

## **Predicción de la temperatura y humedad absoluta en una granja de pollos**

SALAZAR-MORENO, Raquel, ROJANO-AGUILAR, Fernando, FITZ-RODRÍGUEZ, Efrén y LÓPEZ-CRUZ, Irineo L.

R. Salazar, F. Rojano, E. Fitz y I. López

Universidad Autónoma Chapingo, Km 38.5 Carr. México-Texcoco Chapingo, Edo. México, C.P 56230. México

University of Arizona.  
raquels60@hotmail.com

F. Pérez, E. Figueroa, L. Godínez, R. Pérez (eds.) Ciencias de la Biología, Agronomía y Economía. Handbook T-II.- ©ECORFAN, Texcoco de Mora, México, 2017.

## Abstract

The wind direction may influence weather conditions in chicken farms and therefore it can affect the broilers development and productivity. In order to study these effects, information of a cycle of organic production (84 days) in a broiler house at the experimental station “Le Magneraud” located in western France (46.15 N, -0.69 W) was used. Data was divided according to different intervals of wind direction. Artificial Neural Network (ANN) models were trained validated and tested at each location, using a wind direction rank between  $36.5^{\circ}$  - $100.5^{\circ}$ , for prediction of temperature and absolute humidity within the farm. Using the models developed, a simulation was performed for four different ranges of wind direction, the results show that ANN predict very well even for wind direction ranges far away from the values used in training. Using this outcomes, the locations more sensitive to wind direction can be identified.

## 10 Introducción

Aunque la idea de las redes neuronales fue propuesta hace más de 50 años por McCulloch y Pittis, el desarrollo de las técnicas de las redes neuronales experimentó un renacimiento hasta 1982, gracias a los esfuerzos de Hopfield en las redes autoasociativas (Govindaraju, 2000). El enfoque de la red neuronal artificial juega un papel importante en construir modelos cuantitativos así como la predicción de variables y es importante para la toma de decisiones (Yildirim, et al., 2011; Veselý, 2011).

El aprendizaje de la red se define como el proceso en el cual se ajustan los parámetros, entre los que se destacan los pesos y los sesgos. Este proceso de ajuste se realiza con el objetivo de minimizar la diferencias entre la variable real y la simulada con la red. Los cuatro tipos de aprendizajes más empleados son: el supervisado, el no supervisado o autoorganizativo, el híbrido y finalmente, el aprendizaje reforzado (Brío y Sanz 2007).

Las redes neuronales artificiales se han utilizado en la modelación de sistemas agrícolas, particularmente en la modelación de la eficiencia económica de la producción de pollos, donde las variables de entrada fueron la cantidad de insumos de la producción y como salida el desempeño económico de las unidades de producción, los autores mostraron que una red neuronal con dos capas ocultas con 4 y 17 neuronas en cada capa oculta respectivamente, provee los mejores resultados con un coeficiente de correlación  $R^2=0.96$  and MSE 0.00024 (Sefat et al. 2014).

Otra aplicación importante de las redes neuronales es en la detección de lecturas erróneas en los sensores, Kulacov y Davcev (2005) aplicaron los modelos de redes neuronales para detectar sensores erróneos y encontraron que el modelo es robusto a pequeñas variaciones de las entradas.

En este trabajo, se evalúa la confiabilidad y precisión de un modelo de redes neuronales para predecir el clima interior (temperatura y humedad absoluta) en diferentes zonas de una granja de pollos gobernado mayormente por las condiciones climáticas externas.

### 10.1 Objetivos

1. Construir una red neuronal para predecir el clima dentro de una granja de pollos en 15 diferentes ubicaciones, utilizando datos experimentales del interior y exterior pero fijando la dirección del viento en un rango de  $36.56^{\circ}$  a  $100.5^{\circ}$  en dirección de la veleta.

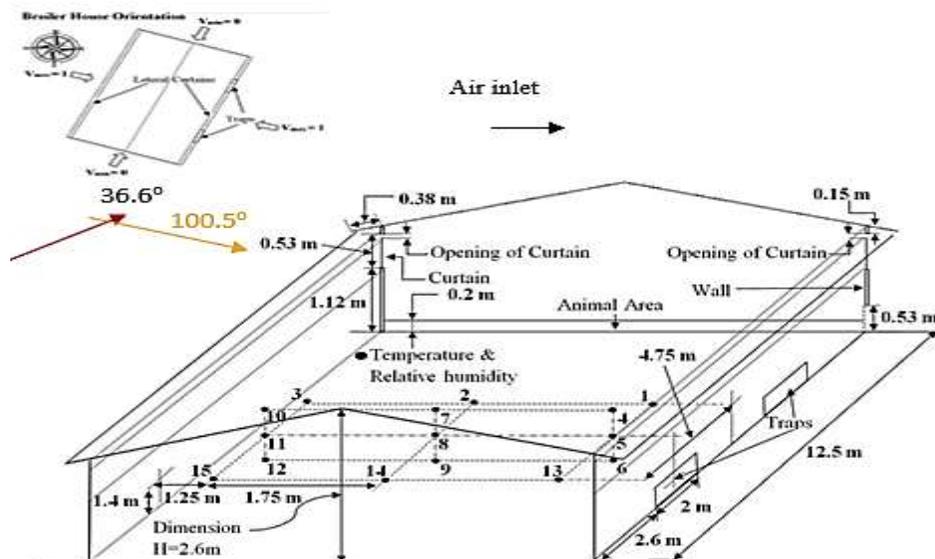
2. Utilizar la red neuronal entrenada y validada para predecir la temperatura y humedad absoluta interior en las 15 diferentes ubicaciones (donde se localizan los sensores), para 4 periodos de tiempo en donde se tienen diferentes direcciones del viento. Lo anterior es para evaluar que tan efectiva es la red neuronal en la predicción de la temperatura y humedad absoluta, para rangos de dirección del viento fuera de su rango de entrenamiento.

