



UNIVERSIDAD NACIONAL DE COLOMBIA

ESTIMACIÓN DE LAS EMISIONES DE AMONIACO EN GALPONES AVÍCOLAS,  
USANDO UN MODELO NEURONAL ARTIFICIAL

John Edison Bastidas Marín

Universidad Nacional de Colombia

Ingeniería y administración, Departamento de Ingeniería Ambiental

Palmira, Colombia

2020

ESTIMACIÓN DE LAS EMISIONES DE AMONIACO EN GALPONES AVÍCOLAS,  
USANDO UN MODELO NEURONAL ARTIFICIAL

John Edison Bastidas Marín

Tesis de Maestría, requisito parcial para optar al título de Magister en Ingeniería  
Ambiental

Director:

Dr. Luis Octavio González Salcedo

Codirector:

Mag. Ricardo Malagón Manrique

Línea de investigación de Monitoreo, modelación y gestión de recursos naturales

Universidad Nacional de Colombia

Ingeniería y administración, Departamento de Ingeniería Ambiental

Palmira, Colombia

2020

## **Agradecimientos**

*A Dios primeramente por levantarme en los momentos de flaqueza y permitirme persistir. A mi familia por su apoyo incondicional. A mi amigo y compañero, el profe Iván Fajardo por su ayuda y disposición, al profesor Luis Octavio por su consejo y orientación y al profesor Ricardo por sus sugerencias. Agradezco de igual manera a todas aquellas personas que de alguna manera han contribuido en el desarrollo y culminación del presente trabajo de investigación.*

## Declaración de obra original

Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.



---

Nombre : John Edison Bastidas Marín

Fecha: 07/10/2021

# Resumen

## Estimación de las emisiones de amoníaco en galpones avícolas, usando un modelo neuronal artificial

En los últimos años la industria avícola ha experimentado tanto a nivel mundial como en Colombia un importante crecimiento, lo cual unido a la exigencia de la normatividad ambiental vigente conlleva al control y disminución de las emisiones de amoníaco dentro de los galpones. El amoníaco proveniente de las deyecciones puede afectar a las aves y a las personas generando problemas de salud y pérdidas económicas en dicha industria. La cantidad de la emisión de amoníaco depende de las condiciones ambientales y de diversas variables de diseño y operación presentes en las actividades avícolas. En este trabajo, para la predicción de la emisión de amoníaco liberadas al aire dentro de galpones para aves de postura y engorde, se elaboraron redes neuronales artificiales multicapa feedforward – backpropagation, evaluando su desempeño a partir del coeficiente de correlación lineal R. Posteriormente, se usó la red neuronal seleccionada y entrenada para analizar la influencia de diferentes variables en la generación de emisiones de NH<sub>3</sub>. Se analizaron las variables ambientales; temperatura, humedad relativa, pH, flujo de aire. Las variables de operación; densidad, tiempo de acumulación del estiércol, consumo de proteína, raza de las aves y factores de diseño como el tipo de ventilación, tipo de galpón y tipo de cama, se sugirieron algunas condiciones de operación para reducir las emisiones de NH<sub>3</sub>. Los resultados de correlación entre las emisiones reales y estimadas por la red neuronal (R=0.99), muestran que la herramienta computacional desarrollada es confiable en la predicción de las emisiones y abre una agenda futura para la optimización y diseño de ambientes controlados mediante aprendizaje de máquinas basadas en redes neuronales.

**Palabras clave:** deyecciones; amoníaco; condiciones ambientales; industria avícola; inteligencia artificial; redes neuronales artificiales.

# Abstract

## Estimation of ammonia emissions in poultry sheds, using an artificial neuronal model

In the last years, the poultry industry has experienced significant growth both worldwide and in Colombia, which together with the requirement of current environmental regulations leads to the control and reduction of ammonia emissions within the sheds. Ammonia from manure can affect birds and people, causing health problems and economic losses in this industry. The amount of ammonia emission depends on environmental conditions and various design and operating variables present in poultry activities. In this work, for the prediction of the ammonia emission released into the air within sheds for laying and fattening birds, feedforward - backpropagation multilayer artificial neural networks were elaborated, evaluating their performance from the linear correlation coefficient R. used the selected and trained neural network to analyze the influence of different variables on the generation of NH<sub>3</sub> emissions. The environmental variables were analyzed; temperature, relative humidity, pH, air flow. The operation variables; Density, manure accumulation time, protein consumption, breed of birds and design factors such as type of ventilation, type of house and type of litter, some operating conditions were suggested to reduce NH<sub>3</sub> emissions. The correlation results between the real and estimated emissions by the neural network (R = 0.99), show that the computational tool developed is reliable in the prediction

of emissions and opens a future agenda for the optimization and design of controlled environments through learning of machines based on neural networks.

**Keywords:** *droppings; ammonia; environmental conditions; poultry industry; artificial intelligence; artificial neural network.*

# Contenido

<b>1. Planteamiento del problema .....</b>	<b>13</b>
1.1. Antecedentes .....	13
1.2. Justificación.....	20
1.3. Objetivos .....	22
1.3.1. Objetivo general .....	22
1.3.2. Objetivos específicos .....	22
<b>2. Marco teórico .....</b>	<b>22</b>
2.1. Marco conceptual .....	22
2.1.1. Producción avícola y contaminación .....	22
2.1.2. Amoniacó .....	28
2.1.3. Modelos neuronales artificiales .....	42
2.2. Marco normativo.....	61
2.3. Marco Referencial .....	64
<b>3. Materiales y métodos .....</b>	<b>69</b>
3.1. Construcción de una base de datos .....	69
3.2. Análisis estadístico.....	70
3.3. Diseño de una Red Neuronal Artificial para la estimación de las concentraciones de Amoniacó .....	71
3.4. Variables de entrada o entrenamiento .....	72
3.5. Arquitectura de la red neuronal .....	74
3.6. Entrenamiento de la red neuronal .....	74
<b>4. Resultados y discusión .....</b>	<b>75</b>
4.1. Resultados de la construcción de la red neuronal.....	75
4.2. Predicción de las emisiones de NH <sub>3</sub> e influencia de las variables de estudio ....	82
4.2.1. Edad de las aves y emisiones de NH <sub>3</sub> .....	82
4.2.2. Densidad animal y emisiones de NH <sub>3</sub> .....	84
4.2.3. Temperatura ambiental y emisiones de NH <sub>3</sub> .....	86
4.2.4. Humedad relativa y emisiones de NH <sub>3</sub> .....	88
4.2.5. Ventilación y Emisiones de NH <sub>3</sub> .....	90
4.2.6. pH y emisiones de NH <sub>3</sub> .....	94
4.2.7. Ingesta de proteína y Emisión de NH <sub>3</sub> .....	97

4.2.8. Acumulación de estiércol en el tiempo y emisión de NH <sub>3</sub> .....	99
<b>5. Conclusiones y recomendaciones.....</b>	<b>102</b>
<b>6. Referencias.....</b>	<b>103</b>

# Lista de figuras

Figura 1. Etapas de degradación aeróbica del ácido úrico en amoníaco. Fuente: Campos y col (2017) ....	32
<b>Figura 2.</b> Esquema de procesos relacionado con las emisiones de amoníaco en una cama de pollos. <b>Fuente:</b> Liu et al, 2007.....	33
Figura 3. Elementos básicos de una neurona biológica. Fuente: Tablada (2009).....	43
Figura 4. Elementos básicos de una neurona artificial. Fuente: Tablada (2009). ....	44
Figura 5. Comparativo estructural de una neurona biológica vs neurona artificial. Fuente: Elaboración propia. ....	45
Figura 6. Esquema general de una red neural. Fuente: Medina & Ore (2016). ....	47
Figura 7. Elementos básicos que integran una red neuronal artificial. Fuente: Serrano (2010). ....	49
Figura 8. Elementos de una red Monocapa. Fuente: Serrano (2010). ....	50
Figura 9. Estructura de una red Multicapa. Fuente: Serrano (2010). ....	51
Figura 10. Esquema del modelo perceptrón simple. Fuente: Tino y Sperduti (2015). ....	52
Figura 11. Arquitectura de las redes neuronales seleccionadas para el estudio. ....	78
Figura 12. Resultados de desempeño para la red neuronal artificial RNA-1 entrenada para estimar las emisiones de NH <sub>3</sub> . Fuente: Elaboración propia. ....	79
Figura 13. Resultados de desempeño para la red neuronal artificial RNA-2 entrenada para estimar las emisiones de NH <sub>3</sub> . Fuente: Elaboración propia. ....	80
Figura 14. Comportamiento en la fase de validación computacional de las Redes Neuronales Artificiales. Fuente: Elaboración propia. ....	81
Figura 19. Efecto de la Flujo de aire al interior del galpón en las concentraciones de NH <sub>3</sub> (gNH <sub>3</sub> /m <sup>3</sup> ) en el interior del galpón para tres tipos de producción diferentes. Fuente: Elaboración propia. ....	91
Figura 20. Efecto de la Flujo de aire al interior del galpón en las emisiones de NH <sub>3</sub> para tres tipos de producción diferentes. ....	91
Figura 21. Efecto del tipo de ventilación en las emisiones de NH <sub>3</sub> en gallinas ponedoras Hy-Line en un sistema de producción en piso. Fuente: Elaboración propia. ....	93
Figura 22. Efecto del pH de la cama aviar en las emisiones de NH <sub>3</sub> para tipos de lechos diferentes. Fuente: Elaboración propia. ....	95
Figura 23. Influencia de la ingesta de proteína en las emisiones de NH <sub>3</sub> para cuatro razas diferentes. Fuente: Elaboración propia. ....	98
Figura 24. Efecto de la acumulación del estiércol en las emisiones de NH <sub>3</sub> para tres tipos de lechos diferentes. Fuente: Elaboración propia.....	100

# Lista de tablas

Tabla 1. Efectos del amoniaco en la salud de humanos y animales.....	16
Tabla 2. Principales emisiones de gases asociados a la avicultura.....	26
Tabla 3. Efectos fisiológicos del NH <sub>3</sub> en las aves a diferentes concentraciones.....	28
Tabla 4. Respuesta a diferentes concentraciones de NH <sub>3</sub> atmosféricas de pollos de engorde.....	29
Tabla 5. Cuantificación de pérdidas monetarias a concentraciones de amoniaco superiores a 75 ppm...	30
Tabla 6. Principales Algoritmos utilizados en entrenamiento de Redes Neuronales. ....	54
Tabla 7. Algoritmos más importantes empleados en MATLAB. Fuente: <i>Fuente:</i> .....	55
Tabla 8. Niveles permisibles de calidad del aire o de emisión para sustancias de olores ofensivos .....	62
Tabla 9. Insumos utilizados para la construcción de la base de datos.....	69
Tabla 10. Variables incorporadas en la base de datos para el entrenamiento de la Red Neuronal Artificial. .....	72
Tabla 11. Variables evaluadas en cada red neuronal.....	76
Tabla 12. Coeficientes de correlación lineal de diferentes arquitecturas de RN_1 usando diferentes algoritmos de entrenamiento. Fuente: Elaboración propia.....	76
Tabla 13. Coeficientes de correlación lineal de diferentes arquitecturas usando levenberg-marquardt. Fuente: Elaboración propia .....	77

## Introducción

La Carne de pollo es una de las fuentes de proteína más importantes del mundo, siendo la industria que mayor crecimiento presentó en el 2019, con una producción de 133.6 millones de toneladas, aumentando el 4,7% respecto al año 2018 (FAO, 2020). Para el año 2019 se produjeron 12,53 millones de toneladas de pollo en Latinoamérica con un aumento del 6.61% en comparación con el 2018 y con 495 millones de aves en postura, logrando un incremento del 5.17% respecto al año anterior (Ruiz, 2020).

Colombia registró un crecimiento general de 2% en la industria avícola para el año 2019, alcanzando un volumen de 2.556.123 toneladas, con un crecimiento de 3.9% en el renglón pollo y un -1.5% en el renglón huevo, presentándose un consumo per cápita de 291 huevos y 34,3 kg de pollo frente a los 12,5 kilos anuales de hace 19 años, lo que refleja un crecimiento del 250% en estos años (Fenavi, 2020).

El crecimiento en la producción avícola genera un aumento en las emisiones de gases, efluentes, y residuos sólidos contaminantes, siendo un reto ambiental en los próximos años y una necesidad de mejora dentro de las empresas (Bohórquez, 2014., Andrade & Arilio, 2017). Las emisiones de amoníaco gaseoso ( $\text{NH}_3$ ), así como gases de efecto invernadero ( $\text{CO}_2$ , y  $\text{N}_2\text{O}$ ), son motivo de preocupación en la industria avícola por los impactos que genera en el medio ambiente (Morazán, 2014). El  $\text{NH}_3$  objeto de estudio en este trabajo puede generar acidificación del suelo, del agua y el aumento en la acumulación de nitrógeno en los ecosistemas y galpones provocando efectos negativos en la salud de las aves y las personas (Morazán, 2014). En Colombia, dados estos

hechos, existe una normatividad para regular este contaminante en las empresas avícolas considerando que la concentración de  $\text{NH}_3$  en el ambiente no debe exceder las  $91 \mu\text{g}/\text{m}^3$  (0.13 ppm) cuando se tiene periodo de exposición de 24 horas y  $1400 \mu\text{g}/\text{m}^3$  (2.01 ppm) en un periodo de exposición de 1 hora (MinAmbiente, 2013).

El amoníaco se genera por la descomposición microbiana de los compuestos nitrogenados orgánicos del estiércol y orina. Las excreciones de las aves de engorde y de postura son ricas en ácido úrico, siendo transformadas fácilmente en urea a través de un proceso aeróbico, seguidamente se volatiliza el  $\text{NH}_3$  y el  $\text{CO}_2$  por la acción fermentativa de las ureasas de origen bacteriano en su mayoría (90%), aunque también fúngicas y protozoarias (Aarnink y Verstegen, 2007).

Aunque en la actualidad se utilizan métodos físicos, químicos y biológicos, para reducir la producción de  $\text{NH}_3$  en las camas avícolas, muchos son corrosivos o contaminantes y los métodos menos agresivos pueden tener menor efectividad además de que se incurre en un gasto adicional (Pezzuolo et al, 2019).

Resulta importante entonces controlar algunas variables ambientales y de operación para disminuir las emisiones de este gas contaminante ya que la cantidad de amoníaco liberada de la cama avícola depende de factores como la temperatura, el pH, la ventilación, la formulación del alimento y el manejo del estiércol (Shepherd et al, 2015).

En este trabajo se construyó y entrenó una red neuronal artificial multicapa que permitió predecir las emisiones de  $\text{NH}_3$  para diferentes condiciones ambientales y de diseño, con el fin de obtener una herramienta que permitiera optimizar y reducir las emisiones de  $\text{NH}_3$  además de facilitar el diseño y construcción de los galpones avícolas para sistemas de

postura y ceba. Los comportamientos soportados por la literatura y los resultados de correlación lineal R entre los valores estimados y reales de las emisiones de NH<sub>3</sub> de salida demostraron la confiabilidad en la aplicación como herramienta de predicción.

## **1. Planteamiento del problema**

### **1.1. Antecedentes**

Las emisiones, los gases olorosos generan un impacto ambiental que a menudo resulta en quejas a las autoridades y, por lo tanto, en regulaciones de la contaminación por olores. Las quejas, a su vez, surgen de las molestias, los efectos adversos sobre la salud y bienestar humano y la depreciación de los precios de las propiedades (MinSalud, 2012).

La Resolución 1541 de 2013 del Ministerio de Ambiente establece directivas en Colombia para tratar las quejas, y establecer las normas de calidad del aire ambiente y la evaluación de emisiones de gases contaminantes y olores ofensivos. Entre los productos químicos regulados están el H<sub>2</sub>S, TRS y NH<sub>3</sub> (sulfuro de hidrógeno, azufre total reducido y amoníaco) (MinAmbiente, 2013). En general los niveles de amoníaco son regulados en el ambiente y no pueden exceder los 1400 µg/m<sup>3</sup> (2.01 ppm) en un periodo de exposición de 1 hora (MinAmbiente, 2013). No obstante, los estudios en Colombia sobre el amoníaco son escasos y no existe un monitoreo de las concentraciones emitidas, ya que no es considerado como un gas de efecto invernadero.

En Colombia no hay una normatividad clara acerca de la concentración máxima permitida dentro de los galpones avícolas, lineamientos europeos como el decreto Real 692/2010, de 20 de mayo, establecen las normas mínimas para la protección de los pollos destinados a la producción de carne y hablan de una concentración de amoníaco ( $\text{NH}_3$ ) no sea superior a 20 ppm medidas al nivel de las cabezas de los pollos (Boe, 2010).

La última normativa es pertinente a las condiciones normalmente encontradas en los galpones, ya que estudios al respecto afirman que concentraciones de amoníaco de 50 a 100 ppm en las instalaciones pueden generar síntomas respiratorios e incluso sólo con 25 ppm los parámetros productivos empiezan a verse afectados (Cedeño y Vergara 2017).

En el sector avícola debido a diferentes condiciones y a la mala disposición de estiércol y purines se generan emisiones de gases contaminantes. Estas emisiones suelen estar compuestas por una mezcla de gases (amoníaco  $\text{NH}_3$  y sulfuro de hidrógeno  $\text{H}_2\text{S}$ ), compuestos orgánicos volátiles y partículas (Herrera et al, 2013).

El amoníaco es uno de los gases de mayor interés ya que es un tóxico que genera un olor desagradable (Jarret et al, 2011) irritante con olor característico (picante), incoloro y más liviano que el aire (Herrera et al, 2013) que resulta agresivo frente a las mucosas celulares afectando la salud de los trabajadores, vecinos y animales de la explotación. Además, se ha demostrado que puede existir una correlación entre factores de contaminación como el amoníaco y el olor (Nimmermark y Gustafsson, 2005). En las personas después de 20ppm se producen irritaciones nasales, después de 50 ppm produce cefaleas y puede ser letal para concentraciones mayores a 500 ppm (Herrera et al, 2013).

Algunos autores han realizado propuestas para la aplicación de redes neuronales para la estimación de emisiones de amoníaco en producciones avícolas. Rege y Tock (1996) desarrollaron un método novedoso para estimar las tasas de emisión de fuentes puntuales utilizando redes neuronales. La red neuronal se entrenó específicamente para los gases  $H_2S$  y  $NH_3$  utilizando datos obtenidos experimentalmente. La red neuronal "aprendió" con éxito la cantidad limitada de datos adquiridos en otras condiciones de estabilidad. Se validó el rendimiento de la red neuronal. Este concepto muestra el enorme potencial de proporcionar estimaciones fiables de la tasa de emisión de contaminantes basadas en datos meteorológicos / de emisión medidos. La simplicidad y confiabilidad de tal técnica se pueden combinar para estimar las tasas de emisión de fuentes puntuales. Para los datos en el conjunto de prueba, se encontró que las predicciones de la mayoría de las tasas de emisión estaban dentro del 10% de los valores experimentales.

Raimundo y Narayanaswamy (2001) determinaron simultáneamente la humedad relativa y la concentración de  $NH_3$  mediante un sensor químico óptico calibrado mediante una RNA. Para el tratamiento de los datos se empleó un ANN feedforward, con un algoritmo de entrenamiento de retropropagación de errores. Una vez que la RNA fue entrenada, se obtuvo un coeficiente de correlación  $R=0.92$  para la concentración de  $NH_3$  y  $R=0.97$  para la humedad relativa, obteniéndose una calibración satisfactoria y una precisión importante en las mediciones.

Xiao (2011) utilizó redes neuronales para predecir la liberación de amonio en la fermentación aeróbica. Los mejores parámetros de proceso obtenidos por el modelo de red neuronal artificial fueron: humedad 60%, C / N 37: 1, pH 7 y temperatura 31.3 °C. La

cantidad total de amoníaco fue 1149.3 mg / kg. A través del análisis pudimos ver que el valor de pronóstico y el valor medido real del modelo de red neuronal de retropropagación no tenían gran diferencia, el error relativo máximo fue 6.58%, indicó que el modelo tenía una mayor precisión de pronóstico.

Las redes neuronales han demostrado ser una herramienta útil para la estimación de gases contaminantes como el NH<sub>3</sub>.

**Tabla 1. Efectos del amoniaco en la salud de humanos y animales**

Concentración (ppm)	Humanos	Animales
5	Algunas personas pueden detectar la presencia de amoníaco por el olor.	
10	Algunas personas pueden detectar la presencia de amoníaco por el olor.	
20	Entorno ambiental nocivo para la salud	Malestar inicial
20-25		Cantidad máxima tolerable para aves con exposición a largo plazo.
30	Problemas del sistema respiratorio, que incluyen tos, secreción, presencia de flema e incluso retención de orina.	
35-40		Cantidad máxima tolerable para aves con exposición a corto plazo.
50	Irritación ocular aguda	Irritación ocular aguda
80		Menor consumo de alimento y retraso del crecimiento.
100	Se producen quemaduras en los ojos, ceguera temporal e irritación de la piel.	Drastica reducción de la tasa respiratoria, consumo de alimento y crecimiento.
500	Ataque violento de tos, irritación severa en los pulmones, edema pulmonar, puede conducir a la muerte.	Dosis letal.

**Tabla 1.** Citado por Campos et al, 2017

El  $\text{NH}_3$  es uno de los principales causantes de la baja producción de las aves, pues en altas concentraciones afecta la salud de las aves e impide su desarrollo, afectando la producción y rentabilidad del avicultor (Miles, 2006). En el galpón, las aves absorben el amoníaco por la parte superior de las vías respiratorias, a través de las membranas mucosas, la presencia de este gas altera los mecanismos de defensa de los animales volviéndolos susceptibles a infecciones.

Cuando las concentraciones se elevan de 50 a 100 ppm producen queratoconjuntivitis (ceguera), daño ocular, sensibilidad a la luz, úlceras en conjuntiva, problemas pulmonares, edemas, hemorragias, menor consumo de alimento, ascitis y en niveles muy altos llega a ser fatal, además la concentración de amoníaco interfiere con la ganancia de peso, la conversión de alimento y la reproducción de las aves (Miles et al, 2004). A una concentración de 25 ppm de  $\text{NH}_3$  en el galpón se presenta una reducción del peso entre 6 y 9%. Para 50 y 75 ppm se presenta una alta mortalidad que puede llegar hasta el 13,9% (Cedeño y Vergara 2017).

El amoníaco también presenta una importante relación con los gases de efecto invernadero (GEI), concretamente con la emisión de  $\text{N}_2\text{O}$  por ser uno de los precursores necesarios, y cuyas concentraciones en el purín están directamente relacionadas con los niveles de emisión y/o síntesis de  $\text{N}_2\text{O}$  (IPCC, 2013). La toxicidad del dióxido nítrico se debe a su alta capacidad radiactiva (265 veces la del  $\text{CO}_2$ ), siendo un gas de importante efecto invernadero (IPCC, 2013).

El amoníaco se genera de las excretas que poseen un contenido considerable de ácido úrico, que en la mayoría de las condiciones se transforma en urea con facilidad (Herrera

et al, 2013). Pero ciertas condiciones ambientales favorecen la volatilización de este ya que la cantidad de amoníaco que se emite realmente a la atmósfera depende de múltiples variables climáticas como lo son la temperatura del aire, la precipitación y velocidad y flujo del viento (Li, et al 2012).

Diferentes estudios han demostrado poca eficiencia del control de calidad de aire en galpones avícolas especialmente en la fase inicial de producción, constatando que se requieren realizar mayores evaluaciones en configuraciones y condiciones típicas de producciones avícolas de países tropicales y subtropicales con el fin de realizar propuestas de mejoramiento de estas instalaciones (Cordeiro et al, 2010; Campos et al, 2017).

La importancia del control de las variables ambientales radica en que es posible manipular los factores ambientales con el fin de generar condiciones desfavorables en la reacción química que genera el amoníaco gaseoso durante la degradación de los residuos orgánicos, así como en la volatilización de éste gas. Logrando generar menores pérdidas de  $\text{NH}_3$  durante el proceso productivo y a su vez menor generación de  $\text{N}_2\text{O}$ . (Campos et al, 2017).

Por lo anterior es necesario conocer las condiciones ambientales óptimas y de manejo para las camas en las producciones avícolas, con el fin de generar ambientes controlados que eviten al máximo la volatilización de amoníaco se hace indispensable el uso de una herramienta que realice predicciones precisas. Debido a la complejidad de las interacciones entre un número considerable de variables es necesario la utilización de un método diferente a los numéricos que permitan ahorrar esfuerzo y tiempo aprovechando el recurso computacional.

El aprendizaje de máquinas es idóneo para resolver problemas como el presentado en este estudio, por ser una rama de la Inteligencia artificial que permite, a partir de métodos programáticos adquirir conocimiento como en el caso de predicciones, planificación, diagnósticos y reconocimiento de patrones cambios en ellos, interpretándolos como mejoras (Russell, 2019). Esto se logra porque el aprendizaje de máquinas toma la información del entorno (datos de entrenamiento) y parte de éstas para emitir un juicio de manera que se cuente con una información para actuar en el futuro (Russell, 2019).

Dentro de los tipos de aprendizaje de máquinas se encuentra la Red Neuronal de Perceptrón Multicapa, un modelo matemático útil a la hora de aproximar o interpolar relaciones no lineales entre datos de entrada y salida siendo entre las redes neuronales una de las arquitecturas más utilizadas en la resolución de problemas, fundamentalmente, por su capacidad como aproximador universal, así como a su fácil uso y aplicabilidad (Pérez y Cadena, 2005).

Para que el aprendizaje sea efectivo, es necesario estructurar un modelo que se adapte al tipo de problema a resolver y que se ajuste al tipo de información a aprender (Datos de entrenamiento), el tipo de conocimiento que será aprendido y como éste será utilizado en la ejecución del programa (Función objetivo) además de definir cuál es el modelo algorítmico que se adapta a las características particulares que se desea aprender (Algoritmo de aprendizaje).

Se pueden encontrar una serie de dificultades relacionados con el aprendizaje de la red, por ejemplo, si se entrena una red neuronal con datos ambientales de una explotación avícola en particular para la estimación de  $\text{NH}_3$ , el modelo estaría muy limitado a las condiciones de dicha región geográfica, y un trabajo de campo en diferentes tipos de

instalaciones avícolas y en diferentes ubicaciones geo climáticas involucraría costos elevados y gran cantidad de tiempo, por lo que se decidió realizar una base de datos con estudios de la literatura que contuvieran condiciones variadas.

El tipo de algoritmo de aprendizaje y función objetivo también van a determinar el buen funcionamiento y precisión de la red neuronal. Por lo anterior, el objetivo del trabajo es construir validar una red neuronal que prediga las emisiones de NH<sub>3</sub> para diferentes condiciones ambientales y de diseño que se presenten en galpones avícolas con el fin de facilitar el control de las acciones de manejo de la unidad de producción avícola, que permitan el control adecuado del origen de dichos gases, de manera que, se mejoren los índices productivos por la disminución de las emisiones y su efecto sobre la salud y el bienestar de las aves.

## **1.2. Justificación**

En Colombia la industria avícola es un sector de gran crecimiento en los últimos años, registrando un aumento general del 2% en la producción avícola para el año 2019, y un incremento del 250% en los últimos 20 años (Fenavi, 2020).

Según el registro de granjas Orealizado por la Federación Nacional de Avicultores (FENAVI), en Colombia se encuentran distribuidas en más de 360 municipios en todo el país alrededor de 5.627 granjas de producción avícola , con un número de 842 millones de aves de engorde y 44.6 millones de aves de postura en 2019 que generaron 7.24 millones de toneladas de poilinaza y 1.5 millones de toneladas de gallinaza

respectivamente con un aporte por parte de las excretas de 114.250 toneladas de nitrógeno y 22850 de nitrógeno amoniacal aproximadamente (Dane, 2019; Fenavi, 2020).

Teniendo en cuenta esto, es indispensable aclarar que el control de amoniaco es vital para una producción eficiente del producto final y para evitar impactar de manera negativa al ambiente. La calidad del aire es indispensable para el adecuado desarrollo de las aves, en especial en el transcurso de 14 a 21 días de vida del animal, siendo las edades más críticas y susceptibles al daño del amoniaco a niveles por encima de 25 ppm de  $\text{NH}_3$  (Merchán y Quezada, 2013). Lo anterior se debe a que las aves jóvenes son más susceptibles a las reacciones e infecciones respiratorias graves ya que sus defensas son menores pues su sistema inmunitario y fisiológico aún están en desarrollo, tanto anatómica como funcionalmente (Albino et al, 2014).

Es necesario implementar prácticas de manejo y operación en los galpones, consiguiendo reducir costos por mal diseño en instalación de sistemas de ventilación y manejo de cama, evitando la acumulación de amoniaco en los galpones, de igual forma disminuyendo perdidas por daños oculares, pulmonares, ascitis y muerte (Merchán y Quezada, 2013). Asimismo, incrementar el consumo de alimento y al mejorar el rendimiento consiguiendo a la vez el control de olores, beneficiando a la comunidad aledaña evitando quejas y daños en la salud. Según Velasco y col (2016) la falta del control del  $\text{NH}_3$  en los galpones genera pérdidas monetarias de alrededor del 10% de la producción.

## **1.3. Objetivos**

### **1.3.1. Objetivo general**

Estimar las emisiones de amoniaco en galpones avícolas con diferentes condiciones climáticas y de diseño, usando un modelo neuronal artificial.

### **1.3.2. Objetivos específicos**

1. Construir una red neuronal apropiada y entrenada para modelar y estimar las emisiones de amoniaco liberadas al ambiente.
2. Analizar la influencia que algunos parámetros ambientales y de diseño presentes en una unidad avícola puedan tener sobre la emisión de amoniaco ( $\text{NH}_3$ ).
2. Utilizar los resultados de las predicciones de la red para realizar consideraciones y sugerencias que permitan mitigar las emisiones de  $\text{NH}_3$ .

## **2. Marco teórico**

### **2.1. Marco conceptual**

#### **2.1.1. Producción avícola y contaminación**

##### **2.1.1.1. Contaminación de los suelos**

La producción avícola genera grandes desperdicios de contenido orgánico causantes de contaminación de los suelos y aguas junto con la proliferación de microorganismos patógenos, olores, altas concentraciones de gases que pueden afectar el ecosistema (Pareja, 2005).

