización y selección de datos.

## 4. Conclusiones

En la predicción del peso corporal de caprinos en crianza semiextensiva, la red neuronal artificial y el modelo de regresión múltiple tuvieron un rendimiento similar.

## Referencias bibliográficas

- Ahmad, H.A. 2012. Pronósticos para la producción de huevos. Journal of Applied Poultry Research. Disponible en: [www.wattagnet.com/articles/11884-pronosticos-para-una-mejor-produccion-de-huevos-mediante-un-modelo-eficiente](http://www.wattagnet.com/articles/11884-pronosticos-para-una-mejor-produccion-de-huevos-mediante-un-modelo-eficiente).
- Chaturvedi, S.; Gupta, A.K.; Yadav, R.L.; Sharma, A.K. 2013. Life time milk amount prediction in dairy cows using artificial neural networks. International Journal of Recent Research and Review. 5: 1-6.
- Díaz-González, L.; Hidalgo-Dávila, C.A.; Santoyo, E.; Hermsillo-Valadez, J. 2013. Evaluación de técnicas de entrenamiento de redes neuronales para estudios geo termométricos de sistemas geotérmicos. Revista Mexicana de Ingeniería Química 12(1): 105-120.
- Espino, C.; Martínez, X. 2017. Análisis predictivo: Técnica y modelos utilizados y aplicaciones del mismo-herramientas. Open Source que permiten su uso. Universitat Oberta de Catalunya.
- Favaro, L.; Briefer, E.; McElligott, A.G. 2014. Artificial Neural Network approach for revealing individuality, group membership and age information in goat kid contact calls. Acta Acustica united with Acustica 100(4): 782-789.
- Felipe, V.P.; Silva, M.A.; Valente, B.D.; Rosa, G.J. 2015. Using multiple regression, bayesian networks and artificial neural networks for prediction of total egg production in european quails based on earlier expressed phenotypes. Poultry Science (4): 772-800.
- Ferrero, M. 2014. Generación de un modelo mediante el uso de redes neuronales artificiales para la detección de mastitis en vacas lecheras del INTA, Estación Experimental Agropecuaria Rafaela. Universidad Católica de Santiago del Estero. XLIII Jornadas Argentina de Informática e Investigación Operativa.
- Galeano-Vasco, L.; Cerón-Muñoz, M. 2013. Modelación del crecimiento de pollitas Lohmann LSL con redes neuronales y modelos de regresión no lineal. Rev. MVZ Córdoba 18(3): 3861-3867.
- Gómez, L.F. 2014. Aplicación de Redes Neuronales Artificiales en la modelación de la deforestación asociada a nuevos proyectos de infraestructura vial en la región del Nordeste y Bajo Cauca del Departamento de Antioquia. Trabajo de grado para optar el título de Magister en Medio Ambiente y Desarrollo. Facultad de Minas, Universidad Nacional de Colombia, sede Medellín.
- Gómez-Urviola, J.; Celi-Mariategui, I.; Milan-Cendra, M.; Jordan-Vidal, J. 2016. La cabra criolla peruana, situación actual y perspectiva conservacionista.
- Gorgulu, O. 2012. Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. South African Journal of Animal Science 42(3): 280-287.
- Hulya, A.; Akilli, Asli. 2015. Investigation of Dairy Cattle Traits by Using Artificial Neural Networks and Cluster Analysis. Proceeding of the 7th International Conference on Information and communication. Greece 17-20 September.
- Instituto Nacional de Estadística e Informática (INEI) - Ministerio de Agricultura y Riego - Dirección General de Evaluación y Seguimiento de Políticas - SIEA. 2014. población de ganado caprino, según unidad agraria.
- Ivanović, S.; Pavlović, I.; Pisinov, B. 2016. The quality of goat meat and its impact on human health. Biotechnology in Animal Husbandry 32(2): 111-122.



- Mehri, M. 2013. A comparison of neural network models, fuzzy logic, and multiple linear regression for prediction of hatchability. *Poultry science* 92(4): 1138–1142.
- Mehri, M. 2014. Optimization of response surface and neural network models in conjugation with desirability function for estimation of nutritional needs of methionine, lysine, and threonine in broiler chickens. *Poultry Science* 93(7): 1862–1867.
- Mercado, D.; Pedraza, L.; Martínez, E. 2015. Comparison of Neural Network applied to prediction of times Series 13(2): 88-95.
- Morales-Tamayo, Y.; Zamora-Hernández, Y.; Vásquez-Carrera, P.; Porras-Vasconez, M.; Barzaga-Quesada, J.; López-Bustamante, R. 2018. Comparación entre Redes Neuronales Artificiales y Regresión múltiple para la predicción de la rugosidad superficial en el tomeado en seco. *Revista Ciencia y Tecnología*. N° 19. Universidad Politécnica Salesiana, Ecuador.
- Pascual, I.; Ortiz, A.; Ramírez de la Rivera, J.; Figueredo, A. 2017. Predicción del rendimiento y la calidad de tres gramíneas en el valle del Cauto. *Revista Cubana de Ciencias Informáticas* 11(3): 144-158.
- Pascual, I.; Ramírez, J.; Ortiz, A. 2016. Métodos de Inteligencia Artificial para la predicción del rendimiento y calidad de gramíneas. *REDVET* 17(12): 1-9.
- Quintín, M.; De Paz, Y. 2007. Aplicación de las redes neuronales artificiales a la regresión. Edit. La Muralla, S.A.
- Salawu, E.; Abdulraheem, M.; Shoyombo, A.; Adepeju, A.; Davies, S.; Akinsola, O.; Nwagu, B. 2014. Using artificial neural network to predict body weights of rabbits. *Open Journal of Animal Sciences* 4: 182-186.
- Sánchez, R.; Fernández, M.; Nolasco, S. 2015. Aplicación de redes neuronales artificiales en la predicción y modelado de la cinética de extracción de aceite de canola. Universidad Nacional del Centro de Buenos Aires - Asociación Argentina de Ingenieros Químicos.
- Sarria, J.A.; Ruiz, F.A.; Mena, Y.; Castel, J.M. 2014. Caracterización y propuestas de mejora de los sistemas de producción caprina de la costa central de Perú. *Rev. Mex. de Ciencias Pecuarias* 5(4): 409.
- Sheta, A.F.; Elsir S.M.; Ahmed, S.E.M.; Faris, H. 2015. Redes neuronales y máquinas de vectores de soporte para índice de mercado de valores de predicción. *International Journal of Advanced Research in Artificial Intelligence*. IJARAI 4(7).
- Vargas, J.E.; Zaragoza, L.; Delgado, J.V.; Rodríguez, G. 2017. Biodiversidad Caprina Iberoamericana. Ediciones Universidad Cooperativa de Colombia.
- Vásquez, V.; Arteaga, P.; Chaname, K.; Esquivel, A. 2013. Modelamiento matemático y por redes neuronales artificiales del crecimiento de *Spirulina* sp. en fotobioreactor con fuente de luz fluorescente e iluminación en estado sólido. *Scientia Agropecuaria* 4(3): 199-209.
- Vega, C.A.; Altamirano, M.; García, R.; Hernández, M.; Vite, C. 2017. Clasificador de carne de res usando redes neuronales. *Revista Digital RIISDS* 1(3): 49–59.