## 10.2 Metodología

### 10.2.1 Granja experimental

La información utilizada corresponde a un ciclo de producción (84 días) de la estación experimental en Francia “Le Magneraud” localizada en el Oeste (46.15 N, -0.69 W). La granja de pollos tiene un volumen de 158.4 m<sup>3</sup> con ventilación natural a través de ventanas laterales con una apertura máxima de 0.53 m. En la Figura 10 se muestra el esquema de la granja y la ubicación de los sensores. Las paredes y techo están construidas con espuma con un anel de acero en el exterior del techo. Los pollos se mantienen dentro de la granja durante los primeros 35 días, después de ese tiempo se les permite salir a un patio exterior de las 9:00h -17:00h. La estación experimental cuenta con una estación meteorológica localizada a 30 m afuera de la granja, en donde se miden las variables: velocidad y dirección del viento, temperatura, humedad relativa, y radiación solar. Dentro de la granja se trazó un plano vertical y horizontal para monitorear el clima y la calidad del aire. El plano vertical se define por tres ejes (B, C and D) localizados a 0.7 m, 1.4 m y 2 m del piso. En cada eje se midió la temperatura y humedad relativa interna con un data logger (DL-101T USB, Voltcraft, France). En el plano horizontal se consideraron también tres ejes (A, C and E) a 1.4 m del piso y con distancia entre ellos de 4.75 m; se colocaron seis sensores desde el techo al piso. Los datos exteriores e interiores tienen frecuencia de 10 min durante todo el ciclo de producción.

**Figura 10** Esquema de la granja y localización de sensores



Debido a que la dirección del viento puede influir en las condiciones internas de la granja y en el desarrollo de los pollos, los datos disponibles se dividieron en seis periodos de acuerdo a la dirección del viento descritos en la Tabla 10 y Figura 10.1.

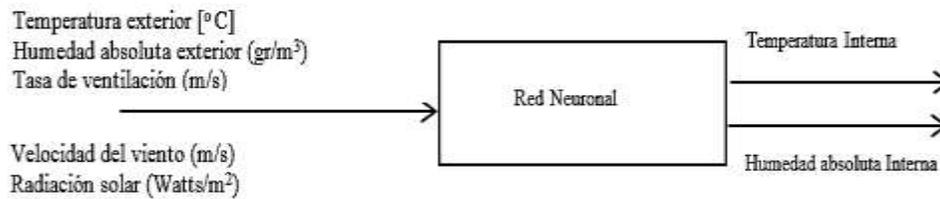
**Tabla 10** Dirección del viento en diferentes periodos

Periodo	Dirección del viento	Periodo	Dirección del viento
1: (11 junio 2014, 7 am -13 junio 2014, 2 pm)	(36.56° -100.5°) Rango=11.8 Desv Est=63.64	4: (21 junio 2014, 16:29 hrs -23 junio 2014, 18:10 hrs)	39.25° -282° Rango =242.75 Desv Est =40.81
2: (16 junio 2014, 0.40 hrs-18 junio 2014, 1:10 hrs)	40.76° -86.3° Rango =45.54 Desv Est =7.75	5: (23 junio 2014, 18:20 hrs -25 junio 2014, 20:20 hrs)	39.74° -294.9° Rango =255.16 Desv Est =58.98
3: (19 junio 2014, 23:30 hrs -21 junio 2014, 15.40 hrs)	40.57° -105.8° Rango =65.23 Desv Est =10.8	6: (25 junio 2014, 20:30 -27 junio 2014, 22:10 hrs)	149° -275.5° Rango =126.5 Desv Est =22.16

**10.2.2 Descripción de la red neuronal**

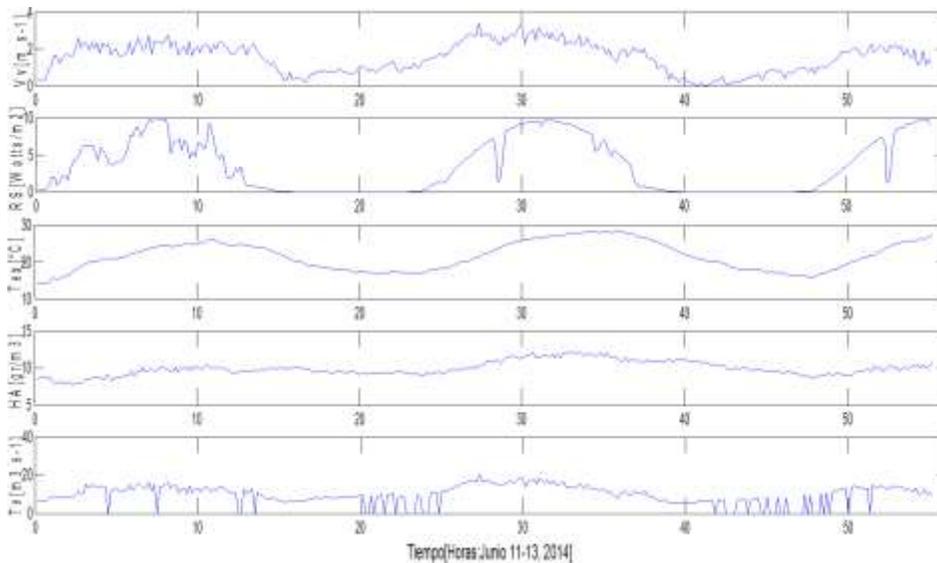
Los datos de los periodos 1 y 2 en los que la dirección del viento se encuentra entre 36.56 ° -100.5°, se utilizaron para entrenar, validar y probar las redes neuronales para las 15 localizaciones descritas en la Figura 10. En la Figura 10.1 se presenta las variables de entrada y salida de las redes neuronales.

**Figura 10.1** Esquema general de la red neuronal utilizada para entrenamiento validación y prueba para las 15 ubicaciones en los periodos 1 y 2 WV'; SR'; Tout'; Ahout'; Ventrante'



El comportamiento de las variables utilizadas como entradas en la red neuronal se despliega en los Gráficos 10 y 10.1 para los periodos 1 y 2.