De acuerdo con la Organización de las Naciones Unidas para la Alimentación y la Agricultura FAO (2020) la contaminación en los suelos se puede derivar del proceso de reutilización agrícola de la materia fecal como abonos para cultivos, cuando éstos superan la cantidad del cultivo receptor. Un incorrecto almacenamiento del estiércol ayudaría a la emisión de gases contaminantes y a la proliferación de elementos microbianos que puedan contaminar los suelos, por ende, se debe realizar un correcto almacenamiento y posteriormente una reutilización del estiércol en abono soportado por el análisis de la capacidad de los cultivos receptores para absorber los nutrientes del abono o de lo contrario se afectaría la composición de los suelos involucrados (Williams, 2013). La contaminación del suelo y el agua con nutrientes, patógenos y metales pesados generalmente es causada por un manejo deficiente del estiércol y ocurre donde se almacena el estiércol (Delgado et al, 2014).

El suelo también puede contaminarse con nutrientes, patógenos y metales pesados generalmente es causada por un manejo deficiente del estiércol y por la eliminación de aves muertas por lo que el ICA en su norma NTC 5167 exige espacios adecuados para la disposición de éstos residuos. El estiércol se recicla en tierras de cultivo pertenecientes a la granja de animales o se comercializa. Para dicho fin existe la NTC 5167 y la Resolución 150 de 2003 “Por la cual se adopta el Reglamento Técnico de Fertilizantes y Acondicionadores de Suelos para Colombia” que exigen una previa estabilización agronómica o fermentación de la gallinaza y pollinaza antes de ser usada como fertilizante. Un mal proceso de compostaje o mal manejo de la cama desechada puede provocar acidificación del suelo o que los patógenos del estiércol generen enfermedades transmitidas por los alimentos a las personas (Séraphin et al, 2016).

### 2.1.1.2. Contaminación hídrica

La optimización del agua es una preocupación para toda la industria avícola en reducción de costos y en minimizar el impacto ambiental de la producción. La utilización de este recurso hídrico se encuentra principalmente en dos fases de la etapa productiva; la fase de limpieza que involucra el lavado de los pisos y canales que contienen los residuos de excrementos de las aves (gallinaza y pollinaza) que puede arrojar contaminantes a los afluentes junto con los subproductos empleados en la producción avícola y la fase de sacrificio de las aves donde los residuos del agua empleada se contamina de sangre y de los químicos manipulados para la limpieza en esta etapa (Aranda, 2018).

La escorrentía de áreas con estiércol de pollo y desechos contaminan tanto el agua superficial como el agua subterránea, que son fuentes de agua potable. Las escorrentías junto con las aguas residuales de proceso pueden contener altos niveles de nitrógeno y fósforo que favorecen la eutrofización de los cuerpos de agua afectados (Maheshwari, 2013).

El nitrógeno del estiércol de pollo se convierte fácilmente en nitrato en las fuentes de agua para beber y facilita la proliferación de algas que a su vez facilita el crecimiento del microorganismo *Pfiesteria piscicida*, que enferma tanto a los animales como a los humanos cuando está presente en el agua potable (Seidavi et al, 2019). La eliminación inadecuada de los cadáveres de aves de corral puede contribuir a problemas de calidad del agua, especialmente en áreas propensas a inundaciones o donde hay un nivel freático poco profundo pero el problema medioambiental más importante derivado de las operaciones de los mataderos es la descarga de aguas residuales al medio ambiente (Maheshwari, 2013).

La necesidad de higiene y control de calidad en el procesamiento de carne da como resultado un alto uso de agua y, en consecuencia, altos niveles de generación de aguas residuales, con una alta demanda bioquímica y química de oxígeno (DBO y DQO, respectivamente) debido a la presencia de materiales orgánicos. tales como sangre, grasa, carne y excretas que a su vez pueden conducir a niveles reducidos de actividad o incluso a la muerte de la vida acuática. También pueden estar presentes en el agua residuos de productos químicos como el cloro, que se utiliza para el lavado y desinfección, así como varios patógenos, como Salmonella y Campylobacter (Seidavi et al, 2019). En este aspecto es necesario el uso de plantas de tratamiento de aguas residuales (PTAR) al verter los residuos del agua a los cauces y en la reutilización del agua tratada como medida de un plan de sostenibilidad, ello con el fin de reducir la huella del impacto ambiental y cumplir con la normatividad colombiana en manejo de vertimientos (Aranda, 2018).

### **2.1.1.3. Contaminación atmosférica**

Las grandes emisiones de gases de la producción avícola son ocasionadas por el metabolismo de las aves y por los patrones naturales de descomposición del estiércol en el suelo, las emisiones de gases y repercusiones de GEI (Gases de Efecto Invernadero) están inmersos en todas las etapas del proceso productivo de la industria. Sin embargo, el índice de las emisiones de gases en la producción varía de acuerdo con el tipo de instalaciones de producción, el área de ventilación, la temperatura del ambiente y el tipo de alimentación, entre otros (MinSalud, 2006).

La producción de animales en confinamiento y en especial la de pollos de crecimiento rápido es la causante de una importante emisión contaminantes atmosféricos. Los gases

contaminantes que más emite la avicultura son el metano (CH<sub>4</sub>), óxido nitroso (N<sub>2</sub>O), dióxido de carbono (CO<sub>2</sub>) y principalmente el amoniaco (NH<sub>3</sub>) (tabla 2) siendo el gas que más se encuentra en la industria en grandes proporciones y que más afectaciones genera en las crías y en los humanos (Campos et al, 2017).

**Tabla 2. Principales emisiones de gases asociados a la avicultura.**

<b>EMISIONES DE GASES AL AIRE</b>	<b>PUNTO DE PRODUCCIÓN</b>
Amoniaco	Alojamientos de animales, almacenamiento de estiércol y aplicación del estiércol en el campo.
Metano	Alojamientos animales, almacenamiento y tratamiento del estiércol.
Óxido nitroso	Almacenamiento y aplicación del estiércol.
Dióxido de carbono	Alojamientos animales, energía usada para iluminación, ventilación y transporte.
Olor	Alojamientos animales, almacenamiento y aplicación en campo.
Polvo	Preparación y almacenamiento del pienso, alojamientos animales, almacenamiento y aplicación de estiércol sólido

**Fuente:** MinSalud, 2006.

A nivel mundial, las emisiones de NH<sub>3</sub> de la agricultura animal, y específicamente del estiércol, se estimaron en 30 millones de toneladas métricas; que representa el 64% del NH<sub>3</sub> de las emisiones antropogénicas (Seidavi et al, 2019). El amoníaco reacciona con el dióxido de azufre atmosférico y el óxido nítrico en la atmósfera para formar PM 2.5, aerosoles que contienen sulfato de amonio o nitrato de amonio. Estos aerosoles reducen

la calidad del aire y la visibilidad (Wang et al, 2019). La mayor parte del  $\text{NH}_3$  se depositará en un radio de 1 km del sitio, es decir alrededor de la planta avícola, por lo tanto, las emisiones de  $\text{NH}_3$  pueden provocar la eutrofización de las vías fluviales y problemas de olores para los vecinos (Seidavi et al, 2019).

### **Dióxido de carbono**

El dióxido de carbono es el gas que más se asocia al efecto de cambio climático en el mundo, la razón de ello es debido a que este es el gas que más se emite en todos los sectores económicos y de mayor concentración en la atmosfera (Velasco et al, 2016). Aunque las emisiones de carbono de la industria avícola no afectan de forma directa la salud humana, si lo hacen de manera indirecta por medio del calentamiento global (Velasco et al, 2016).

### **Óxido nitroso**

El óxido nitroso ( $\text{N}_2\text{O}$ ) es considerado el tercer gas de efecto invernadero que más calentamiento produce y posee una capacidad de retención de calor 310 veces superior en comparación al  $\text{CO}_2$  y puede permanecer activo en la zona atmosférica hasta por 115 años (Steinfeld et al, 2009).

Este se origina de acuerdo con el proceso orgánico del suelo y del agua como consecuencias de la fase nitrificación y desnitrificación bajo condiciones anaeróbicas. En la producción avícola mediante el proceso de descomposición de la materia fecal de las aves y en los pisos de los galpones avícolas se pueden encontrar altas concentraciones de  $\text{N}_2\text{O}$  (Velasco et al, 2016), en este sentido las practicas avícolas conllevan a una fuente considerable de producción de este gas que tiene un importante efecto contaminante.

## 2.1.2. Amoniaco

El Amoniaco ( $\text{NH}_3$ ) es uno de los gases contaminantes más asociados e inherentes a toda producción avícola (Arrieta, 2013). El  $\text{NH}_3$  en grandes concentraciones genera un gran impacto medioambiental y graves afectaciones en la salud de los animales y de las personas involucradas en el proceso productivo y de las comunidades aledañas de manera directa e indirecta.

### 2.1.2.1. Efectos sobre la salud y la productividad

El amoniaco es un gas que produce irritación, con un olor picante característico, incoloro y más menos denso que el aire (0,77 g/L). La concentración en las explotaciones suele estar entre 5 y 20 ppm con un valor máximo permitido de 25 ppm. Concentraciones mayores producen irritaciones nasales y oculares y disminuyen la ingesta mermando las producciones, además puede favorecer las infecciones por virus y micoplasmas (tabla 3). Después de 5050 ppm produce cefaleas y puede ser letal desde los 5000 ppm (MinSalud, 2006).

**Tabla 3. Efectos fisiológicos del  $\text{NH}_3$  en las aves a diferentes concentraciones.**

Concentración (ppm)	Efectos
10-20	Bloqueo de cilios pulmonares por excesiva secreción mucosa, cuando existen periodos prolongados de exposición.
20-25	Aumento en la susceptibilidad del virus de Newcastle y aerosaculitis. Congestión, edemas y hemorragias pulmonares. Mayor suceptibilidad ante las enfermedades respiratorias debido a ciliostasis. Este es el máximo nivel tolerable para largos periodos de exposición.

30-40	Reducción de crecimiento y deficiente índice de conversión. Declinación y disminución de la eliminación de <i>E. coli</i> de los pulmones y sacos aéreos.
50-60	Reducción en el crecimiento (3 al 6%), bajo índice de conversión, presentan bajos efectos en la puesta, irritación ocular y lesiones en sistema respiratorio. Incremento de aerosaculitis en aves expuestas al virus de bronquitis infecciosa.
70-80	Efectos depresores en puesta, retraso de madurez sexual y reducción de consumo de alimento.
100	Drástica reducción de ritmo respiratorio, consumo de alimento y crecimiento, efectos indeterminados en calidad del huevo. En caso de larga exposición (2 meses), se produce reducción significativa en la puesta.
200	Reducción del 20-25% en el crecimiento, aparición de lesiones pulmonares graves, reducción en la ingesta de alimento y crecimiento, reducción de la puesta. Queroconjuntivitis, ulceración corneal y ceguera.

Adaptado de: Herrera et al, 2013.

Las patologías mencionadas anteriormente pueden disminuir la productividad, resultado de la pérdida de peso y el aumento en las tasas de mortalidad, en la tabla 4 se presenta un ejemplo de esto.

**Tabla 4. Respuesta a diferentes concentraciones de NH<sub>3</sub> atmosféricas de pollos de engorde.**

NH <sub>3</sub> (ppm)	Peso corporal	Decremento en peso		Mortalidad (%)
		(g)	(%)	
<b>4 semanas</b>				
0	1.421 <sup>a</sup>	-	-	-
25	1.395 <sup>a</sup>	26	2	-
50	1.1781 <sup>b</sup>	243	17	-
75	1.28 <sup>b</sup>	293	21	-

7 semanas				
0	3.211 <sup>a</sup>			5.8 <sup>ab</sup>
25	3.202 <sup>a</sup>	9	0.3	2.8 <sup>a</sup>
50	3.004 <sup>b</sup>	207	6.9	10.6 <sup>bc</sup>
75	2.820 <sup>b</sup>	291	9	13.9 <sup>c</sup>

**Adaptado de:** Miles et al., 2004. Las letras diferentes en la misma columna hacen referencia a que los valores son significativamente diferentes ( $P \leq 0.05$ ).

La disminución de la productividad producto de las patologías y la pérdida de las aves debido a la falta de control del  $\text{NH}_3$  generan importantes pérdidas económicas, ver Tabla 5.

**Tabla 5. Cuantificación de pérdidas monetarias a concentraciones de amoníaco superiores a 75 ppm.**



Aves de producción por nave	Ganancias con control adecuado de $\text{NH}_3$ (\$)	Ganancias sin control adecuado de $\text{NH}_3$ (\$)	Pérdida monetaria %
10000	154973241.31	140961865.94	9.04
20000	309806298.78	281923731.89	8.99
40000	619612597.55	563847463.77	9.0

**Fuente:** Velasco y col (2016). **Nota:** Precio promedio aproximado \$ 5920 por kilogramo de carne. Peso promedio en pie 2.6 kg por ave.

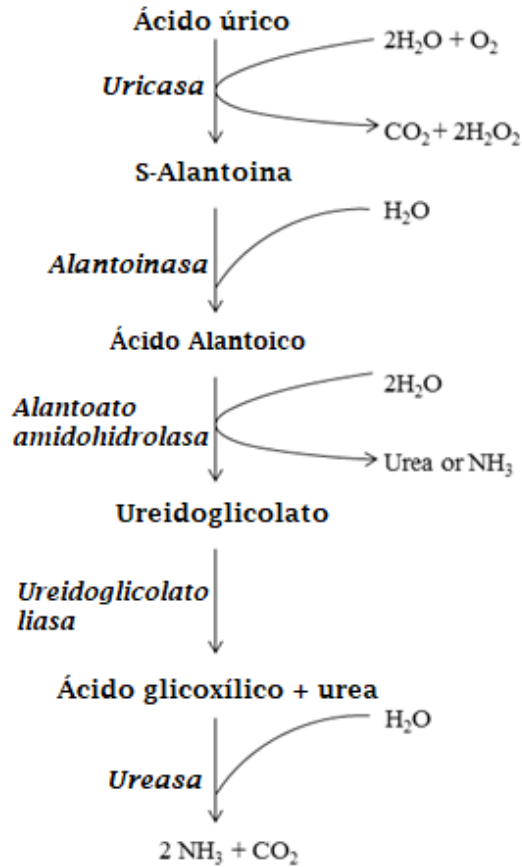
### 2.1.2.2. Reacción de formación del amoníaco

El amoníaco se genera de las excretas, que poseen un contenido considerable de ácido úrico, que en la mayoría de las condiciones se transforma en urea con facilidad. Después

la urea es hidrolizada debido a la acción de la enzima ureasa producida por algunos grupos de bacterias presentes en las excretas (Herrera et al, 2013), las reacciones se representan en las ecuaciones (1y 2).



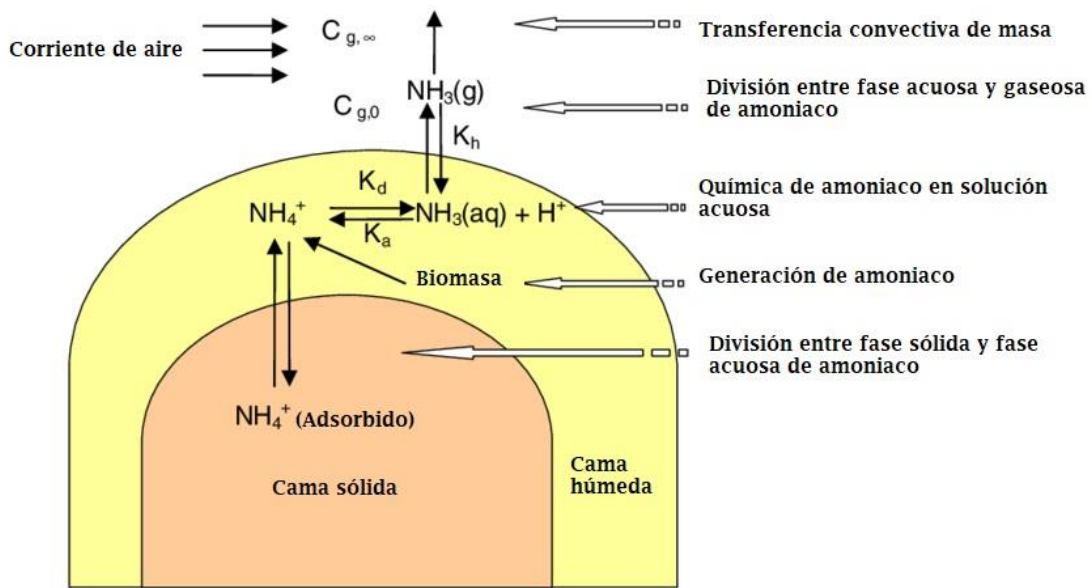
La degradación aeróbica del ácido úrico se realiza en cinco etapas enzimáticas (Figura 1). Primero, el ácido úrico ( $C_5H_4N_4O_3$ ), la forma de nitrógeno que predomina en las excretas, se convierte en alantoína ( $C_4H_6N_4O_3$ ) por la acción de la enzima uricasa. En un segundo paso, la alantoína es transformada en ácido alantoico por la alantoinasa. Posteriormente, el ácido alantoico se convierte en ureidoglicolato mediante la enzima alantoato amidohidrolasa, y luego el ureidoglicolato se transforma en glioxilato y urea mediante la ureidoglicolasa. El último paso consiste en la hidrólisis de urea ( $(NH_2)_2CO$ ) en amoníaco ( $NH_3$ ) y  $CO_2$  por la enzima ureasa (Koerkamp et al,1998).



**Figura 1.** Etapas de degradación aeróbica del ácido úrico en amoníaco. **Fuente:** Campos y col (2017)

### 2.1.2.3. Volatilización del amoníaco

El proceso de volatilización además de las reacciones químicas involucra procesos de transferencia de masa entre las fases sólida, líquida y gaseosa como se observa en la figura 2.



**Figura 2.** Esquema de procesos relacionado con las emisiones de amoníaco en una cama de pollos. **Fuente:** Liu et al, 2007.

En teoría la volatilización del amoníaco de las camas avícolas además de las reacciones químicas involucra procesos de transferencia de masa entre las fases sólida, líquida y gaseosa. El proceso involucra la conversión de ácido úrico en urea, la hidrólisis de urea, la generación enzimática y microbiana de amoníaco, difusión de amoníaco en la cama (Liu et al, 2007).

Primero la difusión entre el amoníaco adsorbido y el disuelto en medio acuoso, las reacciones químicas del amoníaco en solución acuosa, la difusión del compuesto entre fase sólida / acuosa y gaseosa, y la transferencia de masa por convección de gas amoníaco de la superficie con corriente de aire circundante (Liu et al, 2007).

Para el sistema de transporte entre fases mencionado anteriormente, hay muchas teorías propuestas, incluida la "Teoría de las dos películas" de Welty, 1984 y la "Teoría de la capa límite" de Olesen y Sommer de 1993, que permiten obtener una ecuación general de flujo

de transferencia de masa general (Liu & Wang & Beasley, 2006) representada en la ecuación 3.

**Ecuación 3:**

$$J = Km * (Cg0 - Cg\infty)$$

**Donde,**

*J*: flujo de emisión

*Km*: coeficiente de transferencia de masa

*Cg0*: concentración de la fase gaseosa de amoníaco en la capa superficial de la cama

*Cg∞*: concentración de la fase gaseosa de amoníaco en el ambiente

En la ecuación anterior, el flujo de amoníaco es principalmente una función de la transferencia de masa entre la concentración de amoníaco en la fase gaseosa en la superficie del lecho y la concentración de amoníaco en la fase gaseosa en el ambiente. Para estimar el flujo de amoníaco, es necesario entonces calcular el coeficiente de transferencia de masa y la concentración de amoníaco de la fase gaseosa en la superficie del lecho (Liu et al, 2007).

Calcular el coeficiente es la tarea más compleja, ya que se calcula experimentalmente y los resultados pueden variar de manera importante entre experimentos. Ni y Heber (1998) estimaron el coeficiente de transferencia convectiva de amoníaco, el cual variaba de  $1.0 \times 10^{-4}$  a  $2.3 \times 10^{-3} \text{m} \cdot \text{s}^{-1}$ , lo realizó utilizando datos obtenidos durante seis meses de mediciones de campo en un sistema de producción porcino.

La determinación de la concentración de amoníaco en la fase gaseosa en la capa límite de la cama es más compleja ya que está influenciada por el equilibrio entre las fases gaseosa y acuosa del amoníaco y la química de la fase acuosa del amoníaco dependiendo básicamente de las condiciones del lecho (Liu et al, 2007).

#### **2.1.2.4. Variables que influyen en la emisión de amoniaco**

Todas las reacciones biogeoquímicas, sin importar dónde se llevan a cabo, están controlados universalmente por el principio de termodinámica y cinética de reacción.

El primero determina si puede ocurrir una reacción, y el más tarde define su velocidad cuando la reacción tiene lugar (Li et al, 2012).

Las reacciones biogeoquímicas están influenciadas por un grupo de fuerzas o factores ambientales, que incluyen temperatura, humedad, pH, y gradiente de concentración de sustrato. Estos factores ambientales son variables en el espacio y el tiempo, para determinar las ocurrencias y las tasas de reacciones biogeoquímicas para cada ecosistema (Li et al, 2012).

Existen diferentes variables o condiciones que favorecen la generación de  $\text{NH}_3$ , sea por la degradación de la urea (Reacción rápida) o por la degradación del nitrógeno orgánico N (degradación lenta). Estas condiciones aceleran los procesos que van a aumentar los niveles de amoniaco libre en los purines y por consiguiente la emisión gaseosa del mismo (Saha et al, 2010). Por otro lado, las condiciones de anaerobiosis, acidificación, bajas temperaturas o reducción de superficies de contacto reducen las emisiones de amoniaco gaseoso (Botermans et al, 2010).

## **Temperatura**

La temperatura está directamente relacionada con la energía cinética de las partículas y, por lo tanto, controla casi todas las reacciones químicas. El equilibrio entre las energías de entrada y salida determina la variación de temperatura para cualquier sistema (Li et al, 2012).

Una alta temperatura en el estiércol aumenta la formación de amoníaco acuoso, debido a un aumento de la constante de disociación y aumenta la formación de amoníaco gaseoso ya que se disminuye la capacidad de disolución del amoníaco en la fase acuosa (Tong, 2020). Por lo tanto, la temperatura ambiente afecta la volatilización de amoníaco. La evaporación del agua del estiércol aumenta la concentración de amoníaco en el estiércol. En caso de que la concentración de amoníaco en el aire sea menor que la concentración en el estiércol, la evaporación estimula la volatilización del amoníaco, dicha evaporación se ve afectada por la temperatura ambiente, humedad del aire y radiación solar (Tong, 2020).

## **pH de la cama**

El pH de la cama está directamente relacionado con las concentraciones de amoníaco presentes en los galpones, se ha reportado que valores de pH de la cama en un rango superior de 8.0 arroja una concentración de  $\text{NH}_3$  significativa, esto se explica por el crecimiento microbiano que altera el ácido úrico favoreciendo la formación de  $\text{NH}_3$ . Además, un pH en este rango de alcalinidad ayuda a la descomposición de ácido úrico (Pezzuolo et al, 2019).

La concentración de la fracción acuosa del estiércol también se ve afectada por el pH del estiércol. A una temperatura de 10 a 30 ° C y a pH 7, menos del 1% del nitrógeno amoniacal total ( $\text{NH}_4^+$ , aq, m +  $\text{NH}_3$ , aq, m) está presente como amoníaco ( $\text{NH}_3$ , aq, m). Esta proporción excede el 50% a pH 10 (Ecetoc, 1994). La acidificación disminuye entonces la concentración de amoníaco ( $\text{NH}_3$ , aq, m) en el estiércol.

La volatilización puede ser disminuida entre un 30 a 98% descendiendo el pH del estiércol de 7.0 a un rango entre 5.0 y 6.5 y un 55 a 85% de la volatilización de amoníaco se puede ser disminuida al bajar el pH del estiércol en valores de 6.0 y 4.5 , respectivamente, comparado con el mismo estiércol a un pH de 7 (Huijsmans, 2003).

Con respecto a los niveles de humedad de la cama se dice que el pH se verá afectado con el aumento de esta, es decir a valores de rangos mayores de humedad será más alcalino (Huijsmans, 2003).

El amonio a valores ligeramente básicos en un rango de pH 7-8 se convierte en  $\text{NH}_3$ , que es el gas causante del fuerte olor de este estiércol (Soto et al, 2019). Según la literatura estos olores son mayores al presentarse un alto contenido de humedad, es decir a > Humedad de heces se emite una > emisión de  $\text{NH}_3$  y por consiguiente mayores olores.

### **Humedad relativa**

Velasco y col (2016) reportan que la humedad relativa (HR) en el interior de las granjas avícolas está estrechamente relacionada con la volatilización del  $\text{NH}_3$ . Por su parte afirman que una alta humedad relativa ayuda a la absorción del  $\text{NH}_3$  en las partículas de polvo. De esta manera valores de HR entre 50% a 70% respectivamente son los recomendados.

En lo reportado según Cohuo y col (2018) con respecto a la humedad de la cama, esta se ve afectada por factores como lo son: la ventilación, forma del bebedero y la densidad de las aves. Esta humedad genera una enfermedad en el animal llamada pododermatitis que es la ulceración en las patas de las aves. Esta enfermedad es más grave a medida que se incrementa la humedad de la cama más, si esta humedad está acompañada de excrementos fecales (estiércol) por tal motivo si no se lleva a cabo o no se tiene un adecuado manejo de la cama, esto será un factor significativo para presentarse una mayor concentración y emisión de  $\text{NH}_3$  (Castro, 2018). Esto se debe a que el  $\text{NH}_3$  junto con altos niveles de HR genera este tipo de afecciones en las aves.

La humedad juega un doble papel en la biogeoquímica del estiércol. La mayoría de las reacciones bioquímicas o geoquímicas tienen lugar solo en la fase líquida, por otro lado, casi todos los microbios sobreviven confiando en la disponibilidad de agua. El contenido de agua del estiércol acumulado en el piso del corral está definido por la entrada y salida de agua del piso (Li et al, 2012).

### **Densidad del animal**

La densidad de población es un factor significativo en el rendimiento del pollo, una sobrecarga de aves por  $\text{m}^2$  genera mayor concentración de  $\text{NH}_3$  (Kang, 2016). Una mayor densidad de población aumenta el nivel de nitrógeno y humedad en la cama, por lo tanto, favorece la actividad microbiana (Kang, 2016).

(Sánchez et al, 2001) exponen que la ventilación y la humedad están relacionadas con la densidad del animal, reportan en su estudio que el galpón más pequeño fue el que arrojó una menor densidad con un valor de 8,2 aves/ $\text{m}^2$  en relación con los demás galpones con un valor de densidad de 9,5 aves/ $\text{m}^2$ . Lo cual afirma y evidencia que una alta

densidad del animal (aves/m<sup>2</sup>) de construcción o menor área de galpón por ave, altera a la ventilación y a la cantidad de NH<sub>3</sub>.

### **Acumulación de estiércol**

En el estudio reportado por (Herrera et al, 2013) evidencian que las concentraciones de NH<sub>3</sub> varían con respecto al tipo de sistema de explotación utilizado en los galpones. Los resultados que obtuvieron con base a los dos sistemas utilizados evidenciaron que los galpones tipo jaula con fosa mostraron una mayor cantidad de emisión de NH<sub>3</sub> comparados con los galpones en piso, esto se debe a que en este tipo de galpón las excretas del animal no fueron apartadas ni retiradas mientras se encontraban las aves, provocando una cantidad mayor acumulada, generando una mayor concentración de NH<sub>3</sub>.

Por su parte los galpones en piso arrojaron una concentración y emisión de NH<sub>3</sub> menor, esto se presentó porque a diferencia del sistema tipo fosa, las excretas fueron retiradas. Por lo tanto, factores como el tiempo de acumulación y cantidad de las excretas dentro del galpón, la temperatura y el grado de ventilación influyen en la cantidad de NH<sub>3</sub> emitida.

(Álvarez et al, 2005) indican que el cambio del nitrógeno presente en las excretas de las aves y amonio cambia en función de factores como el pH del estiércol, la temperatura, humedad y el efecto del tipo de ventilación.

### **Ingesta de proteína**

Varios estudios demuestran que la producción de NH<sub>3</sub> se puede reducir mediante la manipulación de la dieta (Roberts et al, 2015). Respecto a la dieta animal, la literatura

reporta diversos trabajos sobre la reducción del contenido de nitrógeno en la dieta y su efecto en el  $\text{NH}_3$ . Reducir el porcentaje de proteína en la ingesta de aves del 2 al 10% genera una disminución y/o pérdida de excreción de nitrógeno en las excretas fecales hasta del 20 % y por consiguiente un 10 % menos de dispersión de  $\text{NH}_3$  en la atmósfera al igual que en la composición del estiércol (Escorcía, 2015).

Gonzalez y col (2019) registraron que proporcionarle una dieta balanceada a las aves es fundamental para evitar y/o disminuir la producción de estiércol húmedo, ya que este se genera por el mal manejo que se le da a la dieta, por la formulación del alimento y/o presencia de antibióticos. Causando un aumento en la cantidad, concentración y emisión de  $\text{NH}_3$ , así mismo provocando una disminución de la productividad de las aves.

## **Ventilación**

La ventilación juega un papel importante en la distribución espacial de calor, humedad y concentraciones de gas y polvo en los establos de animales. Se han reconocido grandes variaciones temporales y espaciales en el ambiente térmico y las concentraciones de  $\text{NH}_3$  en los galpones debido a patrones de flujo de aire de ventilación no uniformes, que conducen a una productividad no uniforme (es decir, diferente tamaño de huevo, calidad de cáscara de huevo y cantidad) y diferentes niveles de los riesgos para la salud de las aves y los trabajadores (Tong et al, 2019).

La tasa de ventilación a través de una fuente de emisión es uno de los dos elementos indispensables para cuantificar las tasas de emisión, siendo el otro elemento la concentración de la sustancia de estudio. La tasa de ventilación es generalmente más compleja de obtener que las concentraciones, según Li, H. (2006).

La ventilación se utiliza para mejorar la calidad del aire y puede aumentar producción de  $\text{NH}_3$  debido al alto gradiente de concentración de  $\text{NH}_3$  entre la superficie del estiércol y el aire circundante. Por lo tanto, al disminuir la tasa de intercambio de aire del almacenamiento de estiércol se puede reducir la emisión de  $\text{NH}_3$  debido al gradiente de presión más bajo en el  $\text{NH}_3$  entre el estiércol y el aire circundante. El secado se puede utilizar para reducir la emisión de  $\text{NH}_3$  del estiércol almacenado Li, H (2006).

