



Artículo de investigación

Redes neuronales en la predicción de micro-clima Zona de estudio La Hechicera, Mérida-Venezuela

Neural networks in the prediction of microclimate, La Hechicera-Mérida-Venezuela, Case of Study

Misael Darío Rosales Ramírez^a, Cesar Augusto Mora Benavídes^b, Carlos Eduardo Guada Barráez^a

^aUniversidad de Los Andes, Facultad de Ciencias. Venezuela

^bFundación para el Desarrollo de la Ciencia y la Tecnología - Mérida. Venezuela

Recibido: 01-12-2017

Aceptado: 07-06-2018

Resumen

Se desarrolló una Red Neuronal Artificial (RNA) con capacidad para realizar predicciones climáticas a corto plazo, entrenada con datos a intervalos de 15 min durante 454 días, de una estación climatológica ubicada en La Hechicera Mérida-Venezuela (1896 msnm). Para el entrenamiento y su validación se usaron patrones simulados que contienen variaciones diarias de la Radiancia y la Temperatura. Se eligieron 3 funciones de prueba tales como el Seno, Coseno y los Polinomios de Legendre $P_l(x)$. La (RNA) puede predecir el intervalo $(0,1]$ usando sólo como entrada el intervalo $[-1,0]$ de la correspondiente derivada $P'_l(x)$ del polinomio. En la fase de producción con datos reales, se encontró que la red es capaz de predecir la temperatura con un 5 % de error en el rango horario [12:15 a 06:15] pm, sólo con los datos de temperatura en el rango [6:00 a 12:00] am. Igualmente al predecir temperatura a partir de Radiancia (5 %), Radiancia-Radiancia (16 %). Se considera viable el uso de (RNA) para la predicción de micro-clima a corto plazo, pudiendo extender su uso a otras localidades, lo que podría ser útil para el desarrollo de planes de prevención de desastres, períodos de siembra y en la predicción de oferta de energía en plantas eólicas y solares.

Palabras clave: microclima, redes neuronales, predicción de microclima, predicción climática.

Código UNESCO: 250911- Predicción Operacional Meteorológica

Abstract

An Artificial Neural Network (RNA) was developed with capacity to make short-term climatic predictions, trained with data at intervals of 15 min for 454 days in a climatological station located in La Hechicera Mérida-Venezuela (1896 masl). For training and validation, were used simulated patterns that contain daily variations of radiance and temperature. Three test functions were chosen such as the Sine, Cosine and the Legendre Polynomials $P_l(x)$. The (RNA) e.g, can predict the interval $(0,1]$ using only as input the interval $[-1,0]$ of the corresponding derivative $P'_l(x)$ of the polynomial. In the production phase with real data, it was found that the network is able to predict the temperature with approx. 5% error in the hourly range [12:15 to 06:15] pm, only with the temperature data in the range [6:00 to 12:00) am. Also, when predicting temperature from radiance (5%), radiance-radiance (16%). The use of (RNA) for the prediction of micro-climate in the short term is considered feasible, being able to extend its use to other localities, which could be useful for the development of disaster prevention plans, sowing periods, prediction of energy supply in wind and solar power stations.

Key words: microclimate, neuronal network, microclimate prediction, climatic prediction.