**Gráfico 10** Comportamiento de las variables externas: flujo de aire, humedad absoluta, temperatura, radiación solar y velocidad del viento para el periodo 1

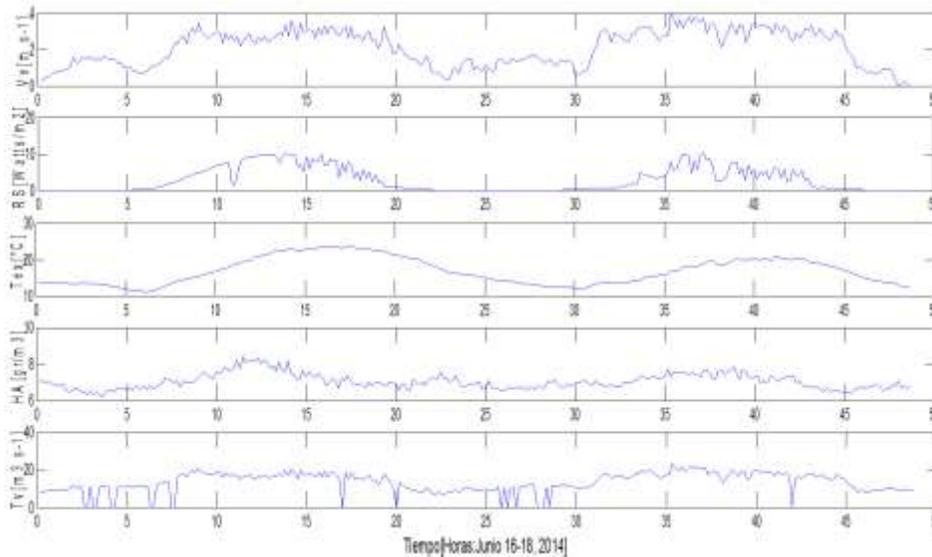


Las redes neuronales construidas, tienen una sola capa oculta y el número máximo de neuronas en la capa oculta se determinó utilizando los siguientes criterios

$$h = \sqrt{mn}; \quad h = n; \quad h = 2n + 1$$

El criterio  $h=2n+1$  propuesto por Hecht-Nielsen (1987), citado por Palazón, y García, (2004). el segundo criterio  $h=\sqrt{mn}$ ; propuesto por Masters, (1993). Finalmente, se probó un criterio adicional intermedio el cual es  $h=n$ ; Dónde:  $h$  es el número máximo de neuronas;  $n$  es el número de variables de entrada y  $m$  es el número de salidas.

**Gráfico 10.1** Comportamiento de las variables externas: flujo de aire, humedad absoluta, temperatura, radiación solar y velocidad del viento para el periodo 2



La función transferencia utilizada fue la Tangente Hiperbólica, la función de entrenamiento fue Levenberg-Marquardt backpropagation y la función de aprendizaje fue la del gradiente descendente por impulso, posteriormente, la información se dividió en tres partes: entrenamiento (60%), validación (20%) y prueba (20%).

### 10.2.3 Medidas de ajuste

Para medir el ajuste del modelo a los datos medidos se calculó el error cuadrado medio, la raíz del error cuadrado medio, el error absoluto y la eficiencia (Wallach et al., 2013).

a) Error cuadrado medio (MSE).

El error cuadrado medio (MSE) es la medida más utilizada, y se define a continuación

$$MSE = \left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (10)$$

Donde  $y_i$  es el valor medido,  $\hat{y}_i$  el valor simulado y  $n$  el número de mediciones. Debido a que MSE es un promedio de las diferencias al cuadrado, grandes diferencias son muy ponderadas. Es importante verificar si MSE no se debe esencialmente a uno o dos grandes diferencias.

b) Raíz del error cuadrado medio (RMSE).

En ocasiones es más conveniente trabajar con la raíz del error cuadrado medio (RMSE), que tiene las mismas unidades:

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (10.1)$$

c) Error absoluto medio.

Una alternativa resumida de la medida del error del modelo, que al igual que MSE evita la compensación entre la sub predicción y sobre predicción, es el error absoluto medio (MAE):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10.2)$$

Las unidades de MAE son las mismas que para MSE; no existe sobre ponderación de las grandes diferencias. Así MAE tiene ventajas sobre MSE o RMSE, si el objetivo es simplemente para examinar el error global del modelo (Willmott y Matura, 2005).

Una ventaja del MSE es que se puede descomponer en contribuciones separadas. La mayoría de las veces  $\text{MAE} \leq \text{RMSE}$ , y la igualdad sólo se produce si todos los errores que se promediaron son iguales.

d) Eficiencia.

La medida más utilizada y con mayor credibilidad probablemente es el que determina la eficiencia del modelo definido como (Wallach et al., 2013).

$$EF = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (10.3)$$

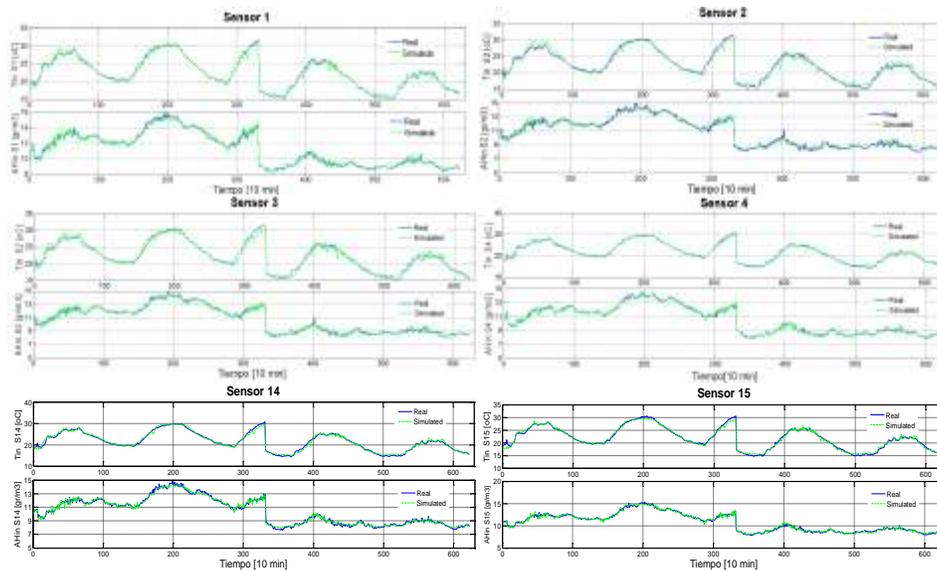
El mismo autor menciona que, si el modelo es perfecto los valores predichos serán igual a los valores observados o medidos ( $Y_i = \hat{Y}_i$ ), por lo tanto, la eficiencia del modelo será  $EF = 1$ . Por otro lado, un modelo con  $EF = 0$  significa que el predictor no es mejor que la esperanza matemática ( $\bar{Y}_i = \hat{Y}_i$ ), por ende, no será un buen modelo, además si  $EF < 0$ , quiere decir que el predictor es peor estimador que la esperanza matemática.