Las concentraciones de amoníaco también varían significativamente entre las estaciones debido a las diferentes tasas de ventilación utilizadas en los galpones de ponedoras. Las tasas de ventilación de las instalaciones para animales suelen estar a un nivel mínimo ( $23 \text{ m}^3/\text{s}^{-1}$ ) en invierno para conservar la energía térmica, comparadas con las tasas de ventilación en verano ( $184 \text{ m}^3/\text{s}^{-1}$ ), las tasas de ventilación mínimas dan como resultado concentraciones de  $\text{NH}_3$  relativamente altas debido a la menor dilución del aire (Tong et al, 2019).

Existen diferentes tipos de ventilación como lo son:

- Natural
- Presión negativa
- Presión positiva
- Recirculación de aire

La ventilación natural se realiza con el manejo de cortinas, pero el aire frío que ingresa puede generar mayor humedad y el flujo de aire que ingresa al galpón puede no ser el suficiente para garantizar la renovación mínima de aire necesaria para los animales.

La ventilación por presión negativa consiste en extraer el aire del galpón e ingresar aire del exterior de manera controlada de forma mecánica a través de ventiladores. Este tipo

de ventilación puede acoplarse a un sistema de enfriamiento evaporativo, para evitar el uso de aire acondicionado y reducir costos. El enfriamiento evaporativo consiste en utilizar nebulizadores de agua cuya finalidad es dispersar en el ambiente gotas muy pequeñas de agua para que puedan ser absorbidas por una corriente de aire y las evapore, produciendo un intercambio de que enfría el aire y refresca el galpón (Álava, 2015).

La ventilación por presión positiva consiste en ingresar aire exterior al galpón y direccionar el aire interior hacia la salida. La ventilación cruzada o por recirculación consiste en ventiladores ubicados dentro del galpón que toman aire del exterior y lo distribuyen uniformemente hacia el interior.

Por ejemplo, la ventilación de túnel da como resultado concentraciones más altas de  $\text{NH}_3$  cerca de los escapes y menos  $\text{NH}_3$  concentraciones cerca de las entradas de aire en galpones de ponedoras y pollos. Las aves cerca de los escapes pueden tener más problemas de salud y un rendimiento de producción deficiente en comparación con las aves cerca de las entradas de aire (Tong et al, 2019).

## **2.1.3. Modelos neuronales artificiales**


### **2.1.3.1. Analogía entre neurona artificial y neurona biológica**

#### **Neurona Biológica**

Para indagar sobre los conceptos de red neuronal artificial (RNA), funciones y algoritmos, en primer lugar, se debe abordar a manera general el concepto de neurona. La neurona es una célula fundamental y básica para el procesamiento y transmisión de información

a todo el sistema nervioso. Se dice por estimación que el cerebro humano tiene más de cien mil millones de neuronas con siete mil conexiones sinápticas cada una (Barrera, 2013). Estas conexiones entre sí forman la red neuronal del cerebro humano.

Las neuronas están conformadas por tres elementos principales: Las dendritas, soma y el axón (figura 3).



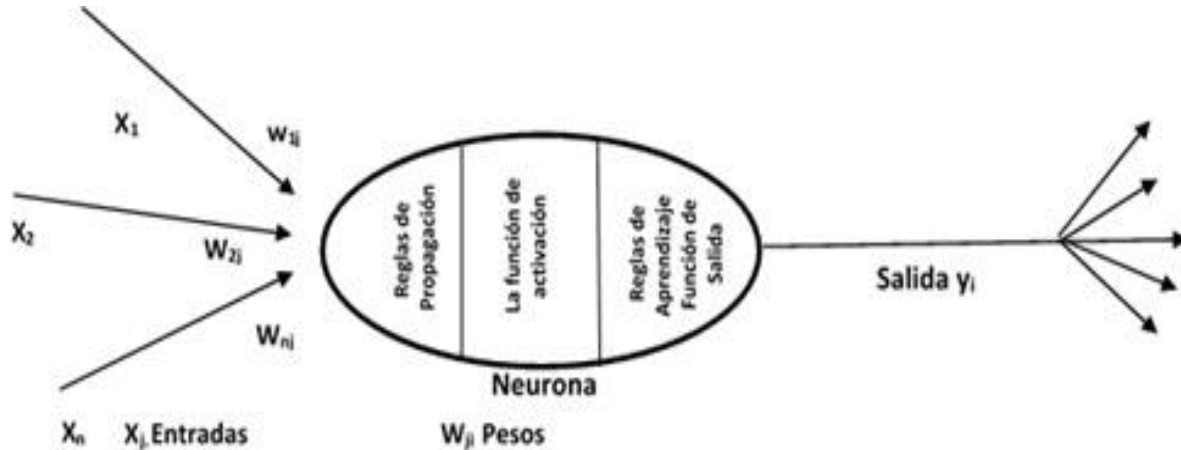
**Figura 3.** Elementos básicos de una neurona biológica. **Fuente:** Tablada (2009).

- **Soma:** La neurona biológica está conformada su cuerpo celular también denominado (soma), siendo la parte de más volumen que compone la neurona, en la cual se encuentra el núcleo y en la que se derivan sus continuaciones (dendritas y axón) (González & García 2019).
- **Dendritas:** Las dendritas son la continuación o prolongación del cuerpo celular que actúan como canal receptor. Se encargan de recibir y procesar la información proveniente de otras neuronas para enviarlas al soma de la neurona (González y García 2019).
- **Axón:** Es una prolongación del cuerpo celular con una prolongación larga y su función es transmitir el mensaje derivado de las interacciones desde el soma a otras células (González y García 2019).

Las neuronas son capaces de transmitir la información entre ellas, a esta zona de conexión se le denomina sinapsis, siendo la unión entre dos neuronas, y es el resultado de la interacción del axón (terminación de la estructura neuronal) con las dendritas (Estructura inicial neuronal) de otra neurona (González y García 2019).

## Neurona Artificial

El desarrollo de las redes neuronales artificiales es una inspiración basada en los conocimientos del cerebro humano, esencialmente sobre las neuronas biológicas y sus conexiones, con el fin de dar solución a problemas con operaciones complejas mediante métodos y algoritmos que definen la red (Lee, 2019). La neurona artificial es un elemento básico para formar la red artificial, la cual se puede confrontar con la neurona biológica dado a su similitud en funcionamiento y estructura (figura 4).



**Figura 4.** Elementos básicos de una neurona artificial. Fuente: **Tablada (2009)**.

**Regla de Propagación:** Calcula a través de las entradas y pesos de la neurona, “el valor del potencial postsináptico” de la misma (Garzón, 2005)

**Función de Activación:** Las neuronas poseen un estado de activación de tipo activo e inactivo, en este aspecto la función (activation function) suministra información del estado de activación de la neurona (Bertona e al, 2005).

**Función de salida:** la función (output function) determina la activación y el valor que será enviado a otras neuronas conectadas.

Tal como se observa en la figura 4, la estructura de la neurona artificial tiene grandes semejanzas a las neuronas cerebrales: Las entradas ( $X_i$ ) en la neurona artificial se comportan como las dendritas, las cuales son las que reciben la información de entrada de las neuronas. El elemento de “función de activación” es un paralelo al soma de la neurona procesa la información y la activación de la neurona. Las salidas ( $Y_i$ ) reemplazan el axón, y envían el mensaje a las demás neuronas artificiales. De acuerdo con Bertona y col (2005) si se analiza las neuronas biológicas desde la perspectiva de la informática, estas son equivalente a un procesador simple conformado por subsistemas de entrada (Dendritas), de procesamiento (Soma) y de salida (Axón).

A continuación, se muestra un paralelo comparativo estructural de una neurona biológica con una neurona artificial.

Neurona Biológica	Neurona Artificial
Dendritas	(Variables de entrada)
Sinapsis	(Pesos)
Axón	(Variable de salida)

**Figura 5.** Comparativo estructural de una neurona biológica vs neurona artificial.

**Fuente:** Elaboración propia.

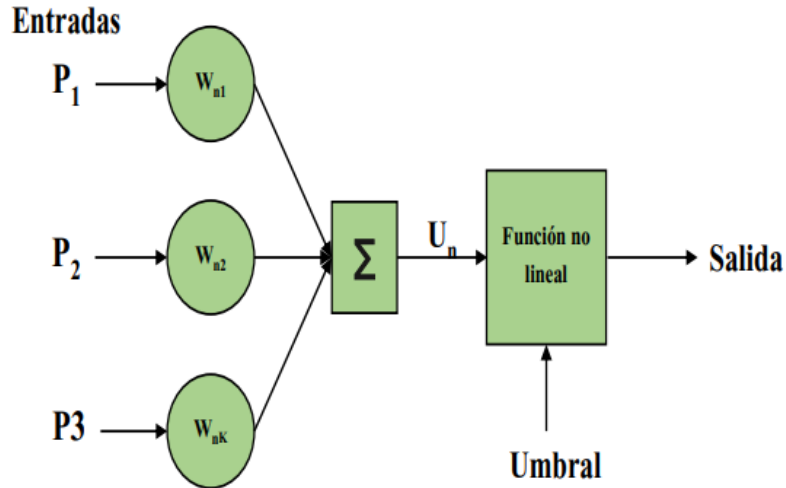
### **2.1.3.2. Redes neuronales artificiales**

Las redes neuronales artificiales son modelos de programación con una gran capacidad de generalización y resolución de problemas de relaciones tanto lineales como no lineales, no necesitan un conocimiento profundo de la distribución de las variables a estudiar (Cortina, 2012); Las redes neuronales se pueden categorizar en base al factor de dos variables precisas de su diseño las cuales son; La Arquitectura y el Aprendizaje (León & Piña, 2018).

En general los modelos neuronales según Martín y col. (2009) poseen cuatro elementos básicos:

- 1)** Una serie de conexiones con unos pesos asociados que determinan el funcionamiento de la neurona.
- 2)** Un contador que totaliza todas las variables de entrada multiplicadas por los respectivos pesos.
- 3)** Una función de activación que defina el amplio de la salida de la neurona.
- 4)** Un umbral que al ser superado genere la activación de la neurona se activa.

Gráficamente una Neurona Artificial puede representarse como en la figura 6 :



**Figura 6.** Esquema general de una red neuronal. **Fuente:** Medina & Ore (2016).

El desarrollo de las redes neuronales artificiales está basado en el cerebro humano, por lo tanto, su desarrollo y aplicación adquiere grandes ventajas. (Asanza, 2018), expone algunas de las ventajas y desventajas más significativas de las redes neuronales artificiales RNA:

### **Ventajas:**

**Aprendizaje Adaptativo:** Las RNA tienen un aprendizaje adaptativo, en este sentido logran aprender a realizar las tareas designadas en base a entrenamiento y en base a la experiencia o información inicial suministrada (datos). La representación de los “datos” son considerados como entradas y pesos en la red neuronal.

**Autoorganización:** Adquieren la capacidad de crear a manera propia su organización o representación de la información que le es suministrada; la red autoorganiza la información que le es proveída en la etapa de aprendizaje.

**Tolerancia a Fallos:** La destrucción a manera parcial de la red reduce su funcionamiento, pero no la destruye completamente. Otros sistemas de computación pierden en manera

total su capacidad de operar cuando presentan un error en la memoria, en cambio en las redes neuronales, si se presenta un error en el almacenamiento o en sus neuronas, la red neuronal no dejará de funcionar, aunque su velocidad de convergencia se vea afectada (Matich, 2001). la información contenida en la red no se pierde.

**Operación en Tiempo Real:** La capacidad de las redes neuronales pueden ser aprovechadas en su totalidad por computadoras y hardware, en tiempos paralelos.

## **Desventajas**

Algunas redes neuronales requieren de altos costos de computación, es decir, que requieren de gran capacidad de almacenamiento.

Existen redes que requieren de múltiples ejemplos para su entrenamiento y aprendizaje, lo que se traducen en más operaciones de cálculo y grandes demoras en tiempos de convergencia.


No poseen la capacidad de interpretar la información de salida de la red (resultados) por lo tanto requiere de la interpretación de un agente externo.

### **2.1.3.3. Arquitectura de una red neuronal**

La propiedad de capacidad de cálculo y de velocidad de procesamiento (potencia) de la información de una red neuronal se deriva de las múltiples conexiones que integran una RNA (Cordoba, 2017).

Las neuronas de una red se congregan en modelos conexionistas que se denominan capas y la agrupación de una o más capas de neuronas son las que conforman una red

neuronal. En este aspecto se distinguen tres tipos de capas: de *entrada*, *salida* y *oculta* (Figura 7).



**Figura 7.** Elementos básicos que integran una red neuronal artificial. **Fuente:** Serrano (2010).

**Las capas de entrada o capas sensoriales son las que reciben la información (datos) del exterior.**


- Las **capas ocultas** son aquellas que se encuentran en medio de las capas de entrada y salida, pero no tienen contacto directo con el entorno.
- las **capas de salida** formada por grupos de neuronas las cuales son las que dan la respuesta de la red neuronal.

#### 2.1.3.4. Tipos de redes neuronales

##### Redes Monocapa

Las redes monocapa constituyen la red menos compleja, dado a que solo está compuesta por una capa de entrada que proyecta la información a las capas de neuronas (figura 8), sin embargo, como la entrada solo envía la información a las neuronas y no realiza algún


tipo de cálculo no se consideran una capa, en la practica la mayoría de problemas en ingeniería, informática y en otros campos de estudios requirieren de modelos con mayores regiones de clasificación (múltiples capas) razón por la cual las redes monocapa se han visto limitadas en su uso.



**Figura 8.** Elementos de una red Monocapa. **Fuente:** Serrano (2010).

### Redes neuronales Multicapas


Las redes multicapas son redes que están diseñadas con varios grupos de neuronas que se encuentran en diversos niveles de capas. A diferencia de la red monocapa existen diversos números de capas que realizan cálculos entre las entradas y la salida, a lo que se denomina capas ocultas (Serrano, 2010).



**Figura 9.** Estructura de una red Multicapa. **Fuente:** Serrano (2010).

### Perceptrón

El perceptrón propuesto por Rosenblatt en 1958 y fue el primer modelo de red neuronal simple programado para ser entrenado. El modelo a través de una primera capa de neuronas toma señales de entrada (patrones) codificadas como vectores de entrada (reales)  $(X_n \in \{x_1; x_2; \dots; x_{nC1}\})$  para determinar cada uno de los pesos sinápticos asociados  $(W_n \in \{w_1; w_2; \dots; w_{nC1}\})$ . La salida es la suma ponderada de las entradas, (es decir, el producto por punto de peso y los vectores de entrada), consta también de una función de activación  $f$  que es de tipo escalón, generando salidas binarias. Por convención, si hay  $n$  entradas para el perceptrón, la entrada  $x_{nC1}$  se fijará 1 y el peso asociado a  $w_{nC1}$  es el valor del umbral de excitación (Tino y Sperduti, 2015) (figura 10).



**Figura 10.** Esquema del modelo perceptrón simple. **Fuente:** Tino y Sperduti (2015).

El perceptrón posee un algoritmo que le permite ajustar los pesos sinápticos basado en una diferencia entre la salida o estimación de la red y una referencia o salida objetivo, minimizando cada vez más el error. El principal inconveniente de este método es que la función a representar debe ser linealmente separable sino el entrenamiento no converge y no conseguirá una solución (Bertona et al, 2005).

### Perceptrón multicapa

El modelo de perceptrón multicapa está basado en la estructura del perceptrón simple, pero posee una mayor robustez. Esta red contiene un conjunto de capas ocultas además de las capas de entrada y de salida. Además, pueden ser utilizadas diferentes tipos de función de activación, siendo generalmente utilizadas funciones sigmoideas.

El perceptrón multicapa es el diseño de red más comúnmente aplicado en la actualidad.

Posee un amplio rango de aplicaciones. Algunas de las áreas de aplicación son:

- Codificación de información
- Traducción de texto en lenguaje hablado

- Reconocimiento óptico de caracteres

### **2.1.3.5. Métodos de entrenamiento para las redes neuronales de perceptrón multicapa**

El entrenamiento de la red radica en aprender un comportamiento de los patrones para generar una respuesta, eso se logra mediante una alimentación hacia adelante y otra hacia atrás. En el recorrido hacia adelante, se aplica un vector de entrada a los nodos fuente de la red, y su efecto se propaga a través de la red, capa a capa. Finalmente, aparece un conjunto de salidas que constituyen la respuesta actual de la red (Pérez y Cadenas, 2005).

Durante la alimentación hacia adelante, se fijan todos los pesos sinápticos de la red. Posteriormente, durante la pasada hacia atrás, los pesos sinápticos se ajustan de acuerdo con la regla de aprendizaje por corrección de error. De este modo, para conseguir la señal de error se resta la respuesta actual de la red a la deseada. Esta señal de error se propaga luego hacia atrás por la red, en dirección opuesta a la de las conexiones sinápticas. Los pesos sinápticos se ajustan, de esta forma, para así conseguir acercar lo más posible la respuesta actual de la red a la respuesta deseada (Pérez y Cadenas, 2005). Este algoritmo de aprendizaje se denomina backpropagation, y la red por su funcionamiento completo es conocida también como red feedforward backpropagation, pero que de manera generalizada se ha denominado como perceptrón multicapa (MLP).

Para el entrenamiento de redes neuronales artificiales (RNA) se emplean diversos métodos y algoritmos, los cuales definen el modelo de la red neuronal que se desarrolla, en ese sentido las RNA se pueden clasificar de acuerdo con el término del algoritmo empleado para su entrenamiento. El entrenamiento radica en aprender un comportamiento de los patrones para generar una respuesta alimentando la información a través de las capas hacia adelante, y posteriormente una vez supervisa el error en la estimación, hace un ajuste de los pesos sináptico distribuyendo dicho error, hacia atrás. Este algoritmo de aprendizaje se denomina backpropagation, y la red por su funcionamiento completo es conocida también como red feedfoward backpropagation, pero que de manera generalizada se ha denominado perceptrón multicapa (MLP).

A continuación, se muestran los algoritmos de aprendizaje más empleados y conocidos de acuerdo con su tipo de aprendizaje regla y arquitectura:

**Tabla 6. Principales Algoritmos utilizados en entrenamiento de Redes Neuronales.**

ALGORITMOS DE APRENDIZAJE			
TIPO DE APRENDIZAJE	REGLA DE APRENDIZAJE	ARQUITECTURA	ALGORITMO DE APRENDIZAJE
SUPERVISADO	Corrección de error	Perceptrón Perceptrón Multi Capa	Backpropagation, ADALINE, MADALINE LMA
		Elman y Jordan recurrentes	Backpropagation
	Boltzmann	Recurrente	Algoritmo de aprendizaje Boltzmann

	Competitivo	Competitivo	LVQ
		Red ART	ARTMap
<b>NO SUPERVISADO</b>	Relajamiento	Red de Hopfield	Aprendizaje de memoria asociativa
	Competitiva	Multi Capa sin realimentación Competitiva	Proyección de Sammon VQ
		SOM	Kohonen SOM
		Redes ART	ART1, ART2
	Hebbian	Multi Capa sin realimentación	Análisis lineal de discriminante
		Sin realimentación o competitivas	Análisis de componentes principales

**Adaptado de:** Saavedra (2017). Algoritmos usado en este trabajo, siendo los más importantes empleados en MATLAB®1.

**Tabla 7. Algoritmos más importantes empleados en MATLAB. Fuente: Fuente:**

<b>FUNCIÓN DE LIBRERÍA</b>	<b>FUNCIÓN DE LIBRERÍA</b>	<b>DESCRIPCIÓN</b>
traingd	Gradiente Descendente (GD)	GD es el algoritmo de gradiente descendente original pero el más lento para entrenamiento de RNA

traindm	GD Con momentum	Este algoritmo corrige los defectos del GD, en este sentido es más rápido en entrenamiento.
trainda	GD con adaptación $\alpha$	Es más rápido que el gradiente descendente, sin embargo, sólo puede ser empleado en entrenamiento de redes por lotes.
traindx	GD con adaptación $\alpha$ y momentum	
trainrp	Propagación hacia atrás	Este algoritmo adquiere una convergencia más rápida
traincgf	Actualización de Fletcher-Reeves	Estos algoritmos de entrenamiento corresponden a algoritmos de gradiente conjugada. Poseen una convergencia rápida
traincgp	Actualización Polak-Ribière	
traincgb	Reinicios de Powell-Beale	
trainscg	Gradiente conjugado escalado	
trainbfg	Algoritmos BFGS	
trainoss	Método secante de un paso	Corresponden a algoritmos de métodos de Quasi-Newton con rápida convergencia
trainlm	Levenberg-Marquardt (LM)	Entrenamiento más rápido para una RNA. Requiere de menos costos en memoria en almacenamiento.
trainbr	Red Bayesiana	Logra mejorar la capacidad de generalización

**Adaptado de:** Abdulghani et al (2016)

## **Método de levenberg-marquardt**

Las propiedades de convergencia en entrenamiento de una red neuronal bajo el método de Levenberg-Marquardt (LM) son una pequeña modificación del método tradicional de Gauss Newton, aunque ambos poseen características similares, la implementación de los algoritmos complementarios de (LM) ¿corrige y mejora las desventajas presentadas con el método Gauss Newton (Vivas, 2014).

El método de Levenberg se estableció en base a una función de error Hessiana y la implementación de un método de parada temprana que evita un sobre entrenamiento de la red neuronal (Muñoz y Seijas, 2015), esto se logra a partir de los algoritmos que finalizan de manera automatizada el proceso de entrenamiento en manera oportuna de acuerdo a su programación.

## **Red Bayesiana**

La Red Bayesiana es un modelo probabilístico de grafo dirigido y acíclico, compuesto por nodos y arcos, donde los nodos representan una variable aleatoria y los arcos una dependencia probabilística, en este sentido las conexiones de probabilidad entre estos son los que permiten llegar a una respuesta ante algún caso de indecisión (García, 2017).

De acuerdo con (Muñoz y Seijas, 2015) en las redes bayesianas el aprendizaje se basa en desarrollar un modelo estructural (Creación de estructura o modelo) y de parámetros asociados (cálculo de probabilidades asociados a cada variable) mediante el ingreso de datos.

Una de las características más importantes de este tipo de redes es que logran el aprendizaje sobre relaciones de dependencia y casualidad, lo cual permite que se pueda combinar los conocimientos de la red con nuevos datos (Lozano, 2011).

### **Quasi - Newton**

Entre los métodos más conocidos para solucionar problemas de ecuaciones no lineales se encuentran el método de Newton y el método de Quasi Newton. Desde la perspectiva computacional la implementación del método newton se deriva en altos costos, dado a que se hace necesario la ejecución de múltiples operaciones en cada interacción para calcular la matriz jacobiana, el Hessiano y sus derivadas (Torres, 2014), sin embargo, se desarrollaron métodos alternos para corregir estas dificultades a lo que se interpretan como métodos de Cuasi Newton, estos métodos no realizan un cálculo exacto , sino una aproximación de la matriz hessiana.

### **Algoritmo secante de un paso**

El método de secante de un paso es un método desarrollado con el fin de solucionar los espacios existentes de los algoritmos de gradiente conjugados y de los algoritmos de Quasi-Newton (Garzón, 2005).Se origina de acuerdo a la necesidad de un algoritmo con aproximación a la secante a menos costos, es decir, con menos almacenamiento y con reducción de esfuerzos en materia de equipos de cómputo. La reducción de almacenamiento es lograda dado a que el algoritmo no almacena la matriz hessiana en su totalidad, sino que asume que en la última iteración se encuentra la matriz.

### **Método Back Propagación:**

El método (BP) Back Propagación (Propagación hacia atrás), también conocido como algoritmo de retro propagación de errores es un método desarrollado con aprendizaje supervisado y el más empleado para entrenamiento de redes neuronales con conexión hacia adelante (Bertona et al, 2005).

En este método de entrenamiento de red neuronal Back Propagation se encuentra la regla de aprendizaje del algoritmo conocido como regla del mínimo error cuadrado (LMS- Least Mean Squared Error) o LMS multicapa, la cual es una generalidad de la regla de aprendizaje delta, esta regla logró modificar los pesos de las capas ocultas de la red neuronal (Matich, 2001).

Este algoritmo realiza la búsqueda del mínimo en la función de error (Valor de error recibido) de pesos existentes en los espacios, empleando algoritmo de descenso de gradiente (Vivas, 2016). La denominación de Back Propagación es derivado dado a que el método propaga el error hacia atrás en toda la red neuronal, en otros términos, se realiza la propagación desde la última capa de salida hacia atrás a todas las capas, en este sentido el algoritmo permite que las conexiones de red en las capas ocultas cambien y aprendan en el desarrollo y entrenamiento.

### **Método de Gradiente Conjugado Escalonado**

El método de Scaled conjugated gradient (Gradiente Conjugado Escalonado) se emplea para resolver problemas de ecuaciones lineales; este algoritmo requiere de menos espacio de almacenamiento. Para una red neuronal desarrollada con este tipo de algoritmo su aprendizaje es detenido de manera automática en medida en que el

algoritmo suspende la generalización a mejorar (Incremento de error cuadrático) (Vivas A., 2016).

En relación con los métodos de gradientes conjugados según García (2017) son el resultado de la unificación los métodos de Newton y del método de descenso de gradiente, ello como propósito de mejorar la velocidad de cálculo en convergencia que era más lenta en el algoritmo de descenso de gradiente y con el fin de reducir los costos de computación que requiere el modelo de Newton por el gran almacenamiento del Hessiano.

### **Método del Gradiente descendente con Momentum**

Los métodos comunes de gradientes descendientes poseen dificultades a la hora de hallar una dirección en superficies de error, por lo cual incrementa costos en tiempo de convergencia y en esfuerzos de la red neuronal, en este sentido y para superar dicha dificultad se implementó el método de Momentum (Doren, 2017). El momentum logra reducir el tiempo en la convergencia, además permitiendo no solo calcular la gradiente local, sino que actúa como un tipo de filtro para pasar por alto las imperfecciones en alguna planicie (García, 2017).

### **Método del Gradiente Descendiente**

El método de gradiente descendente es el más simple, más conocido y aplicado en para entrenamiento de redes neuronales. El objetivo del algoritmo es hallar un equilibrio en configuración de pesos en relación con el mínimo de la función de error (Bertona et al, 2005). Es un método de entrenamiento de redes por lotes donde los pesos y sesgos de

la red se van reestableciendo en trayectoria del negativo de función de rendimiento (García, 2017).

## **2.2. Marco normativo**

### **Normas sector avícola – mitigación de olores**

En Colombia existe un marco constitucional por el cual se logró avanzar en aspectos de prevención, control y contaminación atmosférica mediante la expedición del Decreto 948 de 1995 en el cual se determinó el reglamento de protección y calidad del aire en el país. Este decreto determinó que es el Ministerio de Ambiente la entidad encargada de generar mediante resoluciones los niveles y tiempos de concentraciones de sustancias contaminantes permitidas a fin de preservar la calidad del aire y la responsable de reglamentar todo lo relacionado a olores ofensivos (MinAmbiente, 2013).

De acuerdo con el decreto 948/95 se determina por concepto de “olor ofensivo” a todo olor generado por sustancias o actividades de los sectores industriales, del comercio o deservicios, que produzcan fastidio aun cuando no cause afectaciones en la salud humana.

En el país existe un marco normativo especial para la reglamentación y disposiciones sobre olores ofensivos que se encuentra en la resolución 1541 del 2013.

De acuerdo con esta resolución del Ministerio de Ambiente y Desarrollo Sostenible No. 1541 del 2013 las principales sustancias generadoras de olores ofensivos para una unidad de producción pecuaria son el sulfuro de hidrogeno ( $H_2S$ ) y el amoniaco ( $NH_3$ ),

así mismo dicta que los niveles tolerables en la calidad del aire o de inmisiones de olores ofensivos bajo condiciones de referencia (25°C y 760 mm Hg) para este sector.

**Tabla 8. Niveles permisibles de calidad del aire o de emisión para sustancias de olores ofensivos**

SUSTANCIA	NIVEL MÁXIMO PERMISIBLE	
	µg/m <sup>3</sup>	Tiempo de Exposición
Sulfuro de hidrógeno (H <sub>2</sub> S)	7	24 horas
	30	1 hora
Azufre total reducido (TRS)	7	24 horas
	40	1 hora
Amoniacó (NH <sub>3</sub> )	91	24 horas
	1400	1 hora

**Fuente:** MinAmbiente (2013). **Nota:** condiciones de referencia (25° C y 760 mm Hg).

La norma 1541 también establece los niveles permisibles de calidad del aire o inmisión de mezclas de sustancias ofensivas. Estos niveles son condiciones de referencia expedidos por el Ministerio de Ambiente. La recepción de quejas por olores ofensivos lo establece la misma resolución 1541/2013 y los procedimientos para la reducción de estas emisiones que deben seguir la autoridad en materia ambiental.

Toda aquella empresa o industria que incumpla con los niveles permisibles de emisiones atmosféricas contaminantes recibirá visitas de la autoridad competente de la región donde se evaluará los niveles de calidad del aire o inmisión de sustancias y deberá presentar un plan para la reducción del impacto por olores ofensivos.

El Artículo 19 de la resolución establece las medidas preventivas y sancionatorias por incumplimiento de las disposiciones y directrices de la autoridad ambiental, dichas sanciones se encuentran inmersas en la ley 1333 del 2009, por la cual se establece el procedimiento sancionatorio ambiental y se dictan otras disposiciones. La emisión de olores es inherente en todo el proceso de la producción avícola, sin embargo, se puede reducir o mitigar en gran medida el impacto generado a la atmosfera y a las comunidades aledañas.

Un correcto manejo de emisiones de amoniaco y la existencia de un plan de reducción de impacto de olores ofensivos permitirá detectar de manera temprana las quejas de la comunidad, así como la recepción, el correcto manejo de atención y solución de las mismas, que evitará que se escale la autoridad ambiental competente y que arrojen como resultado sanciones administrativas o hasta la exigencia de cambios en los procesos de producción , como por ejemplo la ampliación de la capacidad de producción o la exigencia de adquisición de nuevas tecnologías para la producción o para la mitigación de olores (FENAVI, 2018). El control de las variables ambientales y de diseño que afectan la emisión de  $\text{NH}_3$  y olores al ambiente resulta fundamental para mantener los límites permitidos en la normativa y evitar procedimientos sancionatorios.