UNESCO Code: 250911-Meteorological Operational Prediction

1. Introducción

El clima influye de manera significativa en la sociedad y continuará haciéndolo en el futuro [1, 2]. No obstante, los impactos negativos que este pueda tener sobre las comunidades pueden disminuirse a través del conocimiento de la variabilidad del clima y las predicciones que se puedan hacer. Las predicciones climáticas apoyan la gestión de los riesgos y las oportunidades relacionadas, entre otras cosas, con las reservas de agua y la seguridad alimentaria [3, 4]. Así mismo proporcionan los elementos de apoyo necesarios para tomar decisiones acerca del manejo y planificación de las actividades sensibles al clima para hacer frente a posibles desastres naturales. Gracias a un mejor análisis de los riesgos climáticos y a la disponibilidad de las predicciones estacionales, los agricultores pueden adaptar sus fechas de plantación, sembrar una mejor combinación de cultivos y elegir variedades resistentes a enfermedades y a la peste. Ello puede contribuir a mejorar la seguridad alimentaria y a reducir la pobreza. Las predicciones climáticas proporcionan a los gestores de los recursos hídricos la información necesaria para planificar y hacer funcionar sus sistemas de forma más eficaz. Los desastres relacionados con el clima, como las inundaciones o las sequías, repercuten enormemente en las comunidades y en sus actividades socioeconómicas. Los sistemas de alerta temprana pueden impedir la pérdida de vidas, medios de sustento y bienes al alertar a las poblaciones de amenazas específicas y mejorar su nivel de preparación. El turismo y el transporte, y las correspondientes cadenas y servicios de suministros, son sumamente sensibles al clima. Incluso los cambios moderados de las condiciones climáticas pueden afectar al turismo y, de hecho a la mayoría de las actividades recreativas al aire libre [5, 6]. Numerosos sectores de actividad socioeconómica y ambiental manifiestan una gran dependencia de las condiciones climáticas, de manera que las predicciones climáticas contribuyen al desarrollo y bienestar de las comunidades, aumentando la protección frente a los desastres naturales, mejorando la seguridad alimentaria, contribuyendo considerablemente a la construcción de una gestión integrada y uso sostenible de los recursos hídricos y a la protección del medio ambiente [6]. En esta investigación se propone entonces como objetivo estimar el comportamiento del microclima en la zona de La Hechicera/Mérida-Venezuela, usando (RNA) entrenadas con una base de datos local, a los propósitos de predecir las variables climatológicas a corto plazo y que la generalización de esta metodología pueda ser aplicada a cualquier zona del país. Actualmente existen diferentes **metodologías** [7] para realizar un pronóstico del tiempo. Los procedimientos que un pronosticador utilice dependen básicamente de su experiencia, la cantidad de información disponible, del nivel de dificultad que presenta la situación y del grado de exactitud o confianza necesaria en el pronóstico.

El **método de persistencia** por ejemplo asume que hoy es igual a mañana. Es la manera más simple de hacer un pronóstico, en éste se postula que las condiciones atmosféricas no cambiarán en el tiempo. Por ejemplo si hoy es un día soleado con 20 °C, se asume que mañana será soleado y con 20 °C, de igual forma si 2 mm de precipitación cayeron hoy, mañana también caerán 2 mm. Este argumento funciona bien cuando los patrones atmosféricos cambian poco y los sistemas de los mapas del tiempo se mueven muy lentamente. Por otra parte, el uso de **la tendencia** involucra el cálculo de la velocidad de centros de altas y bajas presiones, frentes y áreas de nubes y precipitación. Usando esta información el pronosticador puede predecir donde se esperan estas características en un tiempo futuro. En este caso se trabaja con sistemas que se mueven en la misma dirección y a la misma velocidad por un largo periodo. El **método climatológico** es otra forma simple de realizar un pronóstico. Este involucra el uso de promedios estadísticos de las variables atmosféricas, acumulados durante muchos años. Este procedimiento funcionará bien mientras que los patrones climatológicos sean similares para la fecha escogida, pero si los patrones son diferentes fallará. Un procedimiento de pronóstico supone examinar el escenario actual y recordar un día en el pasado en el cual el escenario meteorológico fue muy similar (un análogo). El pronosticador podría predecir que el tiempo en este pronóstico será muy similar al ocurrido en el pasado [8, 9, 10, 11].

2. Desarrollo

2.1. Estado del arte

Los fenómenos meteorológicos son bien conocidos por tener comportamientos caóticos, de modo que el desarrollo de soluciones predictivas ha sido bastante complejo [8, 10]. Los trabajos en la meteorología usualmente comprenden dos áreas, la primera son los métodos estadísticos, los cuales presentan una tendencia de dichos comportamientos; sin embargo son poco confiables ya que es muy difícil que las condiciones atmosféricas se repitan exactamente en los mismos lugares. La segunda área son los métodos numéricos, los cuales dependiendo del área de estudio, exigen mucho poder de cómputo y tiempo de procesamiento. En las últimas décadas el desarrollo de los sistemas inteligentes (SI) ha dado proyección a un sin número de aplicaciones en diversas áreas del conocimiento (robótica, economía,