### 10.3 Resultados y discusión

Al desarrollar las tres metodologías para establecer el número máximo de neuronas en la capa oculta, el criterio que tuvo mejor desempeño fue el de  $h=2n+1$ . Se obtuvieron buenos resultados con una red estática con 11 nodos en la capa oculta.

En el Gráfico 10.2 se presenta un ejemplo de la comparación entre los resultados reales y predichos de temperatura y humedad absoluta en el entrenamiento, validación y prueba de la red neuronal para los periodos 1 y 2 y seis ubicaciones.

**Gráfico 10.2** Comparación entre la temperatura y humedad absoluta medidos y predichos para seis sensores, en el entrenamiento validación y prueba de la red neuronal (periodos 1 y 2)



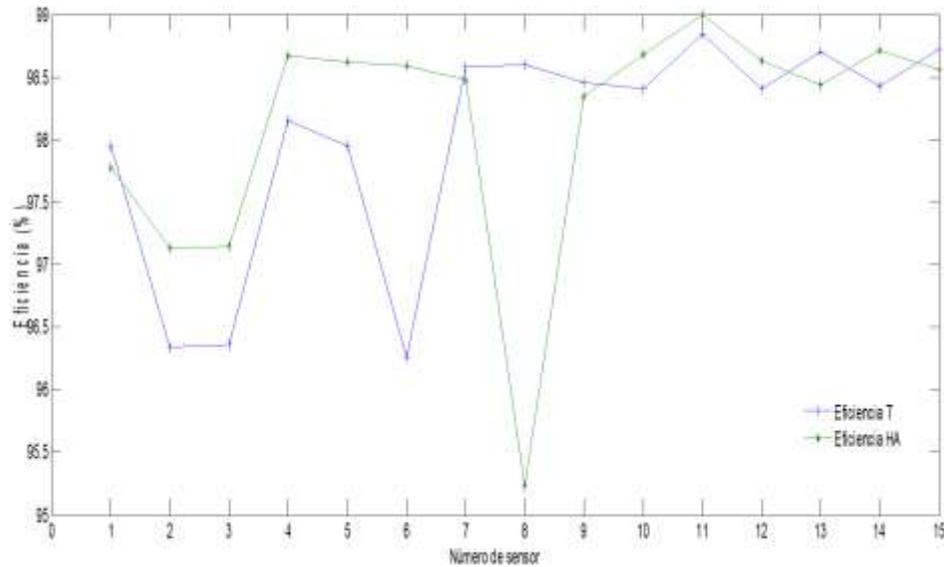
Los resultados de las medidas de ajuste para la temperatura y humedad absoluta dentro de la granja se presentan en la Tabla 10.1.

**Tabla 10.1** Resultados del entrenamiento validación y prueba de la red neuronal para las 15 ubicaciones dentro de la granja

Sensor	MSET	RMSET	MAET	EFT	MSEAH	RMSEAH	MAEAH	EFAH	No Iter
1	0.384	0.620	0.478	0.979	0.100	0.317	0.244	0.978	54
2	0.677	0.823	0.609	0.963	0.112	0.335	0.257	0.971	38
3	0.674	0.821	0.613	0.964	0.112	0.334	0.257	0.971	69
4	0.337	0.581	0.431	0.982	0.051	0.225	0.178	0.987	99
5	0.387	0.622	0.441	0.979	0.060	0.245	0.185	0.986	77
6	0.734	0.857	0.564	0.963	0.060	0.245	0.186	0.986	80
7	0.258	0.508	0.374	0.986	0.067	0.259	0.199	0.985	76
8	0.261	0.511	0.376	0.986	0.186	0.431	0.341	0.952	111
9	0.286	0.535	0.397	0.985	0.064	0.253	0.198	0.983	58
10	0.299	0.547	0.417	0.984	0.065	0.254	0.196	0.987	73
11	0.219	0.468	0.359	0.988	0.046	0.215	0.167	0.990	94
12	0.295	0.543	0.424	0.984	0.055	0.235	0.180	0.986	75
13	0.237	0.487	0.368	0.987	0.062	0.249	0.193	0.984	85
14	0.292	0.540	0.405	0.984	0.050	0.225	0.176	0.987	73
15	0.240	0.489	0.366	0.987	0.060	0.245	0.187	0.986	75

La eficiencia del modelo para el periodo 1 y 2, oscila entre 0.971 y 0.99 para el caso de la temperatura y entre 0.952 y 0.99 para humedad absoluta (Gráfico 10.3).