## 2.3. Marco Referencial

En la literatura se encuentran diferentes trabajos, acerca de la estimación de las emisiones de amoníaco provenientes del estiércol tanto en proceso productivo pecuario, como durante la disposición de estos residuos de manera directa en la tierra y en procesos de compostaje, a continuación, se presenta un relato de alguno de estos estudios:

Rege y Tock (1996) describieron el desarrollo y la validación de una red neuronal con el fin de estimar las tasas de emisión de gases peligrosos en fuentes puntuales en instalaciones avícolas. La red neuronal se entrenó específicamente para los gases  $H_2S$  y  $NH_3$  usando datos obtenidos experimentalmente para diferentes clases de estabilidad atmosférica en el oeste de Texas. La predicción de la red se encontró dentro del 20% de las tasas de emisión medidas para estos dos gases a distancias inferiores a 50 m. Las estimaciones de la tasa de emisión de las emisiones a nivel del suelo se obtuvieron en función de siete variables: distancia de sotavento, distancia de viento cruzado, velocidad del viento, concentración a favor del viento, estabilidad atmosférica, temperatura ambiente, y humedad relativa. Un algoritmo de backpropagation se utilizó para desarrollar la red neuronal. Los datos experimentales fueron recolectados en Wind Engineering Sitio de campo de investigación ubicado en Texas Tech University en Lubbock, Texas. Las redes neuronales demostraron su potencial para proporcionar estimaciones confiables de la tasa de emisión de contaminantes en base a los datos meteorológicos. Para los datos en el conjunto de prueba, las predicciones de la mayoría de las tasas de emisión se encontraron dentro del 10% de los valores experimentales. Incluso las predicciones del peor de los casos para las tasas de emisión todavía estaban dentro del 20% de los

valores medidos. Para los investigadores este error puede minimizarse si se abarca el rango de variables de entrada con una granularidad más fina. Sin embargo, debe tenerse en cuenta que la técnica de red neuronal para la estimación de la tasa de emisión de la fuente puntual no permite su uso fuera del rango de variables para el que se desarrolló y validó.

Plöchl (2001) presentó un enfoque de red neuronal, que permitió simular la emisión de amoníaco después de la aplicación de estiércol como enmienda en un campo. Con base en los datos de 227 experimentos de investigaciones previamente publicadas, se puede ilustrar que el curso temporal de la emisión de amoníaco acumulado sigue una función no lineal de Michaelis-Menten. Esta función está determinada por los dos parámetros  $E_{\max}$  y  $K_M$ , que dependen de las fuerzas motrices específicas del estiércol, los parámetros de la aplicación y el clima. 102 conjuntos de datos de los 227 experimentos mostraron datos suficientes para la formación y la validación de las redes neuronales para la estimación de  $E_{\max}$  y  $K_M$ . Las redes neuronales podrían ser entrenadas para valores de  $R^2$  de 0.926 y 0.832 para el conjunto de entrenamiento y el conjunto de validación de  $E_{\max}$ , y para los valores de  $R^2$  de 0.988 para el conjunto de entrenamiento y 0.527 para el conjunto de validación del valor de  $K_M$ , respectivamente.

Yang y col (2011) estimaron la concentración de amoníaco mediante el uso de modelos de redes neuronales (NN). Los dispositivos de onda acústica de superficie horizontal de corte (SH-SAW) recubiertos con hidrocloreuro de ácido L-glutámico y película de polianilina (PANI), respectivamente, se aplicaron como sensores de amoníaco. Los datos detectados por los sensores SH-SAW se implementaron mediante el uso de diferentes modelos de Redes Neuronales. Se concluyó que las relaciones complejas entre amoníaco y la interferencia de humedad para diversos ambientes húmedos se pueden

clasificar de manera más efectiva mediante nodos ocultos de varios niveles, estimando con mayor precisión la concentración de amoníaco. Por lo que un sensor de este tipo con la técnica neuronal correcta podría ser útil para diferentes aplicaciones. Los resultados también evidenciaron que la técnica inteligente en la aplicación del sensor como identificador es muy prometedora.

Boniecki y col. (2012) desarrollaron, probaron y validaron los modelos neuronales Perceptrón multicapa (MLP), Red de función de base radial (RBF), Red neuronal de regresión generalizada (GRNN), buscando un modelo de red neuronal que predijera las emisiones de amoníaco generadas en lodos de aguas residuales de compostaje. Se evaluaron diferentes mezclas de compostaje con diferentes composiciones, variando las proporciones de paja de cereal, serrín y corteza de árbol. Los modelos neuronales creados contenían 7 variables de entrada (parámetros químicos y físicos de compostaje) y 1 de salida (emisión de amoníaco). La base de datos obtenida de la experimentación se subdividió en tres conjuntos de datos: el conjunto de aprendizaje (ZU) que contiene 330 casos, el conjunto de validación (ZW) que contiene 110 casos y el conjunto de prueba (ZT) que contiene 110 casos. Las relaciones de desviación estándar (para las 4 redes creadas) oscilaron entre 0.193 y 0.218. Para todos los modelos seleccionados, el coeficiente de correlación alcanzó los valores altos de 0.972-0.981.

Huang y col (2015) establecieron un modelo de pronóstico de la contaminación atmosférica. El modelo de pronóstico que se combina con técnicas de minería de datos y el algoritmo de red neuronal de BP se basó en los datos de monitoreo de la contaminación del aire obtenidos de las estaciones de monitoreo de la calidad del aire de Shijiazhuang. En primer lugar, este modelo utilizó la tecnología de minería de datos

para encontrar los factores que afectan la calidad del aire. En segundo lugar, utilizó los datos de estos factores para entrenar la red neuronal. Finalmente, se evaluó la prueba de evaluación del modelo de pronóstico. Los resultados mostraron que: El modelo de pronóstico mejoró la efectividad y la viabilidad y puedo proporcionar evidencias de decisiones más confiables para los departamentos de protección ambiental.

El análisis de sensibilidad demostró que los parámetros claves que describen las emisiones de amoníaco liberadas en el lodo de aguas residuales de compostaje fueron el pH y la proporción de carbono a nitrógeno (C:N).

Ruiz y col (2019) evaluaron el impacto ambiental en la calidad del aire generados por las emisiones de amoniaco procedente de una granja avícola de pollo de engorde ubicada en la vereda de Santa Bárbara en la ciudad de Tena-Cundinamarca. Mediante un sistema de modelación de dispersión atmosférica. El modelo integra las variables de temperatura y velocidad del viento para determinar los efectos de las concentraciones de amoniaco y determinar el nivel de contaminación atmosférica. Se utilizaron cuatro galpones de ambiente no controlado en el que se hicieron mediciones de las concentraciones de amoníaco en el centro de los galpones y cada 250 m siguiendo las orientaciones de acuerdo con las direcciones cardinales (norte, sur, este y oeste). Las mediciones se hicieron durante un ciclo productivo de 50 días, con tres lecturas al día (08:00, 12:00, 18:00). Se encontró que las emisiones de amoníaco estuvieron relacionadas con el ciclo reproductivo y no con las horas del día. Así mismo, la concentración de amoníaco estuvo relacionada con la temperatura, pero no con la velocidad del viento. La distancia máxima con concentraciones relevantes de amoníaco fue de 361 m, lo cual no representa una amenaza para la población aledaña.

Tong y col (2019) desarrollaron un modelo 3D de dinámica de fluidos computacional (CFD) capaz de simular el flujo de aire, el ambiente térmico y la distribución de concentración de  $\text{NH}_3$  dentro de un galpón comercial de ponedoras en cinturones de estiércol adaptado a un galpón de gran altura en un pozo profundo. Se observaron temperaturas más altas y concentraciones de  $\text{NH}_3$  en las zonas de estancamiento del aire, como los centros de los flujos de aire circulantes y los espacios cerca de las paredes de los extremos. Se encontró que la ubicación de los extractores de aire en funcionamiento afectaba significativamente las condiciones ambientales interiores. Estos resultados se pueden utilizar como una guía de operación para los galpones de ponedoras modernos con el fin de mejorar la salud de las aves y los granjeros y el rendimiento de la producción de huevos.

Recientemente se han propuesto diferentes aplicaciones de las redes neuronales para el análisis de las emisiones de amoníaco del sector de la minería (Brodny, 2020) en tierras agrícolas (Qu Y, 2019), seguimiento y control simultáneo del crecimiento y emisiones de  $\text{NH}_3$  en porcinos, así como estimaciones en la concentración de olores en gallineros (Guo Y, 2020).

En esta revisión, se evidenció una importante aplicación de las redes Neuronales artificiales en la estimación y control de  $\text{NH}_3$ , evidenciando también que el uso de las redes neuronales artificiales permite hacer modelaciones capaces de relacionar un gran número de variables, con lo cual muestran su potencial como herramientas efectivas para las estimaciones de las variables estudiadas.

### 3. Materiales y métodos

#### 3.1. Construcción de una base de datos y conjuntos de entrenamiento.

Se realizó una revisión sistemática de la literatura sobre estudios de emisiones de amoníaco en galpones avícolas tanto para aves de engorde como de postura. Se analizaron 280 artículos de la base de datos científica Scopus. Fueron recopilados los datos experimentales de estos estudios para países tanto del trópico como de la latitud norte con diversas condiciones ambientales. Con los datos de los estudios se construyó una base de datos estandarizada, obteniéndose un conjunto de datos general de 380 registros con estudios desde el año 1995 hasta la actualidad (tabla tal) . Posteriormente se realizaron dos subconjuntos para el entrenamiento de las redes (Anexo D).

**Tabla 9. Insumos utilizados para la construcción de la base de datos.**

Referencia	País	Variables evaluadas	# Registros
Chepete et al 2011.	Usa	DENS, EDAD, MAT, T, HR, , QH, pH, , H.	10
Mendes et al, 2012.	Usa	DENS, EDAD, MAT, T, HR, , QH, CP, , H.	48
Knížatová et al, 2010.	Canadá	DENS, EDAD, T, HR, QH, B.	30
Osorio et al, 2016.	Brasil	DENS, EDAD, MAT, T, QH, B.	8
Liang et al, 2005.	Usa	DENS, T, HR, , CP, H.	16
Ning, 2008.	Usa	DENS, EDAD, MAT, T, QH, H, B.	20
Fabbri et al, 2007.	Italia	MAT, T, HR, , QH, pH, , H.	12
Alberdi, 2016.	España	DENS, EDAD, MAT, T, HR, , QH, pH, , H.	10
Senyondo, 2013.	Usa	DENS, MAT, T, HR, , QH, pH, , H.	8
Pereira et al, 2018.	Portugal	EDAD, T, HR, , QH, pH, B.	24
Dekker et al, 2017	Países bajos	DENS, EDAD, T, HR, , QH, CP, H.	10

Koerkamp & Bleijenberg, 1998.	Países bajos	DENS, EDAD, T, HR, , QH, pH, CP, H.	15
Koerkamp, 1999.	Países bajos	DENS, EDAD, T, HR, , QH, pH, H.	9
Lima et al, 2015.	Brasil	DENS, EDAD, T, HR, , QH, pH, CP, H.	18
Casey et al, 2003	Usa	DENS, EDAD, T, QH, pH, B.	21
Elwinger & Svensson, 1996	Suecia	DENS, EDAD, MAT, T, HR, pH, CP, B,H.	21
Jugowar et al, 2017	Polonia	DENS, EDAD, T, HR, QH, CP,H.	13
Shepherd et al, 2015	Usa	DENS, EDAD, MAT, T, HR, H.	15
Nimmermark & Gustafsson, 2005	Suecia	DENS, EDAD, T, HR, QH, CP,H, B.	14
Zhao et al, 2015	Usa	DENS, EDAD, T, HR, QH,H, B.	12
Vučemilo et al, 2007	República checa	EDAD, T, HR, QH, B.	6
Koerkamp & Bleijenberg, 1998.	Países bajos	DENS, EDAD, T, HR, QH,CP,H.	8
Pererira, 2017	Portugal	DENS, EDAD, MAT, T, HR, QH, CP, H.	35
<b>Total de registros</b>			<b>383</b>

**Fuente:** Elaboración propia.

### 3.2. Análisis estadístico

La efectividad de cada modelo como método de estimación de las emisiones de NH<sub>3</sub>, fue evaluada utilizando un indicador estadístico que comúnmente se utiliza en la evaluación del desempeño de las redes neuronales artificiales. Este indicador es el coeficiente de correlación (*R*), el cual se estimó al final de las distintas etapas del aprendizaje.

*Coeficiente de correlación (R):*

(Ecuación 3):

$$R = \frac{\sum_{i=1}^n \sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n \sum (X_i - \bar{X})^2 (Y_i - \bar{Y})^2}}$$

En la ecuación 3,  $n$  es el número total de observaciones;  $X_i$  y  $Y_i$  son los valores observados y estimados, respectivamente.  $\bar{X}$  e  $\bar{Y}$  son los valores promedio de todas las observaciones  $X$  y estimaciones  $Y$  (Abyaneh, 2014).

Un  $R$  igual a 1, indica un ajuste perfecto entre los resultados del modelo y los valores de Emisiones de  $\text{NH}_3$  teóricos o de la literatura. Mientras que un  $R$  igual a cero, o negativo describe una correlación nula entre la predicción y la observación de las emisiones de  $\text{NH}_3$ .

Este indicador de desempeño se encuentra incluido en los códigos del perceptrón multicapa (PMC) y sus valores fueron calculados de manera automática luego del entrenamiento. Además, fue usado como criterio de comparación de las distintas arquitecturas de la red. El modelo con el cual se obtuvieron los valores más altos del coeficiente de correlación (calculados de manera simultánea para las cuatro fases del aprendizaje), fue elegido como el más adecuado para hacer estimaciones de  $\text{NH}_3$

### **3.3. Diseño de una Red Neuronal Artificial para la estimación de las concentraciones de Amoniaco**

Para el entrenamiento de los modelos neuronales artificiales propuestos usando redes de perceptrón multicapa (PMC), se elaboraron códigos computacionales en lenguaje de programación M, propio del software MATLAB®, licenciado para ser usado en la Universidad Nacional de Colombia. Adicionalmente, las diversas tipologías de arquitecturas de las redes multicapas y sus algoritmos de aprendizaje, fueron entrenadas y evaluadas en su desempeño (capacidad de hacer las estimaciones) usando la biblioteca y funciones disponibles en el NEURAL NETWORK TOOL BOX, del software

mencionado. Las simulaciones de las tipologías de redes propuestas, para los subconjuntos establecidos en el conjunto de entrenamiento, se hicieron usando el simulador SIMULINK®, también dispuesto en el software MATLAB®.

### 3.4. Variables de entrada o entrenamiento

Las variables de entrada fueron seleccionadas enfocando las variables de medición in situ con el fin de aplicar futuramente la red para trabajos de automatización. Se eligieron las variables más recurrentes e importantes para el proceso de volatilización reportadas en la literatura que se muestran en la tabla 9. Algunas variables se descartaron por ensayo y error. Una vez la red neuronal fue entrenada con la totalidad de las variables, fue reentrenada, repitiendo el procedimiento hasta obtener un error aceptable con el menor número de variables (Suárez, 2009).

**Tabla 10. Variables incorporadas en la base de datos para el entrenamiento de la Red Neuronal Artificial.**

Grupo	Concepto	Variable	Unidad	Símbolo	Representación en la base de datos
Tipo de producción	Ponedoras en piso	Tipo I	-	TPR-1	[1 0 0]*
	Ponedoras en Jaula	Tipo II		TPR-2	[0 1 0]*
	Engorde en piso	Tipo III		TPR-3	[0 0 1]*
Postura o engorde	Postura	Tipo I	-	POE-1	[1 0]*
	Engorde	Tipo II		POE-1	[0 1]*
Densidad animal	Densidad animal	Cantidad	Aves/ m <sup>2</sup>	DENS	Numérica real

Edad	Edad	Cantidad	Días	EDAD	Numérica real
Humedad relativa ambiental	Humedad relativa ambiental	Cantidad	%	HR	Numérica real
Temperatura ambiental	Temperatura ambiental	Cantidad	°C	T	Numérica real
Flujo de aire	Flujo de aire	Cantidad	m <sup>3</sup> h <sup>-1</sup> ave <sup>-1</sup>	QH	Numérica real
pH estiércol	pH estiércol	Cantidad	pH	pH	Numérica real
Tiempo de acumulación del estiércol	Tiempo de acumulación del estiércol	Cantidad	Días	MAT	Numérica real
Raza avícola	Hy Line	Raza 1	-	RAZ- 1	[1 0 0 0]*
	Ross 208	Raza 2		RAZ-2	[0 1 0 0]*
	Cobb 500	Raza 3		RAZ-3	[0 0 1 0]*
	Lohman	Raza 4		RAZ-4	[0 0 0 1]*
Tipo de beneficio	Postura	Gallina	-	H	[1 0 ]*
	Ceba	Pollo		B	[0 1 ]*
Tipo de cama utilizada	Pozo profundo	Ti Tipo I	-	TC-1	[1 0 0]*
	Bandeja	Tipo II		TC-2	[0 1 0]*
	Cama Vegetal	Tipo III		TC-3	[0 0 1]*
Tipo de ventilación	Cruzada-presión positiva	Tipo I	-	TQ-1	[1 0 0 0]*
	Descendente-presión positiva	Tipo II		TQ-2	[0 1 0 0]*

	Cruzada-presión negativa	Tipo III		TQ-3	[0 0 1 0]*
Emisión de amoniaco a estimar	Rata de emisión de amoniaco a estimar	Cantidad	$g \cdot NH_3$ $d^{-1} \text{ hen}^{-1}$	ER	Numérica real

**Fuente:** Elaboración propia. **Nota:** Variables discretas o codificadas, y para cada caso, son mutuamente excluyentes

### 3.5. Arquitectura de la red neuronal

El número de capas se determinó siguiendo el procedimiento de Cortina (2012). Se inició el entrenamiento de la red con una capa oculta. Se hicieron varias pruebas, luego se realizaron ensayos con 10 neuronas en la capa oculta, hasta llegar al doble de la cantidad de patrones de entrada (20 neuronas en la capa oculta) como lo recomienda (Hecht, 1997). El proceso se repitió desde una capa oculta hasta un número de capas ocultas igual al número de variables de entrada utilizando un algoritmo que automatizó el entrenamiento de la red. Las arquitecturas de red que arrojaron los mejores coeficientes de correlación (R) fueron las escogidas para el posterior entrenamiento de éstas.

### 3.6. Entrenamiento de la red neuronal

#### Algoritmo de aprendizaje

Con la finalidad de aprovechar la capacidad de las redes neuronales artificiales de aprender relaciones complejas, se analizaron 12 tipos de algoritmos de aprendizaje para cada arquitectura de la red mediante el algoritmo de automatización. Las redes neuronales que mejores resultados obtuvieron fueron las entrenadas con el algoritmo de

levenberg-marquardt, obteniendo un coeficiente de correlación lineal (R) de 0.99 y 0.98 indicados en las tablas 12 y 13.

### **Función de Activación**

Se utilizaron las funciones de activación configuradas por defecto, la función logística o sigmoidea para las capas ocultas, y la función lineal para la capa de salida.

### **Datos de entrenamiento, validación y test**

Se compararon los datos simulados con los datos de entrenamiento, mediante la técnica cross-validation, para ser representado de forma gráfica (Cervantes, 2013). Se utilizó la técnica cross-validation, dividiendo las mediciones en diferentes conjuntos de datos; 70 % para un conjunto de entrenamiento: para el ajuste de los pesos de la red. 15% para un conjunto de validación: para realizar iteraciones posteriores al entrenamiento y constatar el sobre-aprendizaje. Por último 15% para un conjunto de prueba.

## **4. Resultados y discusión**

### **4.1. Resultados de la construcción de la red neuronal**

Fueron elaboradas y entrenadas dos redes neuronales, de acuerdo con el procedimiento descrito en esta investigación. Las variables de cada red se especifican en la tabla 11.

**Tabla 11. Variables evaluadas en cada red neuronal.**

RNA	ENTRADAS	SALIDA
RNA_1	TPR, RAZ, TC, POE, DENS, TI, HR, PH.	ER-NH <sub>3</sub>
RNA_2	TPR, RAZ, TC, POE, EDAD, TI, HRI, TQ, QH, CPD, MAT.	ER-NH <sub>3</sub>

**Fuente:** Elaboración propia.

El método de levenberg-marquardt fue el elegido ya que obtuvo el mayor coeficiente de correlación utilizando la menor cantidad de neuronas en cada capa, además fue el método que menor tiempo de procesamiento tuvo con relación los demás, permitiendo una mayor exactitud para las predicciones con el menor uso de recursos (tabla 12).

**Tabla 12. Coeficientes de correlación lineal de diferentes arquitecturas de RN\_1 usando diferentes algoritmos de entrenamiento. Fuente: Elaboración propia.**

Método	Arquitectura			
	1 capa		2 capas	
	5 neuronas	20 neuronas	5 neuronas en cada capa	20 neuronas en cada capa
trainlm	0.979	0.981	<b>0.982</b>	<b>0.990</b>
trainbr	NR	NR	NR	NR
trainbfg	0.911	0.968	0.974	0.983
trainrp	0.966	0.961	0.965	0.975
trainscg	0.910	0.984	0.977	0.984
traincgb	0.967	0.972	0.979	0.981
traincgf	0.994	0.989	<b>0.982</b>	<b>0.990</b>
traincgp	0.970	0.983	0.966	0.975
trainoss	0.941	0.950	0.978	0.980
traingdx	0.944	0.976	0.988	0.981
traingdm	0.865	0.904	0.955	0.965
traingd	0.784	0.952	0.724	0.939

La arquitectura que obtuvo mejor coeficiente de correlación R (tabla 13) fue la conformada por una capa de entrada, una primera capa oculta con 9 neuronas, una segunda oculta con 9 neuronas, y una de salida con una única neurona correspondiente al valor de las emisiones de NH<sub>3</sub> (Tabla 13).

**Tabla 13. Coeficientes de correlación lineal de diferentes arquitecturas usando levenberg-marquardt. Fuente: Elaboración propia**

CONJUNTO	ENTRENAMIENTO R <sup>2</sup>	PRUEBA R <sup>2</sup>	validación R <sup>2</sup>	TOTAL R <sup>2</sup>
Arquitectura de la RNA*				
[05 05]	0.9688	0.95696	0.9876	0.97345
<b>[09 09]</b>	<b>0.98978</b>	<b>0.99488</b>	<b>0.99689</b>	<b>0.99042</b>
[10 10]	0.98407	0.97929	0.95644	0.9742
[20 20]	0.97718	0.93265	0.99646	0.9901
[30 30]	0.97714	0.98904	0.98419	0.97495
[30 20]	0.94453	0.99236	0.9984	0.95679
[30 10]	0.98816	0.91151	0.91909	0.9723
[30 05]	0.97086	0.99803	0.96368	0.97417

La arquitectura de la red neuronal que mejor desempeño obtuvo se presenta en la figura 11.

Figura 11. Arquitectura de las redes neuronales seleccionadas para el estudio.


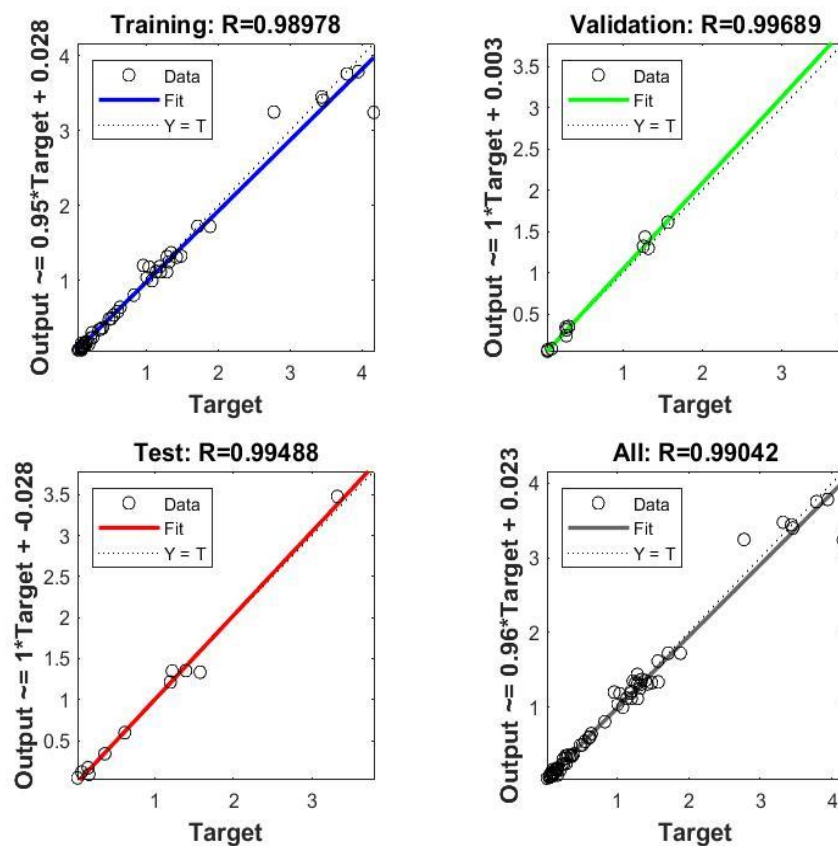


Figura 11. a. arquitectura de la red neuronal RN\_1 de 21 variables de entrada, 2 capas ocultas de 9 neuronas cada una y una capa de salida b. Arquitectura de red neuronal RN\_2 de 23 variables de entrada, 2 capas ocultas de 9 neuronas cada una y una capa de salida.

## Desempeño de la red Neuronal

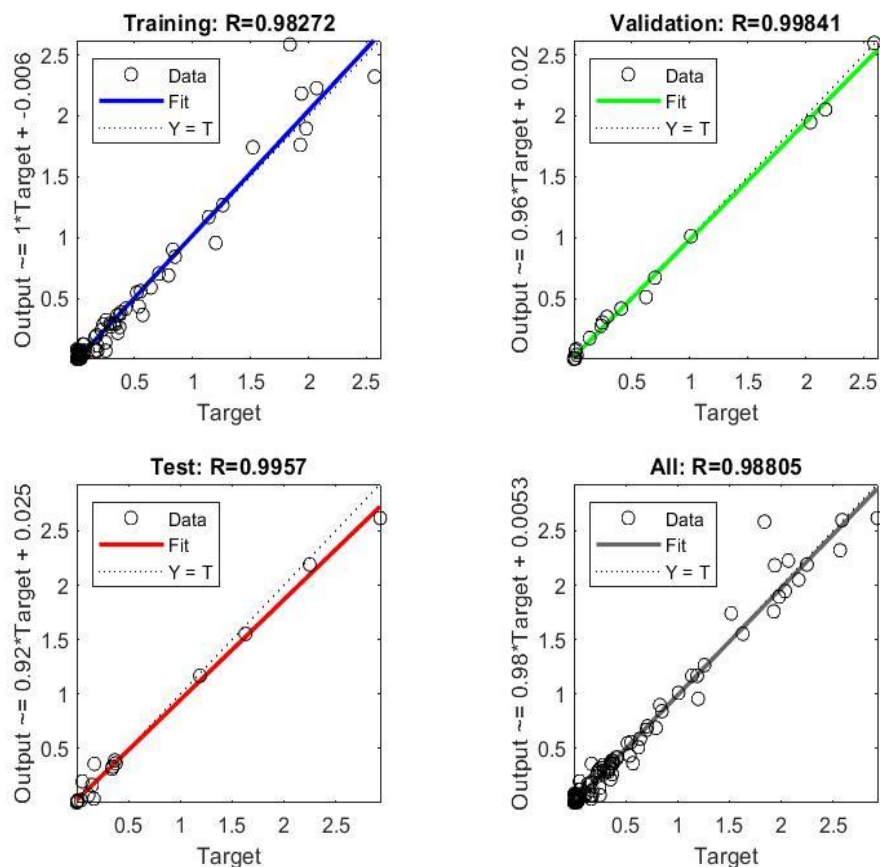
Las Figuras 12 y 13 muestran los resultados de desempeño de las redes neuronales seleccionadas en ambos casos de estudio y para cada una de las etapas de entrenamiento de esta (entrenamiento, prueba, validación computacional y simulación con todo el conjunto de entrenamiento). Las redes seleccionadas estimaron las emisiones de  $\text{NH}_3$  de salida y realizaron una comparación entre el resultado obtenido por la red neuronal artificial (output) y el valor teórico o de los experimentos que conforman la base de datos, asociando a dicha comparación el factor de correlación lineal R.

**Figura 12. Resultados de desempeño para la red neuronal artificial RNA-1 entrenada para estimar las emisiones de NH<sub>3</sub>. Fuente: Elaboración propia.**



**Nota:** se muestra el coeficiente de correlación R entre las emisiones de NH<sub>3</sub> obtenidas en la literatura y el estimado por el modelo neuronal (RNA-1), para cada fase del aprendizaje (entrenamiento, prueba, validación y simulación con todos los datos) Fuente: elaboración propia.

**Figura 13. Resultados de desempeño para la red neuronal artificial RNA-2 entrenada para estimar las emisiones de NH<sub>3</sub>. Fuente: Elaboración propia.**

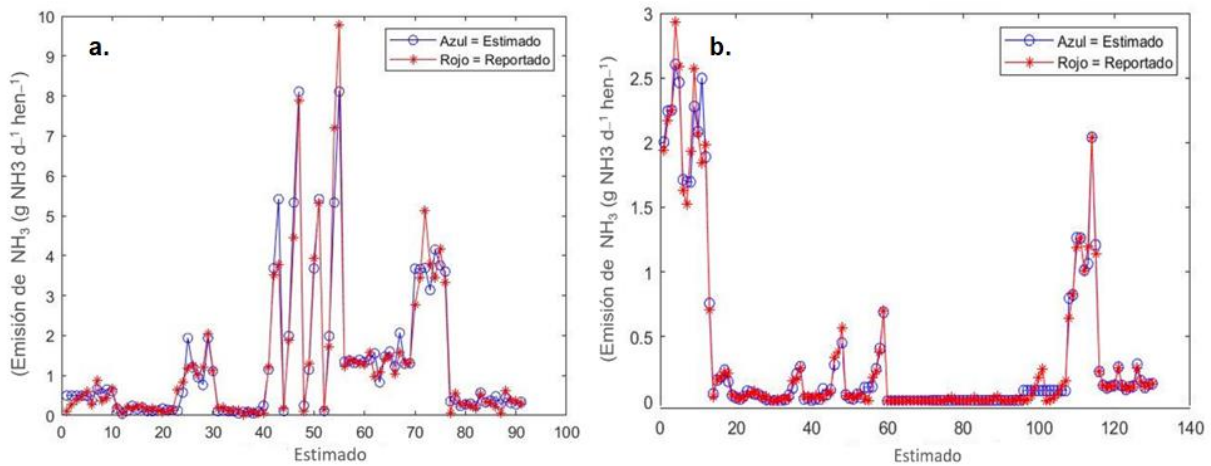


**Nota:** se muestra el coeficiente de correlación R entre las emisiones de NH<sub>3</sub> obtenidas en la literatura y el estimado por el modelo neuronal (RNA\_2), para cada fase del aprendizaje (entrenamiento, prueba, validación y simulación con todos los datos) Fuente: elaboración propia.