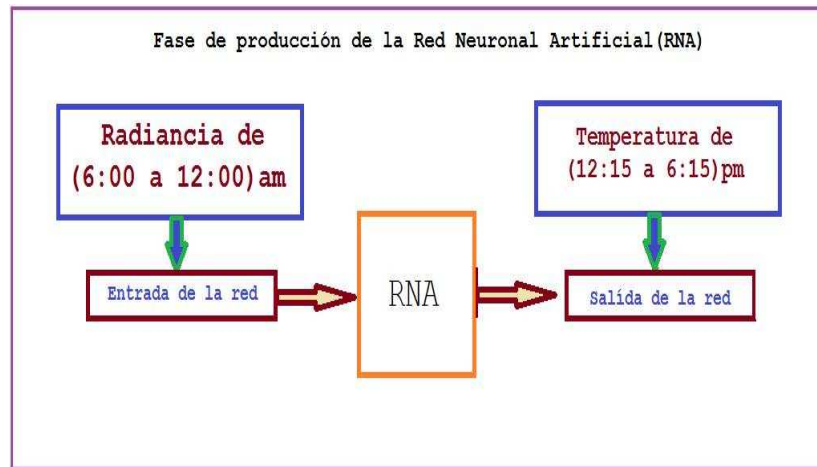


Figura 1: La RNA predice la temperatura durante la tarde a partir de la Radiancia durante la mañana

meteorología, salud, etc.). En el campo de la meteorología existen diversos trabajos que exploran el desempeño de los *SI*, en especial de los sistemas expertos y de las redes neuronales artificiales (*RNA*) en diversas tareas de predicción y clasificación. Los resultados de estos métodos han llevado a insertar estos modelos entre las diferentes herramientas con que cuentan los organismos encargados de los servicios de pronóstico meteorológico; algunos ejemplos son el servicio meteorológico de España y la sociedad estadounidense de meteorología [3, 4]. La aplicación de las *RNA* en las diferentes tareas de los servicios meteorológicos es resultado del paralelo que existe entre los métodos convencionales de la estadística y los métodos de aprendizaje de máquina en los que se encuentran enmarcadas las *RNA*. Los modelos neuronales se han empleado como modelos flexibles de regresión no lineal y de clasificación. Las áreas de estudio en las que se han aplicado en los últimos años las *RNA* en la predicción de series de tiempo, podemos mencionar las siguientes: (a) Predicción de microclima rural [12, 13], (b) Predicción de radiación solar [14], (c) Predicción de microclima en invernaderos [15], (d) Predicción urbana de parámetros climáticos [16, 10], (e) Comportamiento a corto plazo del viento [9], (f) Comportamiento de la demanda eléctrica y picos de electricidad [17] También se han usado las *RNA* en el comportamiento a corto plazo de parámetros económicos y sociales: (g) Predicción de acciones: Consiste en el desarrollo de una *RNA* capaz de realizar la predicción del precio de las acciones para un número dado de compañías. Esta predicción se realiza mediante redes alimentadas hacia adelante, y el objetivo en este caso es predecir el siguiente valor en la serie de tiempo.[18] [19] (h) Predicción de tráfico vehicular: Se han utilizado redes neuronales recurrentes para la predicción a corto plazo del tráfico en una carretera, a fin de prevenir congestiones y tener el control del acceso a la vía. Para esto se utilizan datos históricos de otros días con propiedades similares [20].

2.2. Metodología

a. Puesta a punto de la RNA

Dado que la base de datos real es relativamente pequeña (~ 2 años), se introduce por lo tanto para la validación de la red neuronal una base de datos simulados a los efectos de crear una metodología general que pueda servir de guía para estimar microclima local. El procedimiento estándar para el uso de una *RNA* [21, 7] está basado en tres fases a saber:

- Fase de entrenamiento: en la que se calculan los parámetros de la red haciendo uso de los pares de entrada/salida.
- Fase de validación o test: en esta fase se presentan las entradas validadas y se verifica la eficiencia de la red.
- Fase de producción: en la que se presenta un conjunto de entradas que serán clasificadas por la red (ver figura 1).

El cumplimiento de estas tres fases es realizado en esta investigación usando como pares de entrada y salida, distintas combinaciones de parámetros climáticos como por ejemplo Radiancia-Temperatura. Se da como entrada a la red el registro medido de la Radiancia durante la mañana en el intervalo [6:00 a 12:00] am y se da como salida esperada el registro de la temperatura durante la tarde, en el intervalo [12:15 a 6:15] pm. De manera que la fase de entrenamiento




Figura 2: Estación climatológica addwave 733 con sus respectivos sensores

de la red consistirá en dar todo un conjunto de ejemplos que contenga para cada registro de Radiancia en la mañana su correspondiente registro de temperatura en el intervalo de la tarde. Hecho esto, hasta lograr una convergencia aceptable de la red, esto es por ejemplo un error menor al 1 % en la estimación de la temperatura para una Radiancia dada. El siguiente paso consiste entonces en presentar como entrada sólo la Radiancia y encontrar cuál es la temperatura estimada por la red. La eficiencia de la red se estima haciendo uso de un histograma de dispersión (ver figura 18) a partir de la temperatura real menos la temperatura estimada por la red, a partir de estos datos finalmente se determina el error medio porcentual dado por la ecuación 2.2.