**Gráfico 10.3** Eficiencia del modelo de redes neuronales en la predicción de temperatura y humedad absoluta dentro de la granja, en los periodos 1 y 2



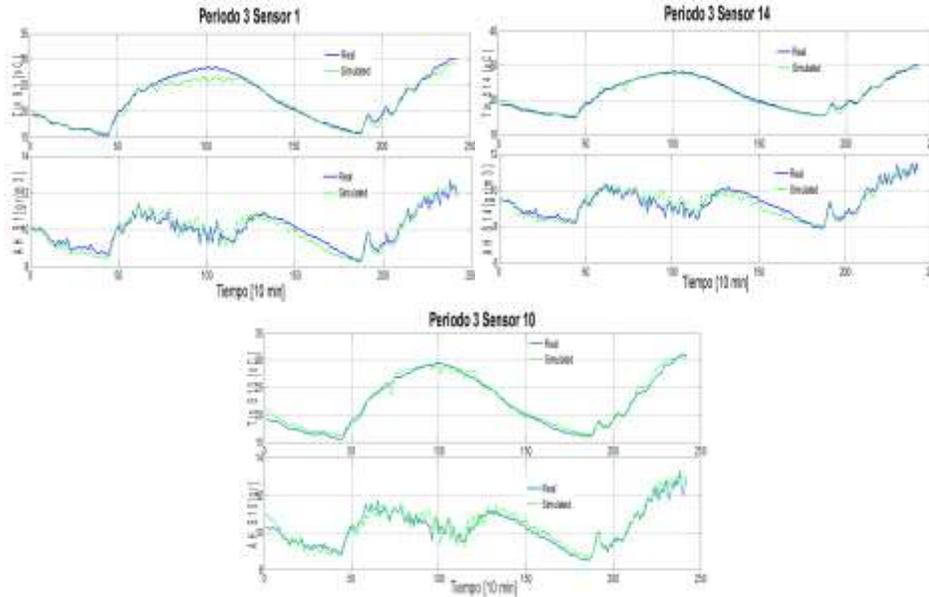
**Tabla 10.2** Medidas de ajuste en la simulación del periodo 3 para los 15 sensores

MEDIDAS DE AJUSTE PREDICCIÓN PERIODO 3								
Sensor	MSET	RMSET	MAET	EFT	MSEAH	RMSEAH	MAEAH	EFAH
1	1.105	1.051	0.779	0.945	0.070	0.264	0.199	0.916
2	0.795	0.892	0.684	0.959	0.161	0.401	0.322	0.723
3	1.100	1.049	0.774	0.948	0.058	0.240	0.184	0.913
4	0.266	0.516	0.391	0.987	0.193	0.439	0.324	0.671
5	0.952	0.976	0.670	0.951	0.070	0.264	0.205	0.903
6	3.137	1.771	0.969	0.860	0.141	0.376	0.264	0.832
7	0.417	0.646	0.498	0.980	0.076	0.275	0.216	0.909
8	0.670	0.819	0.597	0.967	0.136	0.369	0.290	0.782
9	0.788	0.888	0.672	0.961	0.065	0.254	0.194	0.891
10	0.441	0.664	0.538	0.981	0.090	0.299	0.232	0.911
11	0.399	0.632	0.496	0.982	0.052	0.228	0.165	0.949
12	0.729	0.854	0.730	0.965	0.182	0.426	0.330	0.739
13	0.364	0.603	0.483	0.982	0.069	0.263	0.196	0.883
14	0.274	0.523	0.401	0.987	0.079	0.281	0.229	0.871
15	0.563	0.750	0.640	0.974	0.050	0.223	0.169	0.926

Con el fin de evaluar la utilidad de los modelos de redes neuronales, en la predicción de variables climáticas para periodos de dirección del viento más allá de los valores para los cuales fue entrenada la red, se simuló el comportamiento de la temperatura y humedad absoluta dentro de la granja en los periodos 3-6. El modelo predice bien en la mayoría de los sensores del periodo 3, como se muestra en el Cuadro 3, la eficiencia del modelo en el caso de la simulación de temperatura oscilo entre 0.86 (sensor 6 al este) y 0.987 (sensores 4 al este y 14 en el centro), y para el caso de la humedad absoluta oscilo entre 0.67 (sensor 4 al este) y 0.949 (sensor 11 al oeste), ubicaciones que incluyen los dos extremos y centro de la granja, cabe señalar que el periodo 3 contiene los datos de dirección del viento más cercanos a los valores para los cuales fue entrenada la red.

Un ejemplo del desempeño en la simulación del periodo 3 en el caso de 6 sensores se muestra en el Gráfico 10.4, para casi dos días. Se observa en general un buen desempeño de la red, el modelo concuerda con la tendencia de los datos reales.

**Gráfico 10.4** Desempeño en la simulación de los sensores 1(este), 14(centro) y 10 (oeste) del periodo 3



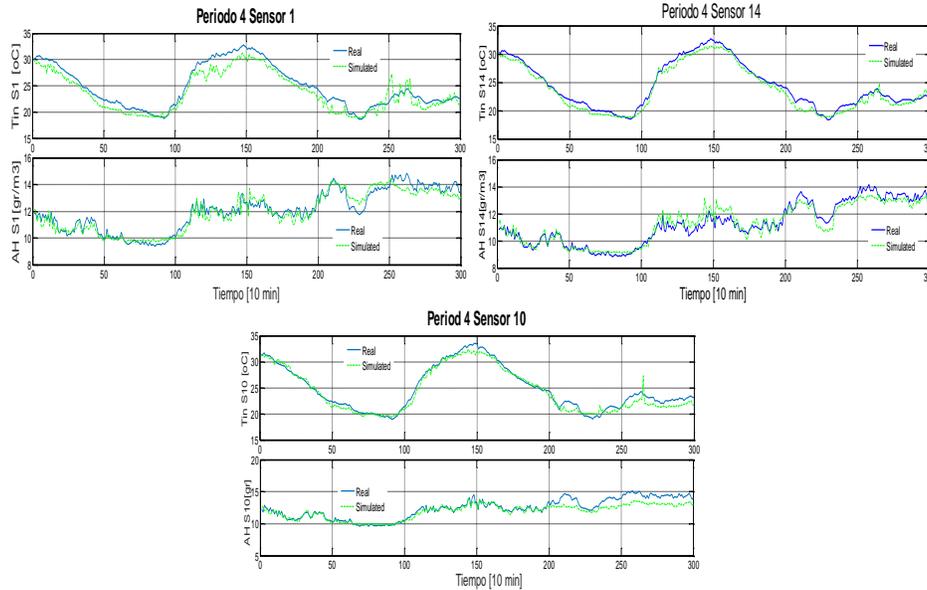
A continuación se presentan los resultados para el periodo 4, que incluye direcciones de viento entre  $39.25^{\circ}$  - $282^{\circ}$ . En el periodo 4, la eficiencia del modelo en el caso de la simulación de temperatura oscila entre 0.43 (sensor 3 al oeste) y 0.99 (sensor 4 al este), y para el caso de la humedad absoluta oscila entre 0.75 (sensor 10 al este) y 0.97 (sensor 5 y 6 al este). A pesar de que la dirección del viento en este periodo se incrementa hasta  $282^{\circ}$ , la eficiencia obtenida en la predicción de las variables fue aceptable.