En las figuras 12 y 13 se observa la presencia de algunos datos dispersos que se salen del patrón de comportamiento, aunque no se afirma que sean anómalos, pueden ser identificados para su exclusión en las bases de datos, permitiendo la repetición del proceso de simulación y la reducción del error. Es importante mencionar que en la base de datos de entrenamiento utilizada es posible eliminar los registros que contienen estos datos, mediante la aplicación de otras técnicas diseñadas para tal fin en la herramienta

computacional de las redes neuronales artificiales, e incluirlas en el algoritmo elaborado (Valdés & González 2011).

**Figura 14. Comportamiento en la fase de validación computacional de las Redes Neuronales Artificiales. Fuente: Elaboración propia.**



Para las dos redes neuronales se observó un comportamiento equivalente a la tendencia de los datos teóricos. La RN\_1 mostró un mejor desempeño en la predicción de las emisiones de amoníaco, la mayor concentración de los datos se dio en emisiones de entre 0 y 1  $\text{g NH}_3 \text{ d}^{-1} \text{ hen}^{-1}$  mostrando el mejor comportamiento en la fase de validación en este rango ver figura 14.

## **4.2. Estimaciones de las emisiones de NH<sub>3</sub> arrojadas por la red neuronal (análisis de las variables de estudio).**

Los resultados y análisis de las emisiones de NH<sub>3</sub> que a continuación se presentan provienen de las predicciones realizadas por la red neuronal propuesta y validada en éste trabajo.

### **4.2.1. Efecto de la edad de las aves sobre las emisiones de NH<sub>3</sub>.**

Al igual que (Wood, 2015; Mendes et al, 2012) las predicciones evidenciaron que la edad tiene incidencia sobre la cantidad de amoniaco emitida al ambiente tanto en las aves de postura como de engorde siguiendo un patrón exponencial.

En las aves de postura se observó un incremento progresivo del factor de emisión de amoniaco desde las primeras semanas en el periodo de cría (figura 15), el comportamiento persistió en el periodo de levante y desarrollo, las emisiones se estabilizaron alrededor del día 150 (semana 21) tiempo cercano al inicio del periodo de postura (Koerkamp y Bleijenberg, 1998), cuando las aves se encuentran desarrolladas y la variación del peso de estas se estabiliza. Aunque Koerkamp & Bleijenberg (1998) encontraron que la estabilización de las emisiones de NH<sub>3</sub> a partir de los 175 día (25 semanas) de edad puede atribuirse a que en ese periodo los cambios en la composición de la cama (especialmente el contenido de materia seca y concentración de TAN) se estabilizan debido a la uniformidad en la composición de las deyecciones.

El aumento en la agitación de la cama por una mayor actividad de baño de polvo por parte de las aves a partir de las 20 semanas también podría explicar el pico de aumento en la emisión de amoníaco para las aves en piso, mientras que la remoción de la cama generalmente a las 34 semanas puede ser la causa de la disminución de la emisión de amoníaco para el final del ciclo productivo (Koerkamp y Bleijenberg, 1998).


El máximo de las emisiones de amoníaco  $4.35 \text{ g NH}_3 \text{ d}^{-1} \text{ hen}^{-1}$  se registró en el día 160 igual a lo reportado por (Pereira et al., 2018). En las aves de engorde las emisiones incrementaron durante todo el periodo productivo con la edad de las aves, sin presentar descenso al final de la etapa similar a los registros de (Vučemilo et al, 2007; Wood, 2015), debido al constante incremento del peso vivo hasta el final de la producción, a diferencia de las aves de postura.

### **Aves de engorde**

La ración alimenticia de las aves de engorde también es incrementada progresivamente durante todo su ciclo productivo lo que resulta en una mayor cantidad de deyecciones que podría también explicar el mayor aumento de las emisiones de amoníaco entre el día 30 y el día 40 (Knížatová et al, 2010).

En las aves de engorde a pesar de tener un metabolismo más acelerado y mayor conversión de alimento, no se alcanzan niveles tan altos en las emisiones de  $\text{NH}_3$ , esto puede deberse a que la cama no sufre una acumulación importante y compactación del estiércol debido a que se renueva terminado el ciclo de 45 días, pero según la tendencia si se acumulara el estiércol de 3 parvadas en 150 días se generarían valores más altos de amoníaco que en las aves de postura en el mismo tiempo.

**Figura 15. Efecto de la edad de las aves sobre las emisiones de NH<sub>3</sub> para tres tipos de producciones avícolas**



**Fuente:** Elaboración propia. **Nota:** Para aves de engorde e piso el ciclo productivo se tomó hasta los 45 días y en las gallinas el periodo de postura inicia alrededor del día 150.

#### 4.2.2. Efecto de la densidad de las aves en las emisiones de NH<sub>3</sub>.

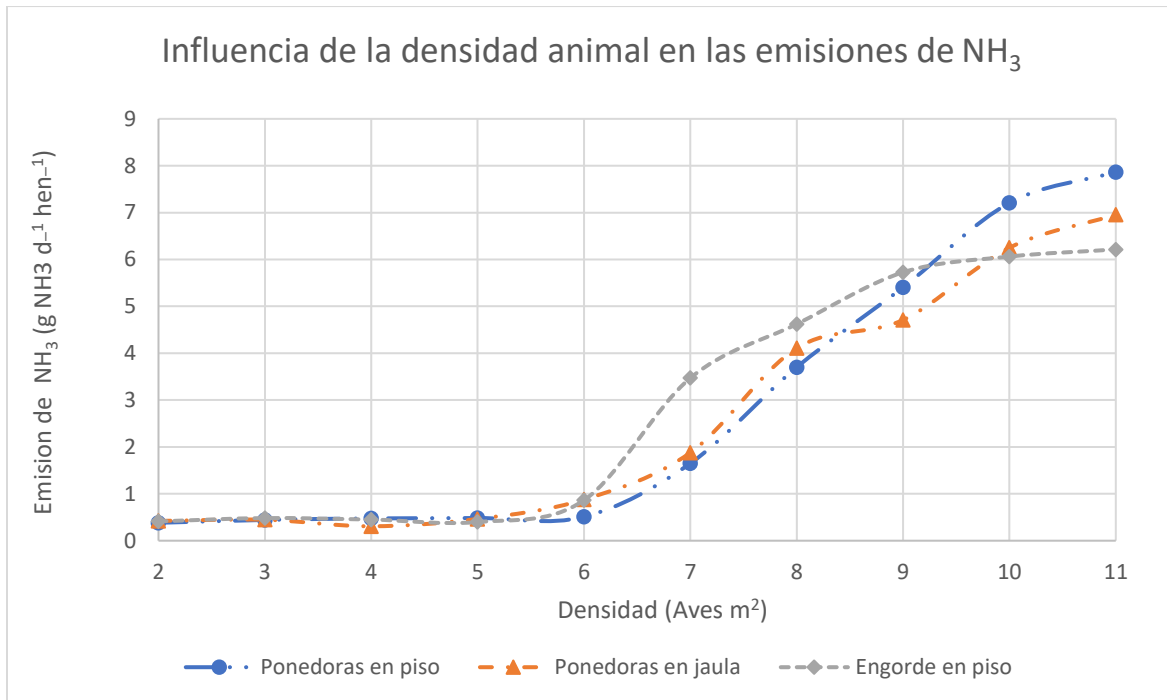
En la figura 16 se observó un aumento muy importante de las emisiones a partir de densidades de 5 aves/m<sup>2</sup> tanto para aves de postura como de engorde similar a lo reportado por Kang y col (2016). Reiter y Bessei (2000) en su estudio también encontraron diferentes temperaturas de la cama en diferentes densidades de población de pollos de engorde y concluyeron que a mayor densidad habrá una mayor cantidad de deyecciones y un mayor contacto de las aves con la cama, mayor compactación y

transferencia de calor, lo que genera como resultado una mayor actividad microbiana y una mayor degradación de ácido úrico y proteínas a  $\text{NH}_3$  (Coufal et al, 2006). Hay que tener en cuenta que las aves de engorde poseen una talla más alta que las aves de postura, por lo que su consumo de alimento y deyecciones son mayores, no obstante los ciclos productivos en las gallinas ponedoras son mucho más largos por lo que los procesos de descomposición de la cama son más desarrollados  $\text{NH}_3$  (Coufal et al, 2006).

Kang y col. (2016) encontraron que las emisiones de  $\text{NH}_3$  fueron mayores ( $P < 0.01$ ) para densidades de 10 aves /  $\text{m}^2$  que para densidades 5, 6 y 7 aves/  $\text{m}^2$ . Además, a medida que aumentaba la densidad de población, la cantidad de cama apelmazada junto con las plumas aumentó significativamente por lo que una mayor densidad de población aumenta el nivel de nitrógeno y humedad en la cama y, por lo tanto, favorece la actividad microbiana. Por lo anterior se hace necesario optimizar la densidad poblacional de las aves para ayudar a limitar el exceso de humedad en la caseta, reduciendo así los procesos anaeróbicos que favorecen la generación de  $\text{NH}_3$  (Gonzales y García, 2019).

En la figura se observa que a partir de 7 aves/ $\text{m}^2$  el aumento de  $\text{NH}_3$  es considerable sobre todo en aves de postura por lo que éste valor de densidad podría ser óptimo para evitar el exceso de  $\text{NH}_3$  (Kang et al, 2016).

**Figura 16. Efecto de la densidad de las aves en las emisiones de NH<sub>3</sub> para tres tipos de producción avícolas.**



**Fuente:** Elaboración propia. **Nota:** Las densidades corresponden a aves en periodo de postura 150 días de edad y en aves de engorde en piso con 45 días.

### 4.2.3. Efecto de la Temperatura al interior del galpón en las emisiones de NH<sub>3</sub>.

La tendencia en los tres tipos de producción fue similar con una mayor incidencia de la temperatura en los sistemas de producción en piso (ver figura 17). Esto puede deberse a que la cama se encuentra en contacto con las aves y debido a su capacidad aislante retiene el calor favoreciendo temperaturas normales de 20 a 32°C dependiendo de la semana de crianza, lo que hace un hábitat óptimo para bacterias, sobre todo, las mesófilas o microaerofilas (Castro, 2018).

Se presentó un incremento importante en la tasa de emisiones de NH<sub>3</sub> a partir de los 22°C en todos los casos. Senyondo (2013) reportó que las emisiones de amoníaco aumentaron

un 55% al aumentar la temperatura de 10°C a 23°C y un 70% al aumentar la temperatura de 23 a 31°C en aves de engorde, similar a los valores de este estudio.

La temperatura ambiente cuando se transfiere al suelo puede estimular la actividad microbiana en la cama, lo que aumenta el potencial de degradación enzimática del ácido úrico y las proteínas a  $\text{NH}_3$  (Coufal et al, 2006). Aunque el fenómeno de difusión de amoníaco gaseoso es complejo y depende de factores microbianos o enzimáticos y fenómenos de transferencia de masa en la superficie de la cama, ambos influenciados de forma distinta por las condiciones analizadas en este estudio.

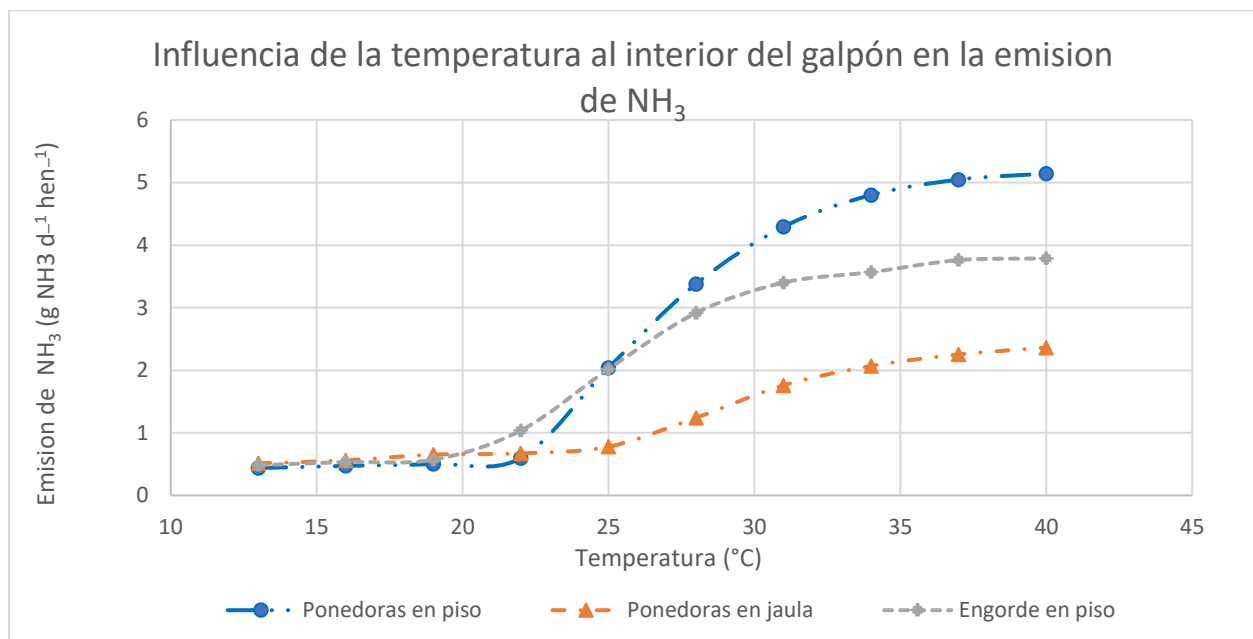
El aumento de la temperatura del aire circundante en el interior del galpón genera como resultado una tendencia decreciente en la concentración de amoníaco al interior de éste (Zheng, 2020). Estas bajas concentraciones se pueden explicar debido a que las altas temperaturas y velocidades de viento facilitan la pérdida de vapor de agua en la superficie del estiércol disminuyendo la humedad en la capa superficial del estiércol, afectando negativamente el equilibrio en la fase acuosa en la superficie y la difusión del amoníaco al medio (Tong, 2020).

Sin embargo, en el caso de las emisiones el comportamiento es contrario, como se observa en la figura 17, esto se debe a que el aumento en la ventilación por la necesidad de retirar el exceso de calor resulta en un mayor flujo de amoníaco liberado al exterior (Knížatová, 2010; Zheng, 2020).

Autores como (Coufal et al, 2006; Redwine et al, 2002) registraron cambios estacionales similares en las emisiones. Las concentraciones más altas de amoníaco se dieron en las parvadas criadas durante "otoño" y "otoño / invierno" donde se registran temperaturas

ambientales más bajas y emisiones de  $\text{NH}_3$  al ambiente más bajas comparadas con las temporadas más cálidas "primavera / verano" y "verano" atribuidas a la menor tasa de ventilación. En verano donde las concentraciones son más bajas y se reportan temperaturas medias más elevadas, se informan tasas de emisión generalmente más altas y lo atribuyen a la mayor capacidad de ventilación, incluso siendo las concentraciones más bajas en esta época del año (Liang et al, 2003).

**Figura 17. Efecto de la Temperatura al interior del galpón en las emisiones de  $\text{NH}_3$  para tres tipos de producción diferentes.**



**Fuente:** Elaboración propia.

#### 4.2.4. Efecto de la Humedad relativa al interior del galpón en las emisiones de $\text{NH}_3$ .

Se observó una relación directamente proporcional entre la humedad relativa HR y las emisiones de  $\text{NH}_3$ , mostrando un crecimiento mayor desde el inicio hasta acercarse al


70% de humedad relativa, ya que el aumento de la HR en el aire puede incrementar significativamente la emisión de amoníaco y la concentración de amoníaco en el aire de salida (Méda et al, 2011).

Algunos autores afirman que la la humedad relativa no se correlaciona directamente con las emisiones de  $\text{NH}_3$ , pero si Afecta indirectamente al contenido de materia seca del estiércol y, posteriormente a las emisiones generadas (Herrera et al, 2013; Rosa et al, 2019).

Una alta humedad relativa en el interior de los galpones de aves provoca un aumento de la humedad de la cama y, en consecuencia, una mayor volatilización del  $\text{NH}_3$  como es el caso de este estudio (Castro, 2018). Una alta humedad de la cama genera una mayor probabilidad de la proliferación de microorganismos, ésta es la causa número uno de la volatilización del amoníaco y uno de los factores ambientales y de rendimiento más graves que afectan la producción principalmente de pollos de engorde por lo que controlar la humedad del de la cama o del estiércol es el paso más importante para evitar problemas con el amoníaco (Méda et al, 2011; Castro, 2018).

La disminución de las emisiones de  $\text{NH}_3$  en los valores más altos de humedad relativa, es decir mayores al 80% puede deberse a la saturación del aire que afecta el fenómeno de difusión del amoniaco y al hecho de que camas muy húmedas en la superficie reducen el intercambio gaseoso con el medio debido a la fuerte afinidad disociativa del amoníaco en el agua (Medeiros et al, 2008) sumado al hecho de que la actividad microbiana y enzimática se reduce debido a la escasez de oxígeno (Liu et al, 2006).

**Figura 18. Efecto de la Humedad relativa al interior del galpón en las emisiones de NH<sub>3</sub>. para tres tipos de producción diferentes.**




Fuente: Elaboración propia.

#### 4.2.5. Ventilación y Emisiones de NH<sub>3</sub>.

La tasa de ventilación a través de una fuente de emisión de NH<sub>3</sub> es uno de los dos elementos esenciales para cuantificar las tasas de emisión, siendo el otro elemento la concentración de la sustancia en cuestión (Li, 2006). La ventilación es un factor que influye en una importante medida en el flujo de amoníaco que se libera al ambiente ya que ambas están directamente relacionadas, una alta remoción o tasa de recambio del aire del galpón genera un mayor arrastre o emisión de NH<sub>3</sub> gaseoso al ambiente (Miles et al, 2012). Los picos de emisiones de amoníaco coincidían con los picos en las altas tasas de ventilación (fig.20), pero no con los picos de concentración de amonio en el interior del galpón (fig.19), por lo que se concluye que no necesariamente altas


concentraciones de amoniaco van a generar altas emisiones o liberación al ambiente (Miles et al, 2012; Zhao et al, 2015; Alberdi et al, 2016).

**Figura 15. Efecto del Flujo de aire al interior del galpón en las concentraciones de NH<sub>3</sub> en el interior del galpón para tres tipos de producción diferentes.**



Fuente: Elaboración propia.

**Figura 16. Efecto de la Flujo de aire al interior del galpón en las emisiones de NH<sub>3</sub> para tres tipos de producción diferentes.**




Fuente: Elaboración propia.

La ventilación se utiliza para mejorar la calidad del aire, en el caso del amoniaco para retirar el exceso en la concentración, pero al aumentar la ventilación las emisiones de  $\text{NH}_3$  aumentan debido al aumento en el gradiente de concentración entre la superficie del estiércol y el aire circundante (Li, 2006). Por su parte Liu y col (2008) argumentan que al aumentar el flujo de aire sobre la superficie de la cama se reduce el grosor de la capa límite (entre las fases líquida y gaseosa), lo que da como resultado una mayor tasa de liberación de masa. Por lo tanto, optimizar el flujo de aire en un mínimo necesario puede reducir la emisión de amoniaco al ambiente sin que las personas y los animales se vean afectados por la concentración de  $\text{NH}_3$  (Li, 2006).

Inclusive en invierno donde las concentraciones de amoniaco pueden ser mayores que en otros climas, se registraron tazas de emisión más bajas  $0.094 \text{ g NH}_3 \text{ d}^{-1} \text{ hen}^{-1}$  frente a las  $0.168 \text{ g NH}_3$  en verano, donde por temas de temperatura el flujo en la ventilación se aumentó de  $2.2$  a  $6.6 \text{ m}^3 \text{ h}^{-1} \text{ ave}^{-1}$  por lo que el aumento en el flujo de aire incrementó las emisiones en un 56 % (Alberdi et al, 2016).

**Figura 17. Efecto del tipo de ventilación en las emisiones de NH<sub>3</sub> en gallinas ponedoras Hy-Line en un sistema de producción en piso.**



**Fuente:** Elaboración propia.

Los diferentes tipos de ventilación y control del clima para los galpones avícolas también pueden ocasionar diferencias en las concentraciones de olores y amoníaco dentro de los galpones, así como diferencias en las emisiones de olores y amoníaco (Nimmermark & Gustafsson, 2005). En el caso de este estudio la ventilación cruzada positiva fue el mecanismo que más emisiones generó, mientras que el flujo de aire descendente positivo tuvo una reducción importante (Figura 21). Esto puede deberse a que cambios en la velocidad y la forma como incide el viento en la superficie de la cama puede favorecer la difusión o coeficiente de NH<sub>3</sub> gaseoso entre la capa límite y el ambiente (Liu et al, 2008; Rong et al, 2009). Dependiendo de la configuración del sistema de ventilación se pueden dar diferentes dinámicas de flujo y el cambio de condiciones de flujo laminar a turbulento

que reduce el grosor de la capa límite en la interfaz gas-líquido y da como resultado una mayor transferencia de masa de la fase líquida a la gaseosa (Rong et al, 2009).

También puede variar la distribución de  $\text{NH}_3$  dentro del galpón dependiendo del tipo de ventilación. La ventilación cruzada por ejemplo da como resultado concentraciones más altas de  $\text{NH}_3$  cerca de los escapes y menos  $\text{NH}_3$  concentraciones cerca de las entradas de aire en galpones de engorde y ponedoras. Las aves almacenadas cerca de los escapes pueden tener más problemas de salud y un rendimiento de producción deficiente en comparación con las aves almacenadas cerca de las entradas de aire (Tong et al., 2019).


#### **4.2.6. pH y emisiones de $\text{NH}_3$**

En este estudio al igual que lo reportado por Tong (2020), la tasa de emisión de  $\text{NH}_3$  tuvo una relación directamente proporcional al pH del estiércol obteniendo las mayores emisiones para valores de pH más altos (ver figura 22), además, el comportamiento de las curvas para gallinas ponedoras registradas en este estudio se asemejan a lo reportado por Tong (2020). En general el pH de la cama también fue proporcional a la cantidad de emisiones de  $\text{NH}_3$  para aves de engorde (Toghyani et al, 2010).

Aunque el pH de la gallinaza se encuentra entre 8-9 y el de la pollinaza está alrededor de 9.5 (Pareja, 2005), cuando se inicia el ciclo productivo en los sistemas de piso el pH de la cama es ácido debido a que la viruta de pino tiene un pH de 6 y la cascarilla de arroz pH 6,9), aumentando durante el transcurso de la camada, convirtiéndose en un medio básico (pH 7-10). Conforme aumenta el pH aumenta la producción de amoníaco volátil (pH 11), que alcaliniza el medio. No obstante cuando el pH permanece más bajo

(alrededor de 9) hay mayor actividad de la uricasa y mayor producción de ión amonio, que permanece en la cama (Peche, 2014). Lo que podría explicar la menor generación de  $\text{NH}_3$  en las aves de engorde al tener camas con un pH de carácter más básico.

**Figura 18. Efecto del pH de la cama aviar en las emisiones de  $\text{NH}_3$  para tipos de lechos diferentes.**



El cambio en el pH depende de factores como la edad de las aves, la temperatura de la cama, la temperatura ambiente y la densidad de las aves (Menegali et al., 2012).

Se registraron bajas emisiones de  $\text{NH}_3$  en valores de pH bajos, entre 6 y 7.5, el comportamiento se debe a que la acidificación de la cama disminuye la concentración de amoníaco ( $\text{NH}_3$ , aq, m) en el estiércol (Pezzuolo et al, 2019). Lo que coincide con los menores niveles de  $\text{NH}_3$  registrados en este estudio.

Se observó que la liberación de amoníaco se maximizó a niveles de pH superiores a 7,5 (Lima et al, 2015). Esto puede explicarse porque lechos de estiércol a temperaturas entre

10 y 30 ° C y pH 7, tienen menos del 1% del nitrógeno amoniacal total ( $\text{NH}_4^+$ , aq, m +  $\text{NH}_3$ , aq, m) presente como  $\text{NH}_3$  en fase acuosa ( $\text{NH}_3$ , aq, m). Mientras que esta proporción puede cambiar y exceder el 50% cuando el pH se aumenta a valores de 10 (Ecetoc, 1994), siendo este valor de pH donde se registraron las mayores tasas de emisión de  $\text{NH}_3$  en este estudio.

El aumento de temperatura y neutralización del pH de las camas donde se utiliza viruta de madera o cascarilla de arroz proporcionan entonces una mayor actividad microbiana y la formación de gases nocivos, además que el uso de estos materiales en la cama también puede afectar la humedad y la dinámica entre las fases (Calvet et al, 2011). Por lo tanto, la cantidad y calidad de la cama afecta la capacidad de las emisiones de  $\text{NH}_3$  de los gallineros de engorde, de ahí la importancia de la reposición del material en mal estado (Toghyani et al, 2010).

El pH de la cama proporciona un impacto creciente en la reacción de degradación de los compuestos nitrogenados lo que hace que la cama tienda a ser alcalina (Lima et al., 2015), esto junto con la capacidad tampón de las deyecciones permite compensar la acidificación derivada del proceso de fermentación anaerobia y la disminución en el pH del estiércol debido a la pérdida de  $\text{NH}_3$  observado por Ghaly y Alhattab (2013).

En los últimos años, se han utilizado con frecuencia métodos físicos, químicos y biológicos, para reducir la producción de  $\text{NH}_3$  en las camas avícolas estudiados por diferentes investigadores (Pezzuolo et al, 2019).

Con el fin de controlar el pH en la cama se han utilizado compuestos como cal, zeolita, bisulfato de sodio, sulfato de aluminio arcilla con ácido sulfúrico, ácido fosfórico, cloruro

de aluminio, superfosfato y bisulfuro de sodio para reducir el pH de la basura, la volatilización del amoníaco e inhibir actividad microbiana (Pezzuolo et al, 2019) Pero la mayoría de estos químicos son corrosivos y pueden contaminar el agua.


También se utilizan tratamientos biológicos como Inhibición competitiva (*Bacillus subtilis*) y otros probióticos en la cama con importantes reducciones en la producción de  $\text{NH}_3$ , pero no son tan efectivos como los métodos convencionales (Pezzuolo et al, 2019).

#### **4.2.7. Ingesta de proteína y Emisión de $\text{NH}_3$**

Las emisiones de amoniaco tuvieron una tendencia de crecimiento lineal, con respecto al porcentaje de proteína en la ingesta de las aves de postura. Una mayor ingesta de proteína genera unas deyecciones con mayor contenido de compuestos nitrogenados que pueden ser degradados y convertidos finalmente en  $\text{NH}_3$  (ver figura 23). La reducción de la proteína cruda en aproximadamente un 1% en la dieta llevó a una reducción de aproximadamente un 10% en la emisión de amoníaco en razas pesadas como la Ross (Liang et al, 2004).

Mientras que se reportan pérdidas totales de  $\text{NH}_3$  de un 8% menor por cada 10 g/ kg menos en la composición proteica en la dieta de ponedoras livianas, similar a lo reportado encontrado en las líneas estudiadas (Hy-Line y Lohman) (van Emous, 2019).

**Figura 19. Influencia de la ingesta de proteína en las emisiones de NH<sub>3</sub> para cuatro razas diferentes.**



**Fuente:** Elaboración propia. **Nota:** Las razas Ross 308 y Cobb 500 de engorde se analizaron a los 25 días de edad mientras que las de postura Hy Line y Lohman fueron simuladas a los 150 días de edad.

La diferencia entre las aves de postura puede deberse a que las líneas pesadas consumen más alimento y generan una mayor cantidad de deyecciones en comparación con las líneas semi-pesadas o livianas, generando una mayor acumulación de los precursores de NH<sub>3</sub> y por ende mayores emisiones de NH<sub>3</sub>.

En el caso de los pollos de engorde, durante su crianza en promedio cada ave produce unos 2 kg de estiércol, que es depositado y mezclado en la cama, aportándole un alto contenido de nitrógeno, principalmente ácido úrico (70 %) y proteínas no digeridas, por lo que evitar que el animal consuma más proteína de la que puede asimilar puede contribuir a que se forme menos amoniaco por medio de microorganismos y enzimas, el

cual se volatiliza, pasa al ambiente y tiene efectos muy negativos sobre los pollos (Peche, 2014).

En cuanto a las curvas de emisión de  $\text{NH}_3$  se encontraron reducciones de alrededor de 9% menor por cada 10 g/kg de menor nivel de proteína en la dieta en pollos de engorde similar a lo reportado por Hernandez y col (2013).


#### **4.2.8. Acumulación de estiércol en el tiempo y emisión de $\text{NH}_3$**

La emisión de  $\text{NH}_3$  aumentó el tiempo de acumulación del estiércol, siguiendo un patrón exponencial. Las emisiones diarias de  $\text{NH}_3$  aumentaron considerablemente para una acumulación de estiércol mayor a 4 días (Figura24), igual que en los estudios de (Mendes et al, 2012).

Las emisiones de amoníaco en aves de postura fueron mayores en el sistema en jaula en comparación con las ponedoras en piso, esto se debe que materiales como las virutas o cascarilla de arroz en un principio contribuyen a disminuir el pH y reducir la humedad del estiércol (Peche, 2014).

Wheeler y col. (2008) afirma que la cantidad de amoníaco emitida aumenta cuando las aves aumentan el peso de los residuos acumulados y es que a medida que pasa el tiempo por lo general se aumenta la humedad, temperatura y pH de los residuos, que junto con el tipo de manejo inciden en las emisiones de gases de efecto invernadero (Menegali et al, 2012) lo que podría explicar la tendencia de las curvas en la gráfica (Figura 24).

**Figura 20. Efecto de la acumulación del estiércol en las emisiones de NH<sub>3</sub> para tres tipos de lechos diferentes.**



**Fuente:** Elaboración propia. **Nota.** La acumulación en bandejas no se llevó hasta el día 150 debido a que en éste sistema no se acumulan las deyecciones tanto tiempo.

Liang y col (2004) encontraron comportamientos semejantes a los representados en la figura 24 donde las emisiones de amoniaco durante los primeros 40 días mostraron un incremento lineal con los días de acumulación de estiércol (coeficiente de correlación = 0,92). Durante el primer mes más o menos, la volatilización del amoniaco se atribuye principalmente al estiércol fresco, pero finalmente se estabiliza a medida que la cantidad de estiércol aumenta continuamente (Liang et al, 2004).