b. Identificación de la estación y del área de estudio

La estación climatológica marca Adcon Telemetry [22], modelo addwave 733, (ver figura 2) se encuentra ubicada en la Facultad de Ciencias en el sector la Hechicera del Estado Mérida-Venezuela, a una altura de 1872 msnm, Lat: 8°37'37.35"N y Long: 71° 9'1.20"O W. Los sensores de los que dispone esta estación son: Radiancia, Temperatura, Pluviosidad, Humedad, Velocidad y Dirección del viento.

c. Captura de los datos

Los datos provenientes de la estación climatológica fueron almacenados diariamente en intervalos de 15 minutos desde el año 2011 hasta el año 2012 en un total de 454 días, éstos se capturaron y procesaron sobre una base de software libre GNU/Linux de 64 bits. En el cuadro 1 se especifican las unidades en que las diferentes variables medidas están expresadas.

Variable	Unidades
Radiancia	W/m^2
Temperatura	°C
Precipitación	mm
Humedad	%
Dirección del viento	Angulo en grados
Velocidad del viento	m/s

Cuadro 1: Variables registradas y sus unidades

Las figuras 3 y 4 muestran todos los datos medidos por la estación meteorológica en el período de tiempo establecido (454 días). El eje vertical en la imagen se expresa de 0 a 24 horas y el eje horizontal son los días de medición, el color representa el valor absoluto del parámetro climatológico, identificado en la barra de color en la parte derecha de cada imagen, cuya escala está dada para cada parámetro según el cuadro 1.




Figura 3: Imágen en pseudocolor de la Radiancia, Temperatura y Precipitación




Figura 4: Imágen en Pseudocolor de la Humedad, Velocidad y Dirección del viento

Se pueden observar ciertas anomalías (denotadas en círculos) en la secuencia de los datos provocadas por cortes eléctricos y/o fallas en la adquisición de los datos y que serán descartadas, no siendo aptas para el uso de la RNA. De igual forma se puede apreciar en la figura 4 que hay aproximadamente 115 días que no contienen datos sobre las variables velocidad y dirección del viento, dado que los sensores usados para medir estas variables aún no estaban instalados.

d. Valores medios de las variables observadas

En el cuadro 2 se muestran los valores medios de las variables climáticas usadas en esta investigación, en los intervalos de tiempo desde las [6:00 a 12:00] am y [12:15 a 6:15] pm. La figura 5 muestra la evolución de la Radiancia (a) y la

Temperatura (b) y la figura 6 la evolución de la Humedad (a) y la Velocidad del viento (b). El promedio ha sido calculado para los 454 días de medición en el intervalo diurno comprendido entre las 6:00 am y las 6:15 pm.

	Mañana [6:00 a 12:00]am	Tarde [12:15 a 6:15]pm)
Radiancia	416.24 W/m ²	376.23 W/m ²
Temperatura	18.29 °C	19.98 °C
Humedad	68.37 %	72.38 %
Velocidad del viento	1.16 m/s	1.72 m/s

Cuadro 2: Valores medios de las variables climáticas medidas




Figura 5: Comportamiento promedio de la Radiancia (a) y de la Temperatura (b)




Figura 6: Comportamiento promedio de la Humedad (a) y de la Velocidad del viento (b)

En la figura 7 se ilustra un histograma polar de distribución de frecuencias predominantes de la dirección del viento en La Hechicera-Mérida-Venezuela. De manera orientativa se ha superpuesto éste sobre una imagen de Google Earth de la zona de estudio. Se aprecian 3 direcciones predominantes: (1) Dirección aproximada *Oeste – Este*, coincidente con la dirección del Valle de la Hechicera, (2) dirección *Norte – Sur* y (3) de menor predominancia la dirección *Norte – Oeste*. El radio de cada círculo concéntrico del diagrama polar representa la frecuencia relativa de las mediciones, es decir, el número de veces que la veleta se orientó en esa dirección. Los valores incrementales de los radios son: 500,1000,1500 y 2000.

e. Procesamiento de los datos

Una vez capturados los datos se procedió a su depuración, normalización y separación en intervalos temporales comprendidos entre las [6:00 y 12:00] am y las [12:15 y 6:15] pm. Estos intervalos serán los pares entrada-salida usados