**Tabla 10.3** Medidas de ajuste en la simulación del periodo 4 para los 15 sensores

	MEDIDAS DE AJUSTE PREDICCIÓN PERIODO 4							
Sensor	MSET	RMSET	MAET	EFT	MSEAH	RMSEAH	MAEAH	EFAH
1	2.15	1.47	1.22	0.87	0.19	0.44	0.35	0.91
2	4.82	2.19	1.80	0.69	0.30	0.55	0.42	0.88
3	8.17	2.86	1.90	0.49	0.10	0.32	0.24	0.96
4	0.24	0.49	0.39	0.99	0.11	0.33	0.26	0.95
5	0.26	0.51	0.36	0.98	0.07	0.27	0.20	0.97
6	0.31	0.56	0.41	0.98	0.07	0.26	0.20	0.97
7	1.82	1.35	1.06	0.89	0.30	0.55	0.43	0.86
8	1.30	1.14	0.96	0.92	0.23	0.48	0.35	0.90
9	1.19	1.09	0.81	0.92	0.26	0.51	0.39	0.90
10	0.70	0.84	0.66	0.96	0.59	0.77	0.55	0.75
11	0.44	0.66	0.55	0.97	0.23	0.48	0.39	0.89
12	7.06	2.66	1.77	0.56	0.18	0.42	0.32	0.92
13	2.90	1.70	1.24	0.82	0.18	0.42	0.30	0.92
14	0.68	0.83	0.70	0.96	0.18	0.43	0.34	0.92
15	2.60	1.61	1.08	0.84	0.17	0.41	0.30	0.93

En el Gráfico 10.5 se presenta la comparación entre los valores reales y simulados para 3 sensores.

**Gráfico 10.5** Desempeño en la simulación de los sensores 1 (este), 14 (centro) y 10 (oeste) del periodo 4



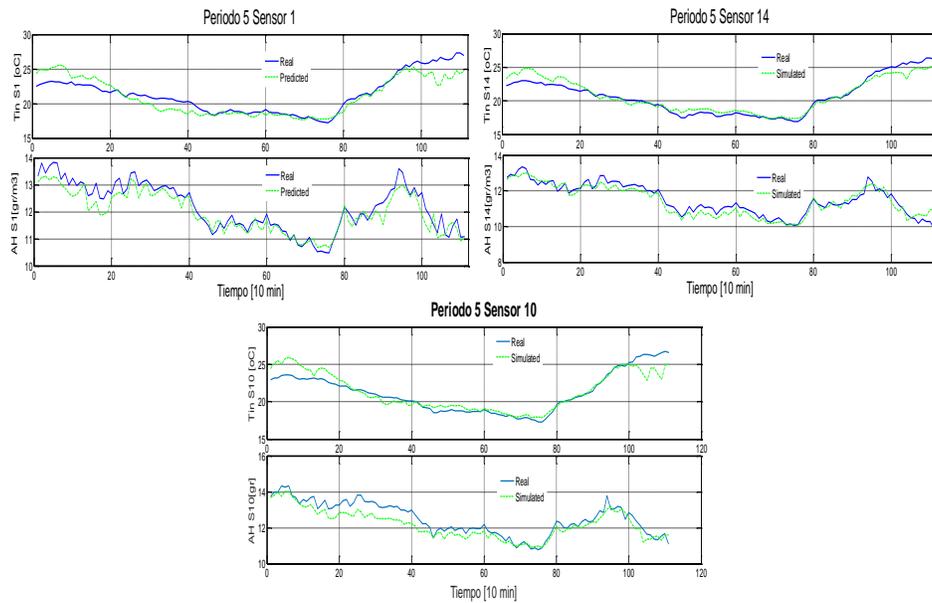
A pesar de que el periodo 4 incluye valores de dirección de viento mucho mas elevados que la dirección del viento utilizada en el desarrollo del modelo, se obtuvieron muy buenos resultados como se muestra en el Gráfico 10.6, donde se seleccionaron 3 ubicaciones representativas del invernadero. Los resultados para el periodo 5, que incluye direcciones de viento entre  $39.74^\circ$  - $294.9^\circ$  se presentan en la Tabla 10.4 y Gráfico 10.6.

**Tabla 10.4** Medidas de ajuste en la simulación del periodo 5 para los 15 sensores

MEDIDAS DE AJUSTE PREDICCIÓN PERIODO 5								
Sensor	MSET	RMSET	MAET	EFT	MSEAH	RMSEAH	MAEAH	EFAH
1	1.58	1.26	0.94	0.78	0.11	0.34	0.26	0.85
2	4.03	2.01	1.60	0.47	0.22	0.46	0.40	0.74
3	1.20	1.09	0.89	0.84	0.26	0.51	0.44	0.69
4	0.34	0.59	0.44	0.95	0.06	0.25	0.19	0.91
5	0.28	0.53	0.41	0.96	0.07	0.26	0.20	0.91
6	0.61	0.78	0.49	0.95	0.05	0.23	0.17	0.94
7	1.21	1.10	0.80	0.83	0.09	0.30	0.24	0.88
8	2.49	1.58	1.26	0.67	0.09	0.29	0.25	0.89
9	1.65	1.29	1.00	0.80	0.27	0.52	0.42	0.69
10	1.09	1.05	0.72	0.84	0.18	0.43	0.35	0.78
11	0.63	0.80	0.61	0.91	0.13	0.36	0.30	0.85
12	2.21	1.49	1.25	0.73	0.12	0.35	0.29	0.86
13	1.28	1.13	0.85	0.82	0.09	0.30	0.24	0.89
14	0.60	0.78	0.60	0.92	0.08	0.29	0.24	0.89
15	1.73	1.32	1.19	0.77	0.08	0.29	0.24	0.90

En el periodo 5, la eficiencia del modelo en la simulación de temperatura oscila entre 0.47 (sensor 2 centro) y 0.96 (sensor 5 al este), y para el caso de la humedad absoluta oscilo entre 0.69 (sensor 3 al oeste y sensor 9 en el centro) y 0.94 (sensor 6 al este). Aunque la dirección del viento en este periodo se incrementa hasta 294.9°, los resultados de predicción en este periodo fueron buenas para casi todas las posiciones de los sensores.