En la figura 24 se observa en las aves de engorde una tasa de emisiones de NH<sub>3</sub> mayor desde los primeros días de producción hasta el final del ciclo, esto puede deberse a el rápido crecimiento y mayor talla de los animales, lo que genera una mayor cantidad de deyecciones y un mayor contenido de Nitrógeno. El aumento en las emisiones de las

ponedoras en piso es menos acelerado pero al en un tiempo prolongado se alcanzan mayores emisiones debido a que la cama sufre una mayor compactación, humedecimiento y carga microbiana.

### Condiciones de operación favorables para la disminución de NH<sub>3</sub> (Recomendado)

De acuerdo a los resultados obtenidos mediante la red neuronal y el análisis de los mismos se suieren las siguientes condiciones de operación para la generación de menores emisiones de NH<sub>3</sub>

Variable analizada	Tipo de producción	Efecto en las emisiones de NH <sub>3</sub> / concentración de NH <sub>3</sub>	Rango óptimo según estudio	Recursos
Densidad	Aves de engorde Gallinas ponedoras	Aumenta/aumenta Aumenta /aumenta	6-8 Aves/m <sup>2</sup>	Reiter y Bessei (2000) Kang y col. (2016)
Humedad Relativa	Aves de engorde Gallinas ponedoras	Aumenta/aumenta Aumenta/aumenta	<70%	Knížatová et al. 2010 Golbabaei and Islami 2000
Edad aves	Aves de engorde Gallinas ponedoras	Aumenta/aumenta Aumenta /aumenta	-	Knížatová et al. 2010b., Vučemilo et al. 2007.  Koerkamp & Bleijenberg, 1998 Mendes & Xin & Li, 2012., Wood, 2015.
Tasa de ventilación	Aves de engorde Gallinas ponedoras	Aumenta/disminuye Aumenta/disminuye	3-4 m <sup>3</sup> h <sup>-1</sup> ave <sup>-1</sup>	Jiang and Sands 2000., Nadier 2013 Zhao et al. 2015.,

Tiempo de acumulación	Aves de engorde Gallinas ponedoras	Aumente  Aumenta	Hasta el final del ciclo productivo (Evitar contaminación y condiciones desfavorables)	Maliselo and Nkonde, 2015  McQuitty et al, 1985
Temperatura del galpón	Aves de engorde Gallinas ponedoras	Aumenta  Aumenta	20-25	Koerkamp, 1994.  Calvet et al. 2011. Nimmermark and Gustafsson 2005
Contenido de proteína	Aves de engorde Gallinas ponedoras	Aumenta/aumenta  Aumenta /aumenta	No exceder requerimiento nutricional de raza y etapa.	Hernandez et al, 2013  van Emous., 2019
pH	Aves de engorde Gallinas ponedoras	Aumenta/aumenta  Aumenta /aumenta	<8.5	Toghyani et al., 2010., Li et al. 2012. Tong, 2020

## 5. Conclusiones y recomendaciones

El coeficiente de correlación R demostró que la red neuronal es efectiva en la estimación de emisiones de NH<sub>3</sub> en diferentes condiciones ambientales.

El tipo de alojamiento, las prácticas de manejo del estiércol, las condiciones climáticas y de operación inciden la cantidad de emisiones de NH<sub>3</sub> liberadas al ambiente.

El NH<sub>3</sub> es un gas nocivo que necesita ser controlado. El control del pH, el contenido de humedad, la acumulación de estiércol, la edad de las aves, la densidad animal, la humedad relativa, la tasa y tipo de ventilación y la temperatura pueden disminuir de manera importante en la producción de NH<sub>3</sub>.

La red neuronal permitió el análisis de las variables proporcionando conocimientos útiles para el ajuste de las condiciones de diseño y operación en pro de la mitigación de las emisiones de NH<sub>3</sub>. Se sugirieron en el trabajo algunas condiciones de operación para la reducción de las emisiones de NH<sub>3</sub>.

Se recomienda o sugiere en futuras investigaciones orientar el uso de las redes neuronales hacia la automatización mediante el uso de Arduino y efectores para el control de las variables de operación.

## 6. Referencias

Aarnink, A. J. A., & Verstegen, M. W. A. (2007). Nutrition, key factor to reduce environmental load from pig production. *Livestock Science*, 109(1-3), 194-203p. <https://doi.org/10.1016/j.livsci.2007.01.112>

Abyaneh, H. (2014). Evaluation of multivariate li-near regression and artificial neural networks in prediction of water quality parameters. *Journal of Environmental Health Science & Engineering*, 12(40), 1-8p. <https://doi.org/10.1186/2052-336X-12-40>

Álava, F. J. (2015). Climatización de los galpones de la avícola inés maría. Trabajo final para la obtención del título: Ing. Mecánico Espol. fimcp, Guayaquil. <http://www.dspace.espol.edu.ec/xmlui/handle/123456789/37045>

Alberdi, O., Arriaga, H., Calvet, S., Estellés, F., & Merino, P. (2016). Ammonia and greenhouse gas emissions from an enriched cage laying hen facility. *Biosystems Engineering*, 144, 1-12p. <https://doi.org/10.1016/j.biosystemseng.2016.01.009>

Albino, L.F.T., Carvalho B.D, Maia R, Barros, V. (2014). Galinhas Poedeiras Criação e Alimentação. *Aprenda Fácil*, 376p.

Álvarez, L., Combellas, J., y Álvarez, R. (2005). Revisión Uso de excretas de aves en la alimentación de ovinos. *Zootecnia Tropical*, 23(2), 183-210. Recuperado en 21 de mayo de 2021, de [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S0798-72692005000200007&lng=es&tlng=es](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0798-72692005000200007&lng=es&tlng=es).

Andrade, A., y Arilio, O. (2017). Estudio de impacto ambiental para una granja de engorde en el municipio de Fusagasugá (Tesis de licenciatura, Universidad Militar Nueva Granada). <http://hdl.handle.net/10654/16439p>.

Aranda, J. I. (2018). Aguas residuales provenientes de la industria avícola en Colombia: una revisión bibliográfica. Villavicencio-Colombia: Universidad de los Llanos. 1-9p. 10.13140/RG.2.2.14655.00168

Arrieta, O. A. (2013). Emisión de gases de efecto invernadero y amoníaco en una explotación de gallinas ponedoras en bizkaia. *uztaila*: Universidad Pública de Navarra. 1-63p. <https://hdl.handle.net/2454/7669>

Asanza, W. R., Olivo, B. M. (2018). Redes neuronales artificiales aplicadas al reconocimiento de patrones. Machala. Universidad Técnica de Machala. <http://repositorio.utmachala.edu.ec/handle/48000/12499>

Barrera, J. A. T. Redes Neuronales. Universidad de Guadalajara. Recuperada el 15 de octubre de: [http://www.cucei.udg.mx/sites/default/files/pdf/toral\\_barrera\\_jamie\\_areli.Pdf](http://www.cucei.udg.mx/sites/default/files/pdf/toral_barrera_jamie_areli.Pdf)

Bertona, L. F., Britos, P., García, M. R. (2005). Entrenamiento de redes neuronales basado en algoritmos evolutivos. (Tesis de grado en ingeniería informática). Buenos Aires, Argentina: Universidad de Buenos Aires. Facultad de ingeniería, 253p.

BOE (2010). Real Decreto 692/2010 de 20 de Mayo, por el que se establecen las normas mínimas para la protección de los pollos destinados a la producción de carne. BOE, 135, 47986-47995.

Bohórquez, V. D. (2014). Perspectiva de la producción avícola en Colombia. Recuperado de: <http://hdl.handle.net/10654/12149>

Boniecki, P., Dach, J., Pilarski, K., & Piekarska, B. H. (2012). Artificial neural networks for modeling ammonia emissions released from sewage sludge composting. *Atmospheric Environment*, 57, 49-54p. <https://doi.org/10.1016/j.atmosenv.2012.04.036>

Botermans, J. G., Gustafsson, K. H., Jeppsson, N., Brown., and Rodhe, L. (2010). Measures to reduce ammonia emissions in pig production. Faculty of Landscape Planning, Horticulture and Agricultural Science. *Landskap Trädgård Jordbruk: Rapportserie (1654)*, 63. <http://urn.kb.se/resolve?urn=urn:nbn:se:slu:epsilon-5-141p>

Brodny, J., & Tutak, M. (2020). The Use of Artificial Neural Networks to Analyze Greenhouse Gas and Air Pollutant Emissions from the Mining and Quarrying Sector in the European Union. *Energies*, MDPI, Open Access Journal, 13(8), 1-31p.

Calvet, S., Cambra-López, M., Estellés, F., and Torres, A. G. (2011). Characterization of gas emissions from a Mediterranean broiler farm. *Poultry Science* (90): 534-542. <https://doi.org/10.3382/ps.2010-01037>

Campos, F., Tinôco, I. F., Silva, J., Baptista, F. D., Souza, C. F., & Silva, A. L. (2017). Gas emission in the poultry production. *Journal of Animal Behaviour and Biometeorology*, 5(2), 49-55p. <https://doi.org/10.31893/2318-1265jabb.v5n2p49-55>

Castro, C. M. (2018). Manejo da cama aviária e impactos na produção avícola. *Anais do 19º Simpósio Brasil Sul de Avicultura e 10º Brasil Sul Poultry Fair*, 11-21p.

Cedeño, K., & Vergara, C. (2017). Manejo de cortinas para mejorar el bienestar animal y parámetros productivos en pollos cobb 500 (Tesis doctoral). Médico Veterinario. Carrera Pecuaria. ESPAM MFL. Calceta. Manabí. EC. 69p).

Chepete, J. H., Xin, H., & Li, H. (2011). Ammonia emissions of laying-hen manure as affected by accumulation time. *The journal of poultry science*, 48(2), 133-138p. <https://doi.org/10.2141/jpsa.010087>

Cohuo-Colli, J. M., Salinas-Ruiz, J., Hernández-Cázares, A. S., Hidalgo-Contreras, J. V., Brito-Damián, V. H., & Velasco-Velasco, J. (2018). Effect of litter density and foot health program on ammonia emissions in broiler chickens. *Journal of Applied Poultry Research*, 27(2), 198-205p. <https://doi.org/10.3382/japr/pfx058>

Cordeiro, M. B., Tinôco, I. F., Silva, J. N., Vigoderis, R. B., Pinto, F. A. C., & Cecon, P. R. (2010). Conforto térmico e desempenho de pintos de corte submetidos a diferentes sistemas de aquecimento no período de inverno. *Revista Brasileira de Zootecnia*, v.39, 217-224p. <http://dx.doi.org/10.1590/S1516-35982010000100029>

Córdoba, C. D. (2017). Herramientas para la enseñanza de sistemas inteligentes utilizando plataformas de hardware libre. Cali: Universidad Autónoma de Occidente - Facultad de Ingeniería.

Cortina Januchs, María Guadalupe (2012). Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos. Universidad Politécnica de Madrid, España. (Tesis doctoral), E.T.S.I. Telecomunicación (UPM), 210. <http://oa.upm.es/11206/>

Coufal, C. D., Chavez, C., Niemeyer, P. R., & Carey, J. B. (2006). Measurement of broiler litter production rates and nutrient content using recycled litter. *Poultry Science*, 85(3), 398-403p. <https://doi.org/10.1093/ps/85.3.398>

DANE. (2019). Estadísticas. Recuperado el 15 de octubre de: [http://www.fenavi.org/index.php?option=com\\_content&view=article&id=2167&Itemid=1172#magictabs\\_erpdb\\_3](http://www.fenavi.org/index.php?option=com_content&view=article&id=2167&Itemid=1172#magictabs_erpdb_3)

Dekker, S. E. M., Aarnink, A. J. A., De Boer, I. J. M., & Koerkamp, P. G. (2011). Emissions of ammonia, nitrous oxide, and methane from aviaries with organic laying hen husbandry. *Biosystems Engineering*, 110(2), 123-133p.

Delgado, A. M. D. M., Miralles I. H. R., Alonso P. F., Rodríguez A. C., Martín Sánchez, J. V. (2014). Concentración de metales pesados en suelos, plantas, lombrices y lixiviados provenientes de gallinaza aplicada a suelos agrícolas. *Revista internacional de contaminación ambiental*, 30(1), 43-50p. Disponible en: <<https://www.revistascca.unam.mx/rica/index.php/rica/article/view/33803>>. Fecha de acceso: 21 may 2021.

Saavedra D. P. (2017). Estudio de la utilización del potencial de información cruzado en el aprendizaje con ensamble de redes neuronales. Disponible en <http://repositorio.uchile.cl/handle/2250/150340>

Ecetoc, (1994). Ammonia emissions to air in Western Europe. Technical report No. 62. European Centre for Ecotoxicology and Toxicology of Chemicals. Brussels, Belgium, 196p.

Elwinger, K., & Svensson, L. (1996). Effect of dietary protein content, litter and drinker type on ammonia emission from broiler houses. *Journal of Agricultural Engineering Research*, 64(3), 197-208p. <https://doi.org/10.1006/jaer.1996.0061>

Fabbri, C., Valli, L., Guarino, M., Costa, A., & Mazzotta, V. (2007). Ammonia, methane, nitrous oxide and particulate matter emissions from two different buildings for laying hens. *Biosystems Engineering*, 97(4), 441-455. <https://doi.org/10.1016/j.biosystemseng.2007.03.036>

FAO. 2020 Food Outlook - Biannual Report on Global Food Markets: June 2020. Food Outlook. Rome. 44-50p. <https://doi.org/10.4060/ca9509en>

Federación Nacional de Avicultores de Colombia, FENAVI (2018). Manual de buenas prácticas disponibles para la mitigación de olores en la industria avícola. Colombia: Fondo Nacional Avícola.

Recuperado en octubre 1 de 2020, de: [https://fenavi.org/wp-content/uploads/2018/05/Cartilla\\_Digital\\_PRI0\\_FINAL.pdf](https://fenavi.org/wp-content/uploads/2018/05/Cartilla_Digital_PRI0_FINAL.pdf)

Federación Nacional de Avicultores de Colombia, FENAVI (2020). Avicultores. Federación Nacional de Avicultores de Colombia – Fenavi- N°. 302 / febrero 15 de 2020. ISSN 0121 –1358. Recuperado en octubre 1 de 2020, de: [https://fenavi.org/wp-content/uploads/2020/02/Fenaviquin\\_ed3022019.pdf](https://fenavi.org/wp-content/uploads/2020/02/Fenaviquin_ed3022019.pdf)

Cervantes, O. R., Arteaga, R. R., Vázquez P. M., Ojeda B. W., Quevedo N. A. (2013). Modelos Hargreaves Priestley-Taylor y redes neuronales artificiales en la estimación de la evapotranspiración de referencia. *Ingeniería, investigación y tecnología*, 14(2), 163-176p. Recuperado en 21 de mayo de 2021, de [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-77432013000200003&lng=es&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-77432013000200003&lng=es&tlng=es).

García, J. B. (2017). Optimización de la Utilización de Catalizadores Orgánicos Biológicos en el Tratamiento de Aguas Residuales de la Industria Avícola usando Redes Neuronales Artificiales. Palmira: Universidad Nacional de Colombia.

Garzón, D. F. (2005). Aplicación de Redes Neuronales MLP a la predicción de un paso en series de tiempo. Bogotá: Fundación Universitaria Konrad Lorenz.

Ghaly, A. E., & Alhattab, M. K. (2013). Drying poultry manure for pollution potential reduction and production of organic fertilizer. *American Journal of Environmental Sciences*, 9(2), 88-102p. Recuperado de <https://doi.org/10.3844/ajessp.2013.88.102>.

Golbabaie F, Islami F (2000) Evaluation of workers' exposure to dust, ammonia and endotoxin in poultry industries at the province of Isfahan, Iran. *Ind Health* 38, 41–46p. <https://doi.org/10.2486/indhealth.38.41>

González-Salcedo, L. O., & García-Nuñez, J. B. (2019). Elaboración de un modelo neuronal artificial para la estimación de turbiedad y proposición de dosificaciones en el tratamiento de aguas residuales de la industria avícola. *Informador Técnico*, 84(1), 3-17p. <https://doi.org/10.23850/22565035.1636>

Gulyani, B. B., Mangai, J. A., & Fathima, A. (2015). An Approach for Predicting River Water Quality Using Data Mining Technique. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9165, 233-243p. [https://doi.org/10.1007/978-3-319-20910-4\\_17](https://doi.org/10.1007/978-3-319-20910-4_17)

Guo, Y., Yang, L., Liu, C., Ye, R., & Duan, Q. (2020). Prediction of stench gas in chicken house based on RF-LSTM. *China Environmental Science*, 40(7), 2850-2857p.

Hecht, R. (1997). Counter-Propagation Networks. *IEEE First International Conference on Neural Networks*. 2,19-32p.

Hernández, F., Rivas, M. D. M., Femenia, J. O., López, M. J., & Madrid, J. (2013). Effect of dietary protein level on retention of nutrients, growth performance, litter composition and NH<sub>3</sub> emission using a multi-phase feeding programme in broilers. *Spanish journal of agricultural research*, (3), 736-746. <http://dx.doi.org/10.5424/sjar/2013113-3597>.

Herrera, J., Rojas, J. F., y Bolaños, A. (2013). Diagnóstico preliminar de los niveles de emisión de amoníaco y sulfuro de hidrógeno en distintas modalidades de producción en granjas avícolas en Costa Rica. *Revista de Ciencias Ambientales*, 46(2), 15-26p. <https://doi.org/10.15359/rca.46-2.2>

Huijsmans, J. F. M. (2003). Manure application and ammonia volatilization. Wageningen Universiteit. <https://edepot.wur.nl/121465>

ICONTEC. (2004). Productos para la industria agrícola. Productos orgánicos usados como abonos o fertilizantes y enmiendas de suelo. NTC 5167. Bogotá D.C. 40p.

ICONTEC. (2004). Productos para la industria agrícola. Productos orgánicos usados como abonos y fertilizantes y enmiendas de suelo, Publicaciones ICONTEC, Bogotá.

IPCC. (2013). Climate change 2013: The physical science basis. Contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change. [Stocker, T. F., D. Qin, G. K. Plattner, M. Tignor, S. K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 p.

Jarret, G., Martinez, J., Dourmad, J.Y. (2011). Pig feeding strategy coupled with effluent management – fresh or stored slurry, solid phase separation – on methane potential and methane conversion factors during storage. *Atmos. Environ.* 45, 6204-6209p. <https://doi.org/10.1016/j.atmosenv.2011.07.064>.

Jiang JK, Sands JR (2000) Odour and ammonia emission from broiler farms. Rural Industries Research and Development Corporation. Australia. Publication no. 00/2. 94p.

Jugowar, J. L., Rzeźnik, W., & Mielcarek, P. (2017). Emission of ammonia, nitrous oxide and methane from hen house in deep litter/slatted floor system. *Journal of Research and Applications in Agricultural Engineering*, 62-64p.

Kang, H. K., Park, S. B., Kim, S. H., & Kim, C. H. (2016). Effects of stock density on the laying performance, blood parameter, corticosterone, litter quality, gas emission and bone mineral density of laying hens in floor pens. *Poultry Science*, 95(12). <https://doi.org/10.3382/ps/pew264>

Knížatová, M., Mihina, Š., Brouček, J., Karandušovská, I., & Mačuhová, J. (2010). Ammonia emissions from broiler housing facility: influence of litter properties and ventilation. In XVIIth World Congress of the International Commission of Agricultural and Biosystems Engineering (CIGR). Canadian Society for Bioengineering (CSBE/SCGAB). Canada, 13-17p.

Koerkamp PG (1994) Review on emissions of ammonia from housing systems for laying hens in relation to sources, processes, building design and manure handling. *J Agric Eng Res* 59:73–87p. <https://doi.org/10.1006/jaer.1994.1065>

Koerkamp, P. G., & Bleijenberg, R. (1998). Effect of type of aviary, manure and litter handling on the emission kinetics of ammonia from layer houses. *British Poultry Science*, 39(3), 379-392p. <https://doi.org/10.1080/00071669888935>

Koerkamp, P.W.G., Metz, J.H.M., Uenk, G.H., Phillips, V.R., Holden, M.R., Sneath, R. W., ... Wathes, C.M. (1998) Concentrations and Emissions of Ammonia in Livestock Buildings in Northern Europe. *Journal of Agricultural Engineering Research* 70, 79–95p. <https://doi.org/10.1006/jaer.1998.0275>

Koerkamp, P. G., Speelman, L., & Metz, J. H. M. (1999). Litter composition and ammonia emission in aviary houses for laying hens: Part II, modelling the evaporation of water. *Journal of Agricultural Engineering Research*, 73(4), 353-362p. <https://doi.org/10.1006/jaer.1999.0425>

León, B. P. A y Piña O. C. D. (2018). Predicción de emisiones contaminantes de gases de escape a través de la presión media efectiva empleando redes neuronales en motores de encendido

provocado. (tesis para la obtención del título de ingeniería mecánica). Universidad politécnica salesiana sede cuenca. Ecuador, 124p. <http://dspace.ups.edu.ec/handle/123456789/15998>

Li, C., Salas, W., Zhang, R., Krauter, C., Rotz, A., & Mitloehner, F. (2012). Manure-DNDC: a biogeochemical process model for quantifying greenhouse gas and ammonia emissions from livestock manure systems. *Nutrient Cycling in Agroecosystems*, 93(2), 163-200p. <https://doi.org/10.1007/s10705-012-9507-z>

Liang, Y., Xin, H. A., Tanaka, S. H., Lee, H., Li, E.F., Wheeler, R. S., Gates, J. S., Zajaczkowski, P., Topper., and Casey.K.D. (2003). Ammonia emissions from U.S. poultry houses: part II – layer houses. In: *Proc. 3rd International Conference on Air Pollution from Agricultural Operations*, American Society of Agricultural Engineers, St Joseph, MI: ASAE, pp. 147-158p.

Liang, Y., Xin, H., Wheeler, E. F., Gates, R. S., Li, H., Zajaczkowski, J. S., ... & Zajaczkowski, F. J. (2005). Ammonia emissions from US laying hen houses in Iowa and Pennsylvania. *Transactions of the ASAE*, 48(5), 1927-194p. <https://doi.org/10.13031/2013.20002>

Lima, N. D. S., Garcia, R. G., Nääs, I. A., Caldara, F. R., & Ponso, R. (2015). Model-predicted ammonia emission from two broiler houses with different rearing systems. *Scientia Agricola*, 72(5), 393-399. <https://doi.org/10.1590/0103-9016-2014-0217>

Liu, Z., Wang, L., and Beasley, D. B. (2008). Comparison of three techniques for determining ammonia emission fluxes from broiler litter. *Trans. ASABE* 51(5), 1783-1790p. <https://doi.org/10.13031/2013.25304>

Liu, Z., Wang, L., Beasley, D. B. (2006). A review of emission models of ammonia released from broiler houses. *American Society of Agricultural and Biological Engineers ASABE*, Portland. (064101), 1-17. <https://doi.org/10.13031/2013.21568>

Liu, Z., Wang, L., Beasley, D., and Oviedo, E. (2007). Effect of moisture content on ammonia emissions from broiler litter: A laboratory study. *J. Atmos. Chem.* 58 (1), 41-53p. <https://doi.org/10.1007/s10874-007-9076-8>

Lozano, M. R. (2011). El papel de las redes bayesianas en la toma de decisiones. Laboratorio de Modelación y Simulación, Universidad del Rosario.

Maheshwari, S. (2013). Environmental impacts of poultry production. Mahe's Biotech Pvt. Ltd, India. *Poultry, Fisheries & Wildlife Sciences*. 2p. <https://doi.org/10.4172/2375-446X.1000101>

Maliselo PS, Nkonde GK (2015) Ammonia production in poultry houses and its effect on, the growth of gallus gallus domestica (broiler chickens): a case study of a small scale poultry in riverside, Kitwe, Zambia. *Int J Sci Technol.* 4,141–145p.

Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Argentina. Universidad Tecnológica Nacional. Facultad Regional Rosario Departamento de Ingeniería Química. *Optics and Photonics Journal*, 7(10), 55p.

McQuitty JB, Feddes JJR, Leonard JJ (1985) Air quality in comercial laying barns. *CBE Journal*, 27, 13–19p.

Meda, B., Hassouna, M., Aubert, C., Robin, P., Dourmad, J. Y. (2011). Influence of rearing conditions and manure management practices on ammonia and greenhouse gas emissions from poultry houses. *World's Poultry Science Journal*, 67(3), 441-456p. <https://doi.org/10.1017/S0043933911000493>

Medina, D. E., Ore, C. L. (2016). Informe final. Redes neuronales artificiales para la predicción de la concentración de PM10 en el distrito de Ate. [Trabajo de especialización, Universidad Nacional Agraria De La Selva]. Facultad de recursos naturales renovables. Tingo Maria-Perú. 82p.

Mendes, L. B., Xin, H., & Li, H. (2012). Ammonia emissions of pullets and laying hens as affected by stocking density and manure accumulation time. *Transactions of the ASABE*, 55(3),1067-1075p.

Menegali, I., Tinôco, I.F.F., Zolnier, S., Carvalho, C.C.S., Guimarães, M.C.C. (2012). Influence of different systems of minimum ventilation on air quality in broiler houses. *Engenharia Agrícola* 32, 1024-1033p.

Merchán I., y Quezada, J. (2013). Reducción de amoníaco de la pollinaza de pollos broiler mediante la adicción de zeolita en la ración alimenticia durante el periodo de crianza en la parroquia Paccha del cantón Cuenca, provincia del Azuay. Tesis de Ingeniero Ambiental. Cuenca, Ecuador: Univ. Politécnica Salesiana. 110p.

Miles, D. M., Branton, S. L., & Lott, B. D. (2004). Atmospheric ammonia is detrimental to the performance of modern commercial broilers. *Poultry science*, 83(10), 1650-1654p.

Miles, D. M., Rowe, D. E., and Moore Jr, P. A. (2012). Litter ammonia losses amplified by higher airflow rates. *Journal of Applied Poultry Research*, 21(4), 874-880p.

Miles, D. M., W. W. Miller, S. L. Branton, W. R. Maslin, and B. D. Lott. (2006). Ocular responses to Ammonia in Broiler Chickens. *Avian Diseases* 50(1):45-49p.

MinAmbiente. (2006). Guía de mejores técnicas disponibles en España del sector matadero y transformados de pollo y gallina. Ministerio de Ambiente. España.

MinSalud. (2006). Guía de mejores técnicas disponibles del sector de la avicultura de puesta. España: Ministerio de Ambiente- Gobierno de España.

MinSalud. (2012). Lineamiento para la vigilancia sanitaria y ambiental del impacto de los olores ofensivos en la salud y calidad de vida de las comunidades expuestas en áreas urbanas.

Morazán, H. J. (2014). Emisión de amoníaco (NH<sub>3</sub>) y gases con efecto invernadero (CH<sub>4</sub> y N<sub>2</sub>O) en cerdos en crecimiento: efecto del nivel de proteína y fibra de la ración.

Muñoz, E., Seijas, Cesar. (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*, 13p. <https://doi.org/10.17163/lgr.n21.2015.04>

Nadier A, Allouim MN, Bennoune O, Bouhental S (2013) Effect of ventilation and atmospheric ammonia on the health and performance of broiler chickens in summers. *J World's Poult Res* 3:54–56p.

Nimmermark, S., & Gustafsson, G. (2005). Influence of temperature, humidity and ventilation rate on the release of odour and ammonia in a floor housing system for laying hens. *Agricultural Engineering International: CIGR Journal*.4 (04008), 14p. <https://hdl.handle.net/1813/10423>

Ning, Xiaopeng. (2008). "Feeding, defecation and gaseous emission dynamics of W-36 laying hens". Graduate Theses and Dissertations. 11575. <https://lib.dr.iastate.edu/etd/11575>

Osorio, H., Tinoco, I. F., Osorio, S., Jairo, A., de F Souza, C., & de Sousa, F. C. (2016). Calidad del aire en galpón avícola con ventilación natural durante la fase de pollitos. *Revista Brasileira de*

Engenharia Agrícola e Ambiental, 20(7), 660-665p. <https://doi.org/10.1590/1807-1929/agriambi.v20n7p660-665>

Pareja, M. M. E. (2005). Manejo y procesamiento de la gallinaza. Revista Lasallista de investigación, 2(1), 43-48. <http://hdl.handle.net/10567/333>

Peche, G. A. (2014). Conservación y calidad de la yacija en naves de pollos. Albéitar: publicación veterinaria independiente, (176), 38-40p.

Pereira, J. L. (2017). Assessment of ammonia and greenhouse gas emissions from broiler houses in Portugal. Atmospheric Pollution Research, 8(5), 949-955p. <https://doi.org/10.1016/j.apr.2017.03.011>

Pereira, J. L., Ferreira, S., Pinheiro, V., & Trindade, H. (2018). Ammonia, nitrous oxide, carbon dioxide and methane emissions from commercial broiler houses in Mediterranean Portugal. Water, Air, & Soil Pollution, 229(12), 377p. <https://doi.org/10.1007/s11270-018-4026-4>

Pérez, A.J.M., Cadenas, C.C (2005). Análisis y Diseño de Dispositivos de Radiocomunicación Mediante Redes Neuronales [trabajo para título de ingeniero Universidad de Sevilla]. Departamento de Ingeniería Electrónica Área de Teoría de la Señal y Comunicaciones. Escuela superior de ingenieros. Universidad de Sevilla.

Pezzuolo, A., Sartori, C., Vigato, E., & Guercini, S. (2019). Effect of litter treatment with probiotic bacteria on ammonia reduction in commercial broiler farm. [Trabajo para obtener título de ingeniero]. Engineering for Rural Development, 18, 1631-1635p. <https://doi.org/10.22616/ERDev2019.18.N390>

Plöchl, M. (2001). Neural network approach for modelling ammonia emission after manure application on the field. Atmospheric Environment, 35(33), 5833-5841p. [https://doi.org/10.1016/S1352-2310\(01\)00281-3](https://doi.org/10.1016/S1352-2310(01)00281-3)

Qu, Y., Wang, M., Dong, W., & Wang, Y. (2019). Prediction of atmospheric ammonia concentration in farmlands using BP neural network. Chinese Journal of Eco-Agriculture, 27(4), 519-528p. <https://doi.org/10.13930/j.cnki.cjea.181057>

Redwine, J. S., Lacey, R. E., Mukhtar, S., and Carey, J. B. (2002). Concentration and emissions of ammonia and particulate matter in tunnel ventilated broiler houses under summer conditions in Texas. Transactions of the ASAE, 45(4): 1101-1109p. <https://doi.org/10.13031/2013.9943>

Rege, M. A., & W. Tock, R. (1996). A simple neural network for estimating emission rates of hydrogen sulfide and ammonia from single point sources. Journal of the Air & Waste Management Association, 46(10), 953-962p. : <https://doi.org/10.1080/10473289.1996.10467530>

Resolución N° 1541 [Ministerio de Ambiente y Desarrollo Sostenible, MinAmbiente]. Por la cual se establecen los niveles permisibles de calidad de aire o de inmisión, el procedimiento para la evaluación de actividades que generen olores ofensivos y se dictan otras disposiciones. 12 de noviembre de 2013.