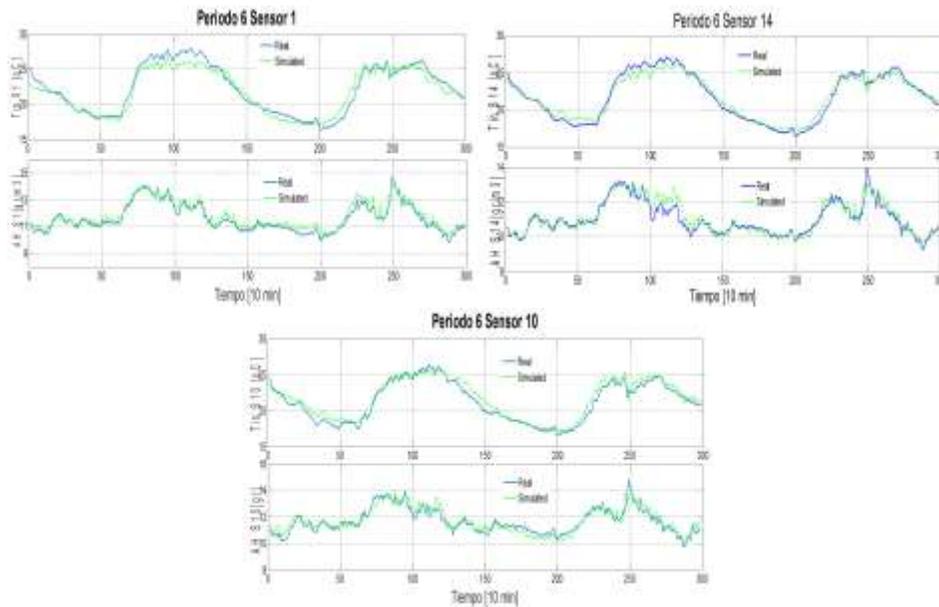
**Gráfico 10.6** Desempeño en la simulación de los sensores 1(este), 14(centro) y 10 (oeste) del periodo 5



Para el periodo 6, la eficiencia del modelo en la simulación de temperatura oscila entre 0.89 (sensor 5 al este) y 0.98 (sensor 4 y 5 al este), y para el caso de la humedad absoluta oscilo entre 0.55 (sensor 9 en el centro) y 0.95 (sensor 5 y 6 al este). En este periodo la dirección del viento (149° -275.5°) se encuentra fuera de los límites para los cuales fue entrenada la red (Tabla 10.5).

**Tabla 10.5** Medidas de ajuste en la simulación del periodo 6 para los 15 sensores

MEDIDAS DE AJUSTE PREDICCIÓN PERIODO 6								
Sensor	MSET	RMSET	MAET	EFT	MSEAH	RMSEAH	MAEAH	EFAH
1	0.83	0.91	0.73	0.93	0.09	0.31	0.24	0.91
2	0.89	0.94	0.75	0.90	0.25	0.50	0.40	0.69
3	0.67	0.82	0.69	0.93	0.09	0.30	0.24	0.88
4	0.24	0.49	0.37	0.98	0.05	0.22	0.17	0.94
5	0.24	0.49	0.38	0.98	0.05	0.22	0.17	0.95
6	0.43	0.66	0.42	0.97	0.06	0.24	0.18	0.95
7	0.63	0.80	0.62	0.94	0.06	0.24	0.17	0.94
8	0.58	0.76	0.61	0.94	0.20	0.45	0.37	0.74
9	0.82	0.91	0.72	0.91	0.37	0.61	0.47	0.55
10	0.47	0.69	0.56	0.94	0.13	0.36	0.29	0.85
11	0.48	0.69	0.57	0.95	0.08	0.28	0.23	0.92
12	0.77	0.88	0.77	0.93	0.15	0.38	0.31	0.84
13	0.59	0.77	0.62	0.95	0.09	0.30	0.24	0.90
14	0.42	0.65	0.54	0.96	0.10	0.32	0.22	0.87
15	1.13	1.06	0.92	0.89	0.11	0.34	0.29	0.87

**Figura 10.7** Desempeño en la simulación de los sensores 1(este), 14(centro) y 10 (oeste) del periodo 6

La red neuronal construida tuvo un buen desempeño incluso para periodos en los cuales la dirección del viento estuvo muy por encima de la dirección del viento para la que fue entrenada.

**Tabla 10.6** Orden del sensor de temperatura con mayor eficiencia al de menor eficiencia en cada periodo

ORDEN DEL SENSOR CON BASE EN LA EFICIENCIA							
TEMPERATURA							
	P3		P4		P5		P6
No sensor	Eficiencia	No sensor	Eficiencia	No sensor	Eficiencia	No sensor	Eficiencia
14	0.99	4	0.99	5	0.96	4	0.98
4	0.99	5	0.98	4	0.95	5	0.98
13	0.98	6	0.98	6	0.95	6	0.97
11	0.98	11	0.97	14	0.92	14	0.96
10	0.98	10	0.96	11	0.91	11	0.95
7	0.98	14	0.96	10	0.84	13	0.95
15	0.97	9	0.92	3	0.84	8	0.94
8	0.97	8	0.92	7	0.83	7	0.94
12	0.97	7	0.89	13	0.82	10	0.94
9	0.96	1	0.87	9	0.80	12	0.93
2	0.96	15	0.84	1	0.78	1	0.93
5	0.95	13	0.82	15	0.77	3	0.93
3	0.95	2	0.69	12	0.73	9	0.91
1	0.94	12	0.56	8	0.67	2	0.90
6	0.86	3	0.49	2	0.47	15	0.89