Rong, L., Nielsen, P.V and Zhang, G. (2009). Effects of airflow and liquid temperature on ammonia mass transfer above an emission surface: experimental study on emission rate. Bioresource Technol. 100(20):4654-4661p. <https://doi.org/10.1016/j.biortech.2009.05.003>

Rosa, E., Arriaga, H., & Merino, P. (2020). Ammonia emission from a manure-belt laying hen facility equipped with an external manure drying tunnel. Journal of Cleaner Production, 251p. <https://doi.org/10.1016/j.jclepro.2019.119591>.

Ruiz, B. (2020). Empresas Líderes 2020: Fuerte crecimiento de la avicultura latinoamericana en 2019. Empresas líderes industria avícola.net. Recuperado en octubre 15 de 2020, de: <https://www.industriaavicola-digital.com/industriaavicola/april2020/MobilePagedArticle.action?articleId=1573912#articleId1573912>.

Ruiz, K., Trilleras, J.M., y Sanjuanelo, D. (2019). Dispersión del amoníaco proveniente de una granja avícola en Santa Bárbara (Cundinamarca, Colombia) y su valoración cualitativa. *Revista de investigaciones veterinarias del Perú*, 30(4), 1443-1455p. <http://dx.doi.org/10.15381/rivep.v30i4.15521>

Saavedra D. P. A. (2017). Estudio de la utilización del potencial de información cruzado en el aprendizaje con ensamble de redes neuronales. Disponible en <http://repositorio.uchile.cl/handle/2250/150340>

Saha, C. K., Zhang, G., Kai, P., and Bjerg, B. (2010). Effects of a partial pit ventilation system on indoor air quality and ammonia emission from a fattening pig room. *Biosystems Engineering*, Volume 105, 279-287p. <https://doi.org/10.1016/j.biosystemseng.2009.11.006>

Sánchez, C., Montilla, J.J., Angulo, I., y León, A. (2001). Efecto del tipo de galpón y ubicación de las jaulas sobre los factores ambientales en gallinas ponedoras. *Revista de la Facultad de Agronomía*, 20(2), 195-209p. Recuperado en 21 de mayo de 2021, de [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S0378-78182003000200008&lng=es&tlng=es](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0378-78182003000200008&lng=es&tlng=es).

Seidavi, A. R., Zaker-Esteghamati, H., & Scanes, C. G. (2019). Present and potential impacts of waste from poultry production on the environment. *World's Poultry Science Journal*, 75(1), 29-42. <https://doi.org/10.1017/S0043933918000922>

Senyondo, N. S. (2013). Mitigation of ammonia emissions from broiler houses using a biodegradable litter amendment [disertación doctoral, Virginia Tech]. Dallas, Texas. 167p. <https://doi.org/10.13031/2013.41878>

Séraphin C. Atidéglá, Joël Huat, Euloge K. Agbossou, Hervé Saint-Macary, Romain Glèlè Kakai. (2016). Vegetable Contamination by the Fecal Bacteria of Poultry Manure: Case Study of Gardening Sites in Southern Benin. *International Journal of Food Science*, Article ID 4767453, 8 p. <https://doi.org/10.1155/2016/4767453>

Serrano, A. J., Soria, E., & Martín, J. D. (2009). REDES NEURONALES ARTIFICIALES. Recuperado el 16 de Agosto de 2020, de <http://ciberconta.unizar.es/leccion/redes/610.HTM>

Shepherd, T. A., Zhao, Y., Li, H., Stinn, J. P., Hayes, M. D., & Xin, H. (2015). Environmental assessment of three egg production systems—Part II. Ammonia, greenhouse gas, and particulate matter emissions. *Poultry science*, 534-543p. <https://doi.org/10.3382/ps/peu075>

Solomon, S. (2007). The physical science basis: Contribution of Working Group I to the fourth assessment report of the Intergovernmental Panel on Climate Change. Intergovernmental Panel on Climate Change (IPCC), *Climate change 2007*, 996p.

Soto-Herranz, M., Antolín-Rodríguez, J. M., Conde-Cid, D., & Sánchez-Báscones, M. (2019). Desarrollo de prototipo de membrana para la captación de gas amoníaco en la atmósfera de las granjas. Universidad de Valladolid. Madrid. España. X congreso ibérico de agroingeniería. 8p. [https://doi.org/10.26754/c\\_agroing.2019.com.3428](https://doi.org/10.26754/c_agroing.2019.com.3428)

Steinfeld, H., Gerber, P., Wassenaar, T., Castel, V., Rosales, M., & de Haan, C. (2009). La larga sombra del ganado problemas ambientales y opciones. Organización de las Naciones Unidas para la Agricultura y la Alimentación. Roma. 81-91p.

Suarez, E. (2009). Predicción de comportamientos a través de redes neuronal en Matlab. Cuba. 134p.

Tablada, C. J., & Torres, G. A. (2009). Redes Neuronales Artificiales. Revista De Educación Matemática, 24(3). Recuperado a partir de <https://revistas.unc.edu.ar/index.php/REM/article/view/10280>

Tino, P., Benuskova, L., & Sperduti, A. (2015). Artificial Neural Network Models. In Springer Handbook of Computational Intelligence. Springer, Berlin, Heidelberg. 455-471p.

Toghyani, M., Gheisari, A., Modaresi, M., Tabeidian, S.A., Toghyani, M. (2010). Effect of different litter material on performance and behavior of broiler chickens. Applied Animal Behaviour Science 122: 48-52p. <https://doi.org/10.1016/j.applanim.2009.11.008>

Tong, X., Hong, S. W., & Zhao, L. (2019). CFD modeling of airflow, thermal environment, and ammonia concentration distribution in a commercial manure-belt layer house with mixed ventilation systems. Computers and Electronics in Agriculture, 162, 281-299p. <https://doi.org/10.1016/j.compag.2019.03.031>

Tong, X., Zhao, L., Heber, A. J., & Ni, J. Q. (2020). Mechanistic modelling of ammonia emission from laying hen manure at laboratory scale. Biosystems Engineering, 192, 24-41p. <https://doi.org/10.1016/j.biosystemseng.2020.01.004>

Torres, C. A. (2014). Un algoritmo cuasi Newton global para problemas de complementariedad no lineal. [Disertación de maestría, Universidad del Cauca] Facultad de Ciencias Naturales, Exactas y de la Educación. Departamento de Matemáticas. <http://repositorio.unicauca.edu.co:8080/xmlui/handle/123456789/581>

Valdés H., N. J. y González S., L. O., Will, Adrián L. (2011). Estimación de la resistencia a la penetración de suelos usando redes neuronales artificiales. Acta Agronómica, 60(3), 252-262p. Recopilado el 21 de mayo de 2021, from [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-28122011000300006&lng=en&tlng=es](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-28122011000300006&lng=en&tlng=es).

van Emous, R. A., Winkel, A., & Aarnink, A. J. A. (2019). Effects of dietary crude protein levels on ammonia emission, litter and manure composition, N losses, and water intake in broiler breeders. Poultry science, 98(12), 6618-6625p. <https://doi.org/10.3382/ps/pez508>

Velasco V. J., Alvarado L. H., Hernández, C., Gómez, M. F., Narciso, G. C., Misselbrook, T. (2016). Buenas prácticas de manejo y emisiones de amoniaco en explotaciones avícolas. Agro Productividad, 9(8). Recuperado el 20 de noviembre de 2020 de: <https://revista-agroproductividad.org/index.php/agroproductividad/article/view/799>

Vivas, H. (2014). Optimización en el entrenamiento del Perceptrón Multicapa. Popayán: Universidad del Cauca. [Disertación de maestría, Universidad del Cauca], Facultad de Ciencias Naturales, Exactas y de la Educación. Departamento de Matemáticas.

Vivas, A. M. (2016). Aplicación de las redes neuronales artificiales y teoría de juegos al cambio climático con control óptimo. Entornos, Universidad Sur colombiana. Revista entornos, 29(2), 371-372p.

Vučemilo, M., K. Matković, B. Vinković, S. Jaksić, K. Granić, and N. Mas. (2007). The effect of animal age on air pollutant concentration in a broiler house. *Czech Journal of Animal Science*, 52(6), 170-174p. <https://doi.org/10.17221/2318-CJAS>

Wang, P., Yao, J., Wang, G., Hao, F., Shrestha, S., Xue, B., Peng, Y. (2019). Exploring the application of artificial intelligence technology for identification of water pollution characteristics and tracing the source of water quality pollutants. *Science of the Total Environment*, 693p. <https://10.1016/j.scitotenv.2019.07.246>

Wheeler, E. F., Casey, K. D., Gates, R.S., Xin, H., Topper, P.A and Liang. Y. (2008). Ammonia Emissions from USA Broiler Chicken Barns Managed with New Bedding, Built-up Litter, or Acid-Treated Litter. *Livestock Environment* 8, 9p. <https://doi.org/10.13031/2013.25475>

Williams, C. M. (2013). Gestión de residuos de aves de corral en los países en desarrollo. En O. d. Agricultura. Revisión del desarrollo Avícola. Revisión del desarrollo Avícola FAO, 14p.

Wood, D. (2015). The evaluation of ammonia and particulate matter control strategies for poultry production facilities [Dissertation doctoral, The University of Guelph]. School of Engineering. <http://hdl.handle.net/10214/9224>

Zhao Y, Shepherd TA, Li H, Xin H (2015) Environmental assessment of three egg production systems—part I: monitoring system and indoor air quality. *Poult Sci* 94(3) 518–533p. <https://doi.org/10.3382/ps/peu076>

Zheng, W., Xiong, Y., Gates, R. S., Wang, Y., & Koelkebeck, K. W. (2020). Air temperature, carbon dioxide, and ammonia assessment inside a commercial cage layer barn with manure-drying tunnels. *Poultry science*, 99(8), 14p. <https://doi.org/10.1016/j.psj.2020.05.009>

# ANEXOS

## A. ANEXO: CÓDIGO PARA LA AUTOMATIZACIÓN DE LA RED

```
%%Codificación para la iteración de los algoritmos de entrenamiento y el número de
capas el entrenamiento de una red neuronal artificial%%
clc
Equipo='JOHN';
raiz=strcat('C:\Users\' ,Equipo, '\Music\Datos\conjunto 2\');
num_max_neuronas=25; % es el número maximo de neuronas por cada capa
num_max_capas=1; % es el número maximo de capas para la red
carpeta_experimento=strcat('Train_',int2str(num_max_capas),'capas_',int2str(num_max
_neuronas),'neuronas\');
mkdir(raiz,carpeta_experimento);
metodo=["trainlm", "trainrp", "traincgf", "traincgb", "trainoss"];
for j=1:12%j lee cada uno de los metodo en el vector
    %disp(metodo(j));
    carpeta_metodo_math=strcat(raiz,carpeta_experimento);
    mkdir(carpeta_metodo_math,metodo(j));
    for capa=1:num_max_capas
        v=[1:capa];
        for var=1:capa
            v(var)=1;
        end;

        for i=1:num_max_neuronas^capa
            for x=1:capa

                if v(capa+1-x)==num_max_neuronas+1;
                    v(capa+1-x)=1;
                    v(capa-x)=v(capa-x)+1;
                end;
            end;

            carpeta_arquitectura=strcat(carpeta_metodo_math,metodo(j),'\');
            %disp(carpeta_arquitectura);
            carpeta='[';
            for var=1:length(v)
                if var~=length(v)
                    carpeta=strcat(carpeta,int2str(v(var)), '_[');
```

```
end;
if var==length(v)
    carpeta=strcat(carpeta,int2str(v(var)),'];
end;
end;
mkdir(carpeta_arquitectura,carpeta);
ruta_guardar=strcat(carpeta_arquitectura,carpeta);
%disp(ruta_guardar);
% disp(v);%aquí va la función red neuronal
%train_mlp_ann(ruta_guardar,v,metodo(j));
train_mlp_ann(v,metodo(j),ruta_guardar);
v(capa)=v(capa)+1;
end;
end;
end;
```

## B. ANEXO: CÓDIGO PARA EL ENTRENAMIENTO DE LA RED

```
%%Codificación para el entrenamiento de una red neuronal artificial
%%multicapa, MLP (Multi-Layer Perceptron)%%
```

```
%%%Basado en el código del profesor Luis Octavio González Salcedo, Profesor Asociado,
%%%Universidad Nacional de Colombia Sede Palmira, con fines exclusivamente
%%%académicos, para la enseñanza de redes neuronales artificiales, en
%%%cursos sobre la temática o de Inteligencia Artificial
```

```
function [] = train_mlp_ann ()
```

```
Datos = [];
```

```
%%%%%%%%Preparación de los datos en entradas (P) y salidas objetivo (T)%%%%%%%%
```

```
P = Datos(:, 1:end-1)';%%Se descarta la última columna, entonces...
```

```
%%corresponde P a la matriz que almacena...
```

```
%%las variables de entrada%%
```

```
T = Datos(:,end)';%%Se toma la última columna, entonces corresponde T...
```

```
%%al vector que almacena la variable de salida%%
```

```
%%%%%%%%%%
%%%%%%%%%%
%%%%%%%%%%
```

```
%%%%%%%%%%
%%%%%%%%%%
```

```
%%%%%%%%Parámetros iniciales de la red neuronal artificial%%%%%%%%
```

```
%%%%%%%%%%
%%%%%%%%%%
```

```
%%%%%%%%Arquitectura: Número de capas ocultas y neuronas en cada capa%%%%%%%%
```

```
Arquit_NN = [10 10 5]; %%el número de columnas corresponde al número...
```

```
%%de capas ocultas.
```

```
%%el número en cada capa corresponde al...
```

```
%%número de de neuronas ocultas
```

```
epocas = 100; %%épocas: el número de veces que se presenta completo...
```

```
%%el conjunto de entrenamiento a la RNA durante el...
```

```
%%entrenamiento
```

```
net = []; %%creación de una RNA vacía para ser configurada
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Configuración de la red neuronal
artificial%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% configuración inicial de la red con valores por
defecto%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
if isempty(net)
    net = newff(P, T, Arquitect_NN);
    net = init(net);
end
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Ajuste de Parámetros de la
RNA:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
net.divideFcn = 'dividerand'; %%división interna de los datos (1)
net.trainFcn = 'trainoss'; %%algoritmo de entrenamiento (2)
net.trainParam.epochs = epocas; %%número de épocas
net.performFcn = 'sse'; %%indicador de desempeño (3)
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Opciones de
parámetros%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% (1) División interna de
datos:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%dividerand: divide los datos aleatoriamente (por defecto).
%%divideblock: divide los datos en bloques continuos.
%%divideint: divide los datos usando una selección en intervalos.
%%divideind: divide los datos por indexación.
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% (2) Algoritmos de
entrenamiento:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%trainlm: Levenberg-Marquardt (por defecto)
%%trainbr: Regularización Bayesiana (Bayesian Regularization)
%%trainbfg: BFGS Cuasi-Newton
%%trainrp: Propagación hacia atrás resiliente (Resilient Backpropagation)
%%trainscg: Gradiente conjugado escalonado (Scaled Conjugate Gradient)
%%traincgb: Conjugate Gradient with Powell/Beale Restarts
%%traincgp: Fletcher-Powell Conjugate Gradient
%%traincgp: Pollak-Ribière Conjugate Gradient
%%trainoss: One Step Secant
```

```

%%traingdx: Variable Learning Rate Gradient Descent
%%traingdm: Gradient Descent with Momentum
%%traingd: Gradient Descent

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%(3) Indicadores de
desempeño:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%sse: Sum Square Error
%%mse: Sum Square Error Mean
%%rmse: Sum Square Error Mean Root

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Entrenamiento de la red neuronal artificial
multicapa%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Entrenamiento:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

for i=1:1:100
[net, tr] = train(net, P, T);%%Se realiza el entrenamiento de net...
                %%mediante con los párametro P y T, que...
                %%contienen las entradas asociadas con...
                %%sus respectivas salidas%%

```

```

Y = sim(net, P);%%Y corresponde a la estimación de la salida, usando...
                %%la MLP entrenada%%

```

```
end
```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Visualización del red neuronal
artificial%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

clf
figure;
view (net)

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Elaboración de gráficos con el desempeño de la
red:%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

figure;
plotperf (tr)
grid on
hold on

```

```

a = min([Y T]);
b = max([Y T]);

```

```

%figure;
%plot(Y,T,'o')
%line([a b],[a b],'color', 'r')
%title('Estimación usando RNA')
%xlabel('Estimado [Unidad]')
%ylabel('Reportado [Unidad]')

```

```

figure;
plot(Y, 'bo-')
hold on
plot(T, 'r*-')
grid on
title('Estimación usando RNA')
xlabel('Registrado[Unidad]')
ylabel('Propiedad [Unidad]')
legend('Azul = Estimado', 'Rojo = Reportado')

```

```

%figure;
%plotregression (T, Y, 'Estimación usando RNA')
%hold on
%line([a b],[a b])
%grid on

```

%%%Almacenamiento de parámetros de la red neuronal artificial entrenada%%%

%%%%%%%%%%%%%%Almacenamiento de los pesos  
sinápticos:%%%%%%%%%

```

W = getx(net);
dlmwrite('Red_Pesos.dat', W)
%%%%%%%%%%%%%%Almacenamiento de la Arquitectura de la  
RNA:%%%%%%%%%

```

```

dlmwrite('Red_Arquitectura.dat', Arquit_NN)
%%%%%%%%%%%%%%Almacenamiento de los datos de entrada y salida  
objetivo:%%%%%%%%%

```

```

dlmwrite('Conjunto_Entradas.dat', P)
dlmwrite('Conjunto_Salidas.dat', T)
%%%%%%%%%%%%%%Cálculo del  
Error%%%%%%%%%
%%%%%%%%Cálculo de errores relativos y absolutos, ER y EA, respectivamente%%%
ER = sum (abs(Y - T)./T); %%Error relativo
EA = sum (abs(Y - T)); %%Error absoluto

```

```

Error_Estimados = [ER EA];

```

%%%Cálculo de indicadores de desempeño basados en errores estadísticos%%%

```

E_SSE = sse (Y,T);%%Sum Square Error
E_MSE = mse (Y,T);%%Sum Square Error Mean
E_RMSE = (E_MSE)^(0.5);%%Sum Square Error Mean Root

```

```

Error_Estadisticos = [E_SSE E_MSE E_RMSE];

```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Almacenamiento de los errores
calculados%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
dlmwrite('Errores_Estimados_Simulacion.dat',Error_Estimados)
dlmwrite('Errores_Estimados_Simulacion.csv',Error_Estimados);
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Almacenamiento de los errores estadísticos
calculados%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
dlmwrite('Errores_Estadísticos_Simulacion.dat',Error_Estadisticos)
```

```
dlmwrite('Errores_Estadisticos_Simulacion.csv',Error_Estadisticos);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
train_mlp_ann = net;
```

## C. ANEXO: CÓDIGO PARA LA ESTIMACIÓN DE LA RED

```
%%Codificación para el uso de una red neuronal artificial
%%multicapa, MLP (Multi-Layer Perceptron), con la cual se puedan hacer
estimaciones%%
```

```
%%%Elaborado por Luis Octavio González Salcedo, Profesor Asociado,
%%%Universidad Nacional de Colombia Sede Palmira, con fines exclusivamente
%%%académicos, para la enseñanza de redes neuronales artificiales, en
%%%cursos sobre la temática o de Inteligencia Artificial
```

```
%% Se debe escribir en la consola: use_mlp_ann([])%%
```

```
function [net] = use_mlp_ann (net)
```

```
%%%%%%%%Cargando variables de la red neuronal artificial entrenada:%%%%%%%%
```

```
Arquit_NN = dlmread('Red_Arquitectura.dat');
P = dlmread('Conjunto_Entradas.dat');
T = dlmread('Conjunto_Salidas.dat');
```

```
%%%%%%%%%%Inserte aquí sus
datos:%%%%%%%%%%
```

```
D = [];
```

```
%%%%%%%%Cargando la red neuronal artificial
entrenada:%%%%%%%%
```

```
if isempty(net)
    net = newff(P, T, Arquit_NN);
    try
        net = setx(net, W);
    catch
        disp('Problemas con el tamaño del vector W')
    end
end
```

```
%%%%%%%%Usando la red neuronal artificial
entrenada:%%%%%%%%
```

```
Y_sim = sim(net, D');
```

```
%%%%%%%%Almacenamiento de los valores estimados con la
RNA:%%%%%%%%
```

```
dlmwrite('Estimados_Simulacion.csv',Y_sim');  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
disp 'se estimó con la RNA, consultar archivo: Estimados_Simulacion.csv'
```

## D. ANEXO: SUBCONJUNTOS DE BASES DE DATOS

### Anexo D-1. Conjunto de entrenamiento 1.

TPR 1	TPR 2	TPR 4	TPR 5	TPR 6	RAZ 1	RAZ 2	RAZ 3	RAZ 4	RAZ 5	TLI 1	TLI 2	TLI 3	TLI 4	POE- 1	POE- 2	DENS	TI	HRI	PHC	NH3EB
1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	23	24	55	8.6	0.1013
1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	23	24	56	8.6	0.2591
1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	23	24	56	8.6	0.3955
1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	23	24	57	8.6	0.4848
1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	23	24	57	8.6	0.6046
0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	5	27.4	59	7.6	0.27397
0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	5	21.9	66	8.95	0.87671
0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	5	21.2	48	7.75	0.35616
0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	5	21.4	58	8.65	0.43836
0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	5	26.8	56	8.63	0.65753
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	24.5	46	8.16	0.19178
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	16.4	50	8.43	0.05479
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	11.4	54	8.17	0.19178
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	9	53	8.52	0.16438
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	8.5	50	7.52	0.21918
1	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	5	11.6	43	8.75	0.21918
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	46.5	23.3	73	7.5	0.1181
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	16.5	24.5	74	7.5	0.1654
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	16.5	22.5	77	7.5	0.1195
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	15.4	20.1	76	7.7	0.0903
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	15.7	22	79	7.6	0.0988
0	0	0	0	1	0	0	0	1	0	0	0	0	1	1	0	15.7	23.8	82	7.6	0.1363
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	26	59	8.07	0.64
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	26.9	66	7.9	0.83

0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	24.4	67	8.04	1.19
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	21	44	7.3	1.26
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	25.6	59	8.22	1.01
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	26.6	66	8.1	1.2
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	24.4	67	8.04	2.04
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	13.2	21.6	44	7.4	1.14
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	25	52	7.2	0.16728
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	24.7	54	7.8	0.20568
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	24.9	54	7.9	0.10176
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	26.7	54	7.4	0.1245
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	28.1	52	7.6	0.1197
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	23.1	59	7.1	0.021
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	23	53	7.6	0.1005
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	22.8	47	7.4	0.0741
0	1	0	0	0	0	0	0	0	1	0	0	0	1	1	0	10.24	22.2	51	7.3	0.05472
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	30.6	76	8	0.06857
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	27.5	73	8.3	1.2
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	25.1	60	8.5	3.51429
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	22.8	80	8.8	3.77143
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	30.9	73	8.4	0.17143
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	26.5	66	8.5	1.88571
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	24.3	66	8.6	4.45714
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	23.4	68	8.9	7.88571
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	30.6	76	8	0.10286
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	27.5	73	8.3	1.28571
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	25.1	60	8.5	3.94286
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	22.8	80	8.8	5.31429
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	30.9	73	8.4	0.15429
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	26.5	66	8.5	1.71429
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	24.3	66	8.6	7.2
0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	14	23.4	68	8.9	9.77143
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.6	22	50	9.6	1.22336
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.9	22	50	10	1.39598

0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.5	22	50	9.6	1.344
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.8	22	50	9.7	1.28842
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.9	22	50	10.3	1.28279
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23	22	50	10	1.57774
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.4	22	50	9.7	0.96
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.2	22	50	7.91	1.08
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.1	22	50	8.41	1.4213
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.3	22	50	8.42	1.48326
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.3	22	50	8.13	1.03828
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	24.2	22	50	8.37	1.57091
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	23.6	22	50	8.08	1.31797
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	22.8	22	50	8.42	1.32632
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	27.1	22	50	8.41	2.77373
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	26.9	22	50	8.72	3.43673
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	26.9	22	50	8.64	5.13903
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	26	22	50	8.44	3.78831
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	28	22	50	8.74	3.456
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	27.2	22	50	8.44	4.16118
0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	1	26.8	22	50	8.74	3.3206
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	23.6	23.1	63	7.5	0.0554
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	23.6	22.8	62	7	0.552
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	23.6	22	56	6.7	0.289
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	23.6	22	57	6.7	0.291
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	23.6	22.2	57	6.25	0.2457
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	19.2	22.4	66	8.4	0.1667
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	19.2	22.2	67	7.7	0.5181
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	19.2	21.5	61	7.6	0.3454
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	19.2	21.4	62	7.6	0.3186
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	19.2	21.6	61	7	0.2292
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	18.4	24.3	60	7.5	0.053
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	18.4	23.2	61	7	0.622
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	18.4	22.3	56	6.7	0.369
0	1	0	0	0	1	0	0	0	0	0	0	0	1	1	0	18.4	22.2	55	6.7	0.369

## Anexo D-2. Conjunto de entrenamiento 2.

TP1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	TL4	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
0	1	0	0	1	0	0	1	0	0	0	0	1	1	24	59	0	0	1	6.3805	16.5	1.94
0	1	0	0	1	0	0	1	0	0	0	0	1	2	29	55	0	0	1	9.95697	16.5	2.17
0	1	0	0	1	0	0	1	0	0	0	0	1	3	28.8	60	0	0	1	9.99645	16.5	2.25
0	1	0	0	1	0	0	1	0	0	0	0	1	4	22.5	55	0	0	1	6.46057	16.5	2.93
0	1	0	0	1	0	0	1	0	0	0	0	1	5	21.5	55	0	0	1	6.48771	16.5	2.59
0	1	0	0	1	0	0	1	0	0	0	0	1	6	20.1	50	0	0	1	5.97348	16.5	1.63
0	1	0	0	1	0	0	1	0	0	0	0	1	7	19.7	47	0	0	1	1.94895	16.5	1.52
0	1	0	0	1	0	0	1	0	0	0	0	1	8	19.7	47	0	0	1	1.95315	16.5	1.93
0	1	0	0	1	0	0	1	0	0	0	0	1	9	24.1	55	0	0	1	5.83202	16.5	2.57
0	1	0	0	1	0	0	1	0	0	0	0	1	10	24.2	55	0	0	1	8.99223	16.5	2.07
0	1	0	0	1	0	0	1	0	0	0	0	1	11	22.8	55	0	0	1	5.93847	16.5	1.84
0	1	0	0	1	0	0	1	0	0	0	0	1	12	21.7	55	0	0	1	2.6071	16.5	1.98
0	1	0	0	1	0	0	1	0	0	0	0	1	13	20.6	55	0	0	1	0.72612	16.5	0.71
0	1	0	0	0	0	1	0	0	0	1	1	0	1	20.7	71	0	1	0	1.04	15.5	0.342179
0	1	0	0	0	0	1	0	0	0	1	1	0	3	20	62	0	1	0	5.32	15.5	0.349315
0	1	0	0	0	0	1	0	0	0	1	1	0	4	21.3	67	0	1	0	5.32	15.5	0.368721
0	1	0	0	0	0	1	0	0	0	1	1	0	8	18.4	63	0	1	0	2.85	15.5	0.248857
0	1	0	0	0	0	1	0	0	0	1	1	0	11	19.4	70	0	1	0	2.03	15.5	0.214324
0	1	0	0	0	0	1	0	0	0	1	1	0	15	15.1	61	0	1	0	0.93	15.5	0.149396
0	1	0	0	0	0	1	0	0	0	1	1	0	18	12.2	61	0	1	0	0.94	15.5	0.135723
0	1	0	0	0	0	1	0	0	0	1	1	0	22	11	64	0	1	0	0.94	15.5	0.171801
0	1	0	0	0	0	1	0	0	0	1	1	0	25	11.7	65	0	1	0	1.19	15.5	0.35392
0	1	0	0	0	0	1	0	0	0	1	1	0	29	20.3	71	0	1	0	1.19	15.5	0.849408
0	1	0	0	0	0	1	0	0	0	1	1	0	31	21.3	67	0	1	0	1.21	15.5	0.792191
0	1	0	0	0	0	1	0	0	0	1	1	0	35	20.7	62	0	1	0	1.21	15.5	0.538256
0	1	0	0	0	0	1	0	0	0	1	1	0	37	20.1	61	0	1	0	1.15	15.5	0.422966
0	1	0	0	0	0	1	0	0	0	1	1	0	45	25	59	0	1	0	1.1	15.5	0.408815

0	0	1	0	1	0	0	0	0	1	0	0	1	1	31.5	31	1	0	0	1.9	19.2	0.03
0	0	1	0	1	0	0	0	0	1	0	0	1	4	29	45	1	0	0	2.2	19.2	0.035
0	0	1	0	1	0	0	0	0	1	0	0	1	10	27	55	1	0	0	0.5	19.2	0.003
0	0	1	0	1	0	0	0	0	1	0	0	1	12	25.5	55	1	0	0	0.7	19.2	0.007
0	0	1	0	1	0	0	0	0	1	0	0	1	18	26	46	1	0	0	0.8	19.2	0.008
0	0	1	0	1	0	0	0	0	1	0	0	1	23	26	51	1	0	0	2.2	19.2	0.012
0	0	1	0	1	0	0	0	0	1	0	0	1	26	26	45	1	0	0	3.4	19.2	0.025
0	0	1	0	1	0	0	0	0	1	0	0	1	28	24	40	1	0	0	2.9	19.2	0.021
0	0	1	0	1	0	0	0	0	1	0	0	1	32	22.5	56	1	0	0	4.5	19.2	0.16
0	0	1	0	1	0	0	0	0	1	0	0	1	35	21.5	75	1	0	0	4.9	19.2	0.17
0	0	1	0	1	0	0	0	0	1	0	0	1	40	20	68	1	0	0	5.7	19.2	0.255
0	0	1	0	1	0	0	0	0	1	0	0	1	1	32	28	1	0	0	2.3	19.2	0.035
0	0	1	0	1	0	0	0	0	1	0	0	1	4	29.5	42	1	0	0	2.5	19.2	0.035
0	0	1	0	1	0	0	0	0	1	0	0	1	10	27.5	57	1	0	0	1	19.2	0.02
0	0	1	0	1	0	0	0	0	1	0	0	1	12	26.5	59	1	0	0	2	19.2	0.04
0	0	1	0	1	0	0	0	0	1	0	0	1	18	25	54	1	0	0	1.9	19.2	0.035
0	0	1	0	1	0	0	0	0	1	0	0	1	23	25	66	1	0	0	2.3	19.2	0.02
0	0	1	0	1	0	0	0	0	1	0	0	1	26	25	59	1	0	0	4.2	19.2	0.06
0	0	1	0	1	0	0	0	0	1	0	0	1	28	23	56	1	0	0	4.4	19.2	0.065
0	0	1	0	1	0	0	0	0	1	0	0	1	32	22.5	69	1	0	0	4.2	19.2	0.335
0	0	1	0	1	0	0	0	0	1	0	0	1	35	22	75	1	0	0	6	19.2	0.38
0	0	1	0	1	0	0	0	0	1	0	0	1	40	20.5	70	1	0	0	5.7	19.2	0.57
0	0	1	0	1	0	0	0	0	1	0	0	1	1	32	33	1	0	0	1.8	19.2	0.04
0	0	1	0	1	0	0	0	0	1	0	0	1	4	29.5	50	1	0	0	1.8	19.2	0.035
0	0	1	0	1	0	0	0	0	1	0	0	1	10	27.5	60	1	0	0	1	19.2	0.02
0	0	1	0	1	0	0	0	0	1	0	0	1	12	26.5	65	1	0	0	1	19.2	0.04
0	0	1	0	1	0	0	0	0	1	0	0	1	18	25.5	62	1	0	0	4.5	19.2	0.055
0	0	1	0	1	0	0	0	0	1	0	0	1	23	25	68	1	0	0	2.2	19.2	0.02
0	0	1	0	1	0	0	0	0	1	0	0	1	26	25	60	1	0	0	6.3	19.2	0.001
0	0	1	0	1	0	0	0	0	1	0	0	1	28	25	58	1	0	0	7.4	19.2	0.18
0	0	1	0	1	0	0	0	0	1	0	0	1	32	22.5	67	1	0	0	3.3	19.2	0.235

0	0	1	0	1	0	0	0	0	1	0	0	1	35	22	72	1	0	0	8.8	19.2	0.38
0	0	1	0	1	0	0	0	0	1	0	0	1	40	20.5	73	1	0	0	9.2	19.2	0.7
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.00005
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.0001
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.00027
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.0006
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.002
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.006
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.00002
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.00005
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.00014
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.0003
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.001
1	0	0	1	0	0	0	0	1	0	0	1	0	28	22	45	1	0	0	2.6	19	0.003
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.0003
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.0006
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.002
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.005
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.011
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.03
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.0001
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.0002
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.001
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.004
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.005
1	0	0	1	0	0	0	0	1	0	0	1	0	56	22	45	1	0	0	2.6	18.25	0.026
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.0003
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.0003
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.001
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.003
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.016

1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.036
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.0001
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.0001
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.0006
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.002
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.014
1	0	0	1	0	0	0	0	1	0	0	1	0	84	22	45	1	0	0	4.8	17.5	0.023
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.005
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.012
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.041
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.098
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.179
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.251
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.007
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.012
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.029
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.064
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.114
1	0	0	1	0	0	0	0	1	0	0	1	0	206	22	45	1	0	0	4.8	17.5	0.16
0	0	1	0	0	1	0	0	0	1	0	0	1	28	26	59	0	0	1	2.8	18	0.64
0	0	1	0	0	1	0	0	0	1	0	0	1	35	26.9	66	0	0	1	4.8	20	0.83
0	0	1	0	0	1	0	0	0	1	0	0	1	28	24.4	67	0	0	1	3.5	18	1.19
0	0	1	0	0	1	0	0	0	1	0	0	1	14	21	44	0	0	1	5	24	1.26
0	0	1	0	0	1	0	0	0	1	0	0	1	28	25.6	59	0	0	1	3.7	18	1.01
0	0	1	0	0	1	0	0	0	1	0	0	1	35	26.6	66	0	0	1	4.3	20	1.2
0	0	1	0	0	1	0	0	0	1	0	0	1	35	24.4	67	0	0	1	4.8	20	2.04
0	0	1	0	0	1	0	0	0	1	0	0	1	28	21.6	44	0	0	1	3.8	18	1.14
0	1	0	1	0	0	0	0	0	0	1	1	0	17	23.1	63	0	1	0	3.53	16.8	0.0554
0	1	0	1	0	0	0	0	0	0	1	1	0	20	22.8	62	0	1	0	2.13	16.8	0.552
0	1	0	1	0	0	0	0	0	0	1	1	0	27	22	56	0	1	0	1.42	16.8	0.289
0	1	0	1	0	0	0	0	0	0	1	1	0	33	22	57	0	1	0	1.27	16.8	0.291

0	1	0	1	0	0	0	0	0	0	1	1	0	35	22.2	57	0	1	0	1.28	16.8	0.2457
0	1	0	1	0	0	0	0	0	0	1	1	0	17	22.4	66	0	1	0	3.86	16.8	0.1667
0	1	0	1	0	0	0	0	0	0	1	1	0	20	22.2	67	0	1	0	2.01	16.8	0.5181
0	1	0	1	0	0	0	0	0	0	1	1	0	27	21.5	61	0	1	0	1.33	16.8	0.3454
0	1	0	1	0	0	0	0	0	0	1	1	0	33	21.4	62	0	1	0	1.22	16.8	0.3186
0	1	0	1	0	0	0	0	0	0	1	1	0	35	21.6	61	0	1	0	1.2	16.8	0.2292
0	1	0	1	0	0	0	0	0	0	1	1	0	17	24.3	60	0	1	0	3.92	16.8	0.053
0	1	0	1	0	0	0	0	0	0	1	1	0	20	23.2	61	0	1	0	2.56	16.8	0.622
0	1	0	1	0	0	0	0	0	0	1	1	0	27	22.3	56	0	1	0	1.5	16.8	0.369
0	1	0	1	0	0	0	0	0	0	1	1	0	33	22.2	55	0	1	0	1.45	16.8	0.369
0	1	0	1	0	0	0	0	0	0	1	1	0	35	22.5	56	0	1	0	1.44	16.8	0.2846

## F. ANEXO: COEFICIENTES DE CORELACIÓN R

Anexo F-1. Coeficientes de correlación para todos los métodos de entrenamiento.

Metodo	Arquitectura			
	1 capa		2 capas	
	5 neuronas	20 neuronas en cada capa	5 neuronas	20 neuronas
trainlm	0.979	0.981	<b>0.982</b>	<b>0.990</b>
trainbr	NR	NR	NR	NR
trainbfg	0.911	0.968	0.974	0.983
trainrp	0.966	0.961	0.965	0.975
trainscg	0.910	0.984	0.977	0.984
traincgb	0.967	0.972	0.979	0.981
traincgf	0.994	0.989	<b>0.982</b>	<b>0.990</b>
traincgp	0.970	0.983	0.966	0.975
trainoss	0.941	0.950	0.978	0.980

traingdx	0.944	0.976	0.988	0.981
traingdm	0.865	0.904	0.955	0.965
traingd	0.784	0.952	0.724	0.939

**Anexo F-2. Coeficientes de correlación para los métodos de mejor desempeño (1 capa oculta, subconjunto de datos 1).**

Conjunto 1	Neuronas (1 Capa)																				
Método	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
traingcb	0.89 3	0.93 3	0.93 1	0.96 4	0.96 7	0.92 0	0.93 4	0.96 0	0.96 5	0.95 5	0.96 4	0.95 9	0.96 9	0.96 4	0.93 4	0.92 9	0.96 5	0.96 4	0.96 4	0.97 3	0.94 3
Traincgf	0.87 6	0.90 2	0.95 7	0.95 8	0.96 7	0.90 6	0.96 0	0.93 1	0.95 1	0.96 7	0.94 3	0.96 5	0.93 9	0.95 5	0.97 1	0.93 9	0.93 7	0.95 5	0.95 6	0.98 0	0.95 1
Trainlm	0.77 3	0.96 9	0.95 3	0.97 2	0.97 7	0.97 5	0.97 3	0.97 4	0.97 4	0.96 5	0.97 1	0.98 1	0.97 8	0.96 5	0.97 4	0.97 3	0.97 4	0.97 7	0.97 4	0.97 3	0.97 6
Trainoss	0.58 3	0.58 3	0.60 0	0.95 0	0.94 1	0.93 4	0.95 4	0.93 6	0.93 4	0.95 4	0.94 6	0.91 7	0.92 9	0.92 4	0.94 5	0.90 6	0.92 6	0.92 3	0.93 8	0.95 0	0.92 5
Trainrp	0.87 4	0.93 8	0.95 9	0.94 8	0.96 6	0.95 8	0.95 1	0.91 6	0.94 9	0.90 8	0.92 4	0.95 9	0.80 9	0.86 4	0.89 6	0.92 0	0.93 5	0.94 6	0.85 6	0.94 7	0.92 3

**Anexo F-3. Coeficientes de correlación para los métodos de mejor desempeño (1 capa oculta, subconjunto de datos 2).**

Conjunto 2	Neuronas (1 Capa)																						
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
Traincgb	0.946	0.958	0.963	0.963	0.962	0.703	0.972	0.965	0.967	0.971	0.967	0.966	0.957	0.956	0.968	0.963	0.960	0.974	0.963	0.962	0.967	0.973	0.965
Traincgf	0.957	0.949	0.966	0.958	0.964	0.960	0.960	0.962	0.966	0.966	0.963	0.966	0.963	9.620	0.973	0.965	0.976	0.964	0.969	0.963	0.968	0.965	0.957
trainlm	0.958	0.964	0.948	0.969	0.979	0.964	0.979	0.986	0.981	0.982	0.981	0.981	0.981	0.982	0.981	0.980	0.973	0.983	0.980	0.981	0.981	0.980	0.985
trainos	0.948	0.965	0.964	0.961	0.963	0.963	0.961	0.962	0.962	0.965	0.958	0.958	0.961	0.960	0.961	0.964	0.968	0.957	0.961	0.962	0.964	0.964	0.964
trainrp	0.943	0.964	0.964	0.957	0.951	0.963	0.966	0.946	0.966	0.951	0.953	0.917	0.689	0.957	0.958	0.956	0.957	0.963	0.942	0.955	0.961	0.964	0.968

**Anexo F-4. Coeficientes de correlación para los métodos de mejor desempeño (2 capas ocultas, subconjunto de datos 1).**

Conjunto 1	Neuronas (2 capas)																				
	1,1	2,2	3,3	4,4	5,5	6,6	7,7	8,8	9,9	10,10	11,11	12,12	13,13	14,14	15,15	16,16	17,17	18,18	19,19	20,20	21,21
metodo	0.905	0.945	0.943	0.976	0.979	0.932	0.946	0.972	0.977	0.967	0.976	0.971	0.981	0.976	0.946		0.977	0.976	0.974	0.980	0.951
traincgb	0.905	0.945	0.943	0.976	0.979	0.932	0.946	0.972	0.977	0.967	0.976	0.971	0.981	0.976	0.946	0.941	0.977	0.976	0.974	0.980	0.951

<b>traincgf</b>	0.89 1	0.91 7	0.97 2	0.97 3	0.98 2	0.92 1	0.97 5	0.94 6	0.96 6	0.98 2	0.95 8	0.98 0	0.95 4	0.97 0	0.98 6	0.954	0.95 2	0.97 0	0.97 1	0.98 5	0.96 6
<b>trainlm</b>	0.91 3	0.93 9	0.94 5	0.94 8	0.98 3	0.97 9	0.98 2	0.98 5	0.99 0	0.97 0	0.98 0	0.98 2	0.99 0	0.98 0	0.97 8	0.965	0.95 8	0.97 5	0.98 0	0.94 5	0.98 0
<b>trainoss</b>	0.59 8	0.59 8	0.61 5	0.96 5	0.95 6	0.94 9	0.96 9	0.95 1	0.94 9	0.96 9	0.96 1	0.93 2	0.94 4	0.93 9	0.96 0	0.921	0.94 1	0.93 8	0.95 3	0.96 5	0.94 0
<b>trainrp</b>	0.95 7	0.97 8	0.97 8	0.97 1	0.96 5	0.97 7	0.98 0	0.96 0	0.98 0	0.96 5	0.96 7	0.93 1	0.70 3	0.97 1	0.97 2	0.970	0.97 1	0.97 7	0.95 6	0.97 5	0.97 5

**Anexo F-4. Coeficientes de correlación para los métodos de mejor desempeño (2 capas ocultas, subconjunto de datos 2).**

Conjunto 2	Neuronas (2 capas)																						
	1,1	2,2	3,3	4,4	5,5	6,6	7,7	8,8	9,9	10,10	11,11	12,12	13,13	14,14	15,15	16,16	17,17	18,18	19,19	20,20	21,21	22,22	23,23
<b>Método</b>	1,1	2,2	3,3	4,4	5,5	6,6	7,7	8,8	9,9	10,10	11,11	12,12	13,13	14,14	15,15	16,16	17,17	18,18	19,19	20,20	21,21	22,22	23,23
<b>traincgb</b>	0.95 8	0.97 0	0.97 5	0.97 5	0.97 4	0.71 5	0.98 4	0.97 7	0.97 9	0.98 3	0.97 9	0.97 8	0.96 9	0.96 8	0.98 0	0.97 5	0.97 2	0.98 6	0.97 5	0.97 4	0.97 9	0.98 3	0.97 7
<b>traincgf</b>	0.97 3	0.96 5	0.98 2	0.97 4	0.98 0	0.97 6	0.97 6	0.97 8	0.98 2	0.98 2	0.97 9	0.98 2	0.97 9	9.63 6	0.98 9	0.98 1	0.99 2	0.98 0	0.98 5	0.97 9	0.98 4	0.98 1	0.97 3
<b>trainlm</b>	0.90 7	0.89 0	0.96 0	0.97 9	0.98 2	0.97 5	0.97 8	0.99 0	0.99 0	0.97 6	0.98 5	0.98 4	0.97 0	0.98 3	0.98 6	0.98 2	0.97 9	0.96 6	0.98 8	0.99 0	0.96 3	0.99 0	0.99 0
<b>trainoss</b>	0.96 3	0.98 0	0.97 9	0.97 6	0.97 8	0.97 8	0.97 6	0.97 7	0.97 7	0.98 0	0.97 3	0.97 3	0.97 6	0.97 5	0.97 6	0.97 9	0.98 3	0.97 2	0.97 6	0.97 7	0.97 9	0.98 0	0.97 9
<b>trainrp</b>	0.97 1	0.99 2	0.99 2	0.98 5	0.97 9	0.99 1	0.99 4	0.97 4	0.99 4	0.97 9	0.98 1	0.94 5	0.71 7	0.98 5	0.98 6	0.98 4	0.98 5	0.99 1	0.97 0	0.98 9	0.98 9	0.01 4	0.01 4

## G. ANEXO. ANÁLISIS DE SENSIBILIDAD.

### Anexo G-1. Análisis de sensibilidad (Edad de las aves)

P1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	TL4	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
1	0	0	1	0	0	0	0	0	1	0	1	0	1	25	65	0	0	1	5	20	1.1297
1	0	0	1	0	0	0	0	0	1	0	1	0	30	25	65	0	0	1	5	20	1.0373
1	0	0	1	0	0	0	0	0	1	0	1	0	60	25	65	0	0	1	5	20	1.4281
1	0	0	1	0	0	0	0	0	1	0	1	0	90	25	65	0	0	1	5	20	1.9609
1	0	0	1	0	0	0	0	0	1	0	1	0	120	25	65	0	0	1	5	20	3.4579
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5	20	4.2928
1	0	0	1	0	0	0	0	0	1	0	1	0	180	25	65	0	0	1	5	20	4.3473
1	0	0	1	0	0	0	0	0	1	0	1	0	210	25	65	0	0	1	5	20	4.139
1	0	0	1	0	0	0	0	0	1	0	1	0	240	25	65	0	0	1	5	20	4.034
1	0	0	1	0	0	0	0	0	1	0	1	0	270	25	65	0	0	1	5	20	3.902
0	1	0	1	0	0	0	0	0	1	0	1	0	1	25	65	0	0	1	5	20	0.6286
0	1	0	1	0	0	0	0	0	1	0	1	0	30	25	65	0	0	1	5	20	0.8054
0	1	0	1	0	0	0	0	0	1	0	1	0	60	25	65	0	0	1	5	20	1.5964
0	1	0	1	0	0	0	0	0	1	0	1	0	90	25	65	0	0	1	5	20	1.7301
0	1	0	1	0	0	0	0	0	1	0	1	0	120	25	65	0	0	1	5	20	1.843
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5	20	2.22593
0	1	0	1	0	0	0	0	0	1	0	1	0	180	25	65	0	0	1	5	20	2.2857
0	1	0	1	0	0	0	0	0	1	0	1	0	210	25	65	0	0	1	5	20	2.1907
0	1	0	1	0	0	0	0	0	1	0	1	0	240	25	65	0	0	1	5	20	2.2044
0	1	0	1	0	0	0	0	0	1	0	1	0	270	25	65	0	0	1	5	20	2.2032
0	0	1	0	0	1	0	0	0	1	0	1	0	13	25	65	0	0	1	5	20	1.0118

0	0	1	0	0	1	0	0	0	1	0	1	0	16	25	65	0	0	1	5	20	1.5657
0	0	1	0	0	1	0	0	0	1	0	1	0	19	25	65	0	0	1	5	20	1.9073
0	0	1	0	0	1	0	0	0	1	0	1	0	22	25	65	0	0	1	5	20	2.584
0	0	1	0	0	1	0	0	0	1	0	1	0	25	25	65	0	0	1	5	20	5.2511
0	0	1	0	0	1	0	0	0	1	0	1	0	28	25	65	0	0	1	5	20	5.3829
0	0	1	0	0	1	0	0	0	1	0	1	0	31	25	65	0	0	1	5	20	5.4697
0	0	1	0	0	1	0	0	0	1	0	1	0	34	25	65	0	0	1	5	20	5.4539
0	0	1	0	0	1	0	0	0	1	0	1	0	37	25	65	0	0	1	5	20	5.6073
0	0	1	0	0	1	0	0	0	1	0	1	0	40	25	65	0	0	1	5	20	5.5551

## Anexo G-2. Análisis de sensibilidad (Temperatura del galpón).

TP1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	TL4	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
1	0	0	1	0	0	0	0	0	1	0	1	0	150	13	65	0	0	1	5	20	0.4372
1	0	0	1	0	0	0	0	0	1	0	1	0	150	16	65	0	0	1	5	20	0.4717
1	0	0	1	0	0	0	0	0	1	0	1	0	150	19	65	0	0	1	5	20	0.5022
1	0	0	1	0	0	0	0	0	1	0	1	0	150	22	65	0	0	1	5	20	0.5980
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5	20	2.039
1	0	0	1	0	0	0	0	0	1	0	1	0	150	28	65	0	0	1	5	20	3.3798
1	0	0	1	0	0	0	0	0	1	0	1	0	150	31	65	0	0	1	5	20	4.2928
1	0	0	1	0	0	0	0	0	1	0	1	0	150	34	65	0	0	1	5	20	4.8006
1	0	0	1	0	0	0	0	0	1	0	1	0	150	37	65	0	0	1	5	20	5.047
1	0	0	1	0	0	0	0	0	1	0	1	0	150	40	65	0	0	1	5	20	5.1435
0	1	0	1	0	0	0	0	0	1	0	1	0	150	13	65	0	0	1	5	20	0.5127
0	1	0	1	0	0	0	0	0	1	0	1	0	150	16	65	0	0	1	5	20	0.562
0	1	0	1	0	0	0	0	0	1	0	1	0	150	19	65	0	0	1	5	20	0.652
0	1	0	1	0	0	0	0	0	1	0	1	0	150	22	65	0	0	1	5	20	0.6727

0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5	20	0.7787
0	1	0	1	0	0	0	0	0	1	0	1	0	150	28	65	0	0	1	5	20	1.2407
0	1	0	1	0	0	0	0	0	1	0	1	0	150	31	65	0	0	1	5	20	1.7593
0	1	0	1	0	0	0	0	0	1	0	1	0	150	34	65	0	0	1	5	20	2.0686
0	1	0	1	0	0	0	0	0	1	0	1	0	150	37	65	0	0	1	5	20	2.252
0	1	0	1	0	0	0	0	0	1	0	1	0	150	40	65	0	0	1	5	20	2.362
0	0	1	0	0	1	0	0	0	1	0	1	0	25	13	65	0	0	1	5	20	0.4825
0	0	1	0	0	1	0	0	0	1	0	1	0	25	16	65	0	0	1	5	20	0.5328
0	0	1	0	0	1	0	0	0	1	0	1	0	25	19	65	0	0	1	5	20	0.5699
0	0	1	0	0	1	0	0	0	1	0	1	0	25	22	65	0	0	1	5	20	1.0378
0	0	1	0	0	1	0	0	0	1	0	1	0	25	25	65	0	0	1	5	20	2.0186
0	0	1	0	0	1	0	0	0	1	0	1	0	25	28	65	0	0	1	5	20	2.9158
0	0	1	0	0	1	0	0	0	1	0	1	0	25	31	65	0	0	1	5	20	3.4014
0	0	1	0	0	1	0	0	0	1	0	1	0	25	34	65	0	0	1	5	20	3.5682
0	0	1	0	0	1	0	0	0	1	0	1	0	25	37	65	0	0	1	5	20	3.7601
0	0	1	0	0	1	0	0	0	1	0	1	0	25	40	65	0	0	1	5	20	3.7868

### Anexo G-3. Análisis de sensibilidad (Humedad relativa ambiente).

TP1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	TL4	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	33	0	0	1	5	20	1.64
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	40	0	0	1	5	20	1.82
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	47	0	0	1	5	20	2.54
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	54	0	0	1	5	20	3.11
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	61	0	0	1	5	20	3.21
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	68	0	0	1	5	20	3.3
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	75	0	0	1	5	20	3.4
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	82	0	0	1	5	20	3.7

1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	89	0	0	1	5	20	4.07
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	96	0	0	1	5	20	4.32
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	33	0	0	1	5	20	1.69
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	40	0	0	1	5	20	1.78
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	47	0	0	1	5	20	2.03
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	54	0	0	1	5	20	2.7
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	61	0	0	1	5	20	3.3
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	68	0	0	1	5	20	3.78
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	75	0	0	1	5	20	4.14
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	82	0	0	1	5	20	4.41
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	89	0	0	1	5	20	4.62
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	96	0	0	1	5	20	4.77
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	33	0	0	1	5	20	1.48
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	40	0	0	1	5	20	1.83
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	47	0	0	1	5	20	2.46
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	54	0	0	1	5	20	3.42
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	61	0	0	1	5	20	3.89
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	68	0	0	1	5	20	3.99
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	75	0	0	1	5	20	4.02
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	82	0	0	1	5	20	4.01
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	89	0	0	1	5	20	4.07
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	96	0	0	1	5	20	4.16

#### Anexo G-4. Análisis de sensibilidad (flujo de aire)

TP1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	TL4	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	0.5	20	0.374
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	1.5	20	0.4731

1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	2.5	20	1.1746
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	3.5	20	1.9669
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	4.5	20	2.4881
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5.5	20	2.7951
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	6.5	20	2.9799
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	7.5	20	3.0950
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	8.5	20	3.1646
1	0	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	9.5	20	3.1995
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	0.5	20	0.3951
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	1.5	20	0.8745
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	2.5	20	1.9529
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	3.5	20	2.8658
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	4.5	20	3.4831
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5.5	20	3.8565
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	6.5	20	4.1246
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	7.5	20	4.3262
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	8.5	20	4.4874
0	1	0	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	9.5	20	4.6189
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	0.5	20	0.3507
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	1.5	20	0.5742
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	2.5	20	0.9609
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	3.5	20	1.3543
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	4.5	20	1.7356
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	5.5	20	1.8427
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	6.5	20	2.0348
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	7.5	20	2.1763
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	8.5	20	2.2564
0	0	1	1	0	0	0	0	0	1	0	1	0	150	25	65	0	0	1	9.5	20	2.3050

## Anexo G-5. Análisis de sensibilidad (densidad de aves).

TPR 1	TPR 2	TPR 4	TPR 5	TPR 6	RAZ 1	RAZ 2	RAZ 3	RAZ 4	RAZ 5	TLI 1	TLI 2	TLI 3	POE 1	POE 2	DENS	TI	HRI	NH3EB
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	2	25	65	0.3818
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	3	25	65	0.4429
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	4	25	65	0.4757
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	5	25	65	0.4838
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	6	25	65	0.5095
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	7	25	65	1.6497
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	8	25	65	3.7004
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	9	25	65	5.4048
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	10	25	65	7.2071
1	0	0	0	0	1	0	0	0	0	0	0	1	1	0	11	25	65	7.8659
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	2	25	65	0.4223
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	3	25	65	0.4466
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	4	25	65	0.3082
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	5	25	65	0.4651
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	6	25	65	0.8782
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	7	25	65	1.87839
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	8	25	65	4.10789
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	9	25	65	4.70932
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	10	25	65	6.251
0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	11	25	65	6.9544
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	2	25	65	0.4122

0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	3	25	65	0.4823
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	4	25	65	0.4509
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	5	25	65	0.3985
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	6	25	65	0.8631
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	7	25	65	3.4709
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	8	25	65	4.6213
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	9	25	65	5.7255
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	10	25	65	6.0616
0	0	0	1	0	1	0	0	0	0	0	0	1	1	0	11	25	65	6.214

## Anexo G-6. Análisis de sensibilidad (pH)

TPR 1	TPR 2	TPR 4	TPR 5	RAZ 1	RAZ 2	RAZ 3	RAZ 5	TLI 1	TLI 2	TLI 3	POE 1	POE 2	DENS	TI	HRI	PHC	NH3EB
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	6	0.3432
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	6.5	0.4772
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	7	0.6698
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	7.5	0.7247
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	8	0.9956
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	8.5	1.262
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	9	1.7063
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	9.5	3.001
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	10	5.3459
0	0	1	0	0	1	0	0	1	0	0	0	1	18	25	65	10.5	6.09576
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	6	0.3552
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	6.5	0.1819
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	7	0.1683

0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	7.5	0.4095
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	8	1.1337
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	8.5	2.729
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	9	5.1754
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	9.5	7.32667
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	10	8.45971
0	0	1	0	0	1	0	0	0	1	0	0	1	18	25	65	10.5	8.9253
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	6	0.3374
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	6.5	0.3554
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	7	0.3767
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	7.5	0.4005
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	8	0.6237
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	8.5	0.6702
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	9	0.9177
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	9.5	1.8853
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	10	3.7793
0	0	1	0	0	1	0	1	0	0	1	0	1	18	25	65	10.5	4.66248

## Anexo G-7. Análisis de sensibilidad (Contenido de proteína en alimento)

TP1	TP2	TP5	R1	R2	R3	R5	TL1	TL2	TL3	HEN	BIRD	EDAD	TI	HRI	TQ1	TQ2	TQ3	QH	CPD	NH3EB
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	15	0.60
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	16	0.68
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	17	0.76
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	18	0.84
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	19	0.92
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	20	1.00

1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	21	1.08
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	22	1.17
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	23	1.26
1	0	0	1	0	0	0	0	0	1	1	0	150	25	65	0	0	1	5	24	1.35
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	15	0.71
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	16	0.88
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	17	1.02
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	18	1.14
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	19	1.26
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	20	1.36
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	21	1.45
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	22	1.54
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	23	1.62
0	0	1	0	1	0	0	0	0	1	0	1	25	25	65	0	0	1	5	24	1.70
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	15	0.72
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	16	0.77
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	17	0.85
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	18	0.88
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	19	0.95
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	20	1.03
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	21	1.16
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	22	1.22
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	23	1.31
0	0	1	0	0	1	0	0	0	1	0	1	25	25	65	0	0	1	5	24	1.39
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	15	0.50
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	16	0.56
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	17	0.62
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	18	0.68
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	19	0.74
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	20	0.80
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	21	0.87

1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	22	0.95
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	23	1.03
1	0	0	0	0	0	1	0	0	1	1	0	150	25	65	0	0	1	5	24	1.11

### Anexo G-8. Análisis de sensibilidad (acumulación de estiércol)

TP1	TP2	TP3	TP4	TP5	TP6	R1	R2	R3	R4	R5	R6	TL1	TL2	TL3	TL4	HEN	BIRD	DENS	EDAD	MA	TI	TQ1	TQ2	TQ3	TQ4	NH3EB
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	1	24	1	0	0	0	0.984
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	15	24	1	0	0	0	3.3518
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	30	24	1	0	0	0	5.3214
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	45	24	1	0	0	0	6.5844
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	60	24	1	0	0	0	7.6565
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	75	24	1	0	0	0	8.5823
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	90	24	1	0	0	0	9.5556
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	105	24	1	0	0	0	10.602
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	120	24	1	0	0	0	11.606
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	135	24	1	0	0	0	12.603
1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	30	150	150	24	1	0	0	0	13.278
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	1	24	1	0	0	0	0.8267
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	5	24	1	0	0	0	1.0606
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	10	24	1	0	0	0	2.1049
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	15	24	1	0	0	0	3.2573
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	20	24	1	0	0	0	4.6674
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	25	24	1	0	0	0	5.6192
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	30	24	1	0	0	0	6.4402

0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	35	24	1	0	0	0	7.4649
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	40	24	1	0	0	0	8.3197
0	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	30	150	45	24	1	0	0	0	9.0766
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	1	24	1	0	0	0	0.7368
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	5	24	1	0	0	0	1.8989
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	10	24	1	0	0	0	2.9791
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	15	24	1	0	0	0	4.1049
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	20	24	1	0	0	0	5.3087
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	25	24	1	0	0	0	6.4586
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	30	24	1	0	0	0	7.6771
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	35	24	1	0	0	0	8.9257
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	40	24	1	0	0	0	10.212
0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	1	0	30	40	45	24	1	0	0	0	11.518