**Tabla 10.7** Orden del sensor de humedad absoluta con mayor eficiencia al de menor eficiencia en cada periodo

ORDEN DEL SENSOR CON BASE EN LA EFICIENCIA							
HUMEDAD ABSOLUTA							
P3		P4		P5		P6	
No sensor	Eficiencia	No sensor	Eficiencia	No sensor	Eficiencia	No sensor	Eficiencia
11	0.95	6	0.97	6	0.94	5	0.95
15	0.93	5	0.97	5	0.91	6	0.95
1	0.92	3	0.96	4	0.91	4	0.94
3	0.91	4	0.95	15	0.90	7	0.94
10	0.91	15	0.93	8	0.89	11	0.92
7	0.91	13	0.92	13	0.89	1	0.91
5	0.90	12	0.92	14	0.89	13	0.90
9	0.89	14	0.92	7	0.88	3	0.88
13	0.88	1	0.91	12	0.86	14	0.87
14	0.87	8	0.90	1	0.85	15	0.87
6	0.83	9	0.90	11	0.85	10	0.85
8	0.78	11	0.89	10	0.78	12	0.84
12	0.74	2	0.88	2	0.74	8	0.74
2	0.72	7	0.86	3	0.69	2	0.69
4	0.67	10	0.75	9	0.69	9	0.55

#### 10.4 Conclusiones

Se desarrollaron 15 redes neuronales estáticas MLP, con 11 nodos en la capa oculta para predecir el clima dentro de una granja de pollos en 15 diferentes ubicaciones, utilizando datos experimentales del interior y exterior pero fijando la dirección del viento en un rango de  $36.56^\circ$  a  $100.5^\circ$ , las cuales mostraron una eficiencia alta en el entrenamiento, validación y prueba. Las redes fueron capaces de simular los valores de temperatura y humedad absoluta, para periodos en donde la dirección del viento fue diferente de aquellas para las cuales fueron entrenadas.

En el periodo 3 donde la dirección del viento se encuentra entre  $40.57^\circ$  -  $105.8^\circ$ , dentro del periodo de dirección del viento para el cual fue entrenada la red, se observó un buen resultado en la predicción de temperatura, a excepción de la ubicación 6 al este de la granja, en el caso de la humedad absoluta el modelo no simuló muy bien en las ubicaciones 2 y 8 en el centro, 4 en el este, y 12 al oeste, es decir no se encuentra un patrón de comportamiento en donde se pueda sugerir que el modelo no simula bien para una ubicación en particular. Respecto al periodo 4 con direcciones del viento entre  $39.25^\circ$  -  $282^\circ$ , se obtuvieron mejores resultados en la simulación de la humedad absoluta, únicamente la ubicación 10 en el oeste se obtuvo una eficiencia menor a 0.8, en el caso de la temperatura tres ubicaciones tuvieron eficiencias menores a 0.8, la ubicación 2 en el centro, 3 y 12 al oeste.

Como era de esperarse, cuando la dirección del viento se encuentra en valores más alejados para los cuales fue entrenada la red como el periodo 5 con direcciones del viento entre  $39.74^\circ$  -  $294.9^\circ$ , para la simulación de temperatura se obtuvieron eficiencias menores a 0.8, en las ubicaciones 1 al este, 2 y 8 al centro y 12 y 15 al oeste, mientras que en la simulación de la humedad absoluta se tienen eficiencias debajo de 0.8 en las ubicaciones 2, 9 en el centro y 3, 19 en el oeste. Por último, el periodo 6 con direcciones del viento entre  $149^\circ$  -  $275.5^\circ$  que se encuentra totalmente fuera de las direcciones del viento para las cuales fue entrenada la red, la eficiencia fue menor a 0.8 en las ubicaciones 2, 4 y 12 en el caso de la humedad absoluta. Sin embargo, en este periodo las medidas de ajuste entre lo real y predicho por la red fueron muy buenas.

Cuando la red neuronal no tiene buenos resultados en la simulación de algunas ubicaciones, significa que en esas ubicaciones es indispensable contar con el sensor. Del análisis anterior se deduce que los sensores 2 y 12 son indispensables en la medición de la temperatura, mientras que los sensores 2, 10 y 4 son indispensables en la medición de la humedad absoluta. Otra interpretación es que en esas ubicaciones habría que calibrar o ajustar dichos sensores.

### 10.5 Referencias

Govindaraju, R. S. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123.

Brío, M. B., Sanz, M. A. (2007). *Redes Neuronales y Sistemas Borrosos*. Alfaomega grupo editor. Tercera edición. México. 404 p.

Kulacov, A., Davcev, D. Intelligent Aggregation in sensor networks using artificial neural networks algorithms. *NSTI-Nanotech 2005*, www.nsti.org, ISBN 0-9767985-2-2 Vol. 3, 2005.

Masters, T. (1993). *Practical neural network recipes in C++*. Morgan KaufmRNA. 490p.

Palazón, G. J., García, G.A. (2004). Modelado de series climatológicas mediante una red neuronal artificial, *Ingeniería del Agua*, 11 (1).

Sefat, M. Y., Borgaee, A. M., Beheshti, B., & Bakhoda, H. (2014). Application of Artificial Neural Network (ANN) for Modelling the Economic Efficiency of Broiler Production Units. *Indian Journal of Science and Technology*, 7(11), 1820-1826.

Veselý, A. (2011). Economic classification and regression problems and neural networks. *Agricultural Economics (Zemědělská Ekonomika)*, 57(3), 150-157.

Wallach, D., Makowski, D., Jones, J. W., & Brun, F. (2013). *Working with Dynamic Crop Models: Methods, Tools and Examples for Agriculture and Environment*. Academic Press. 487 p.

Yildirim, I., Ozsahin, S., & Akyuz, K. C. (2011). Prediction of the Financial Return of the Paper Sector with Artificial Neural Networks. *BioResources*, 6 (4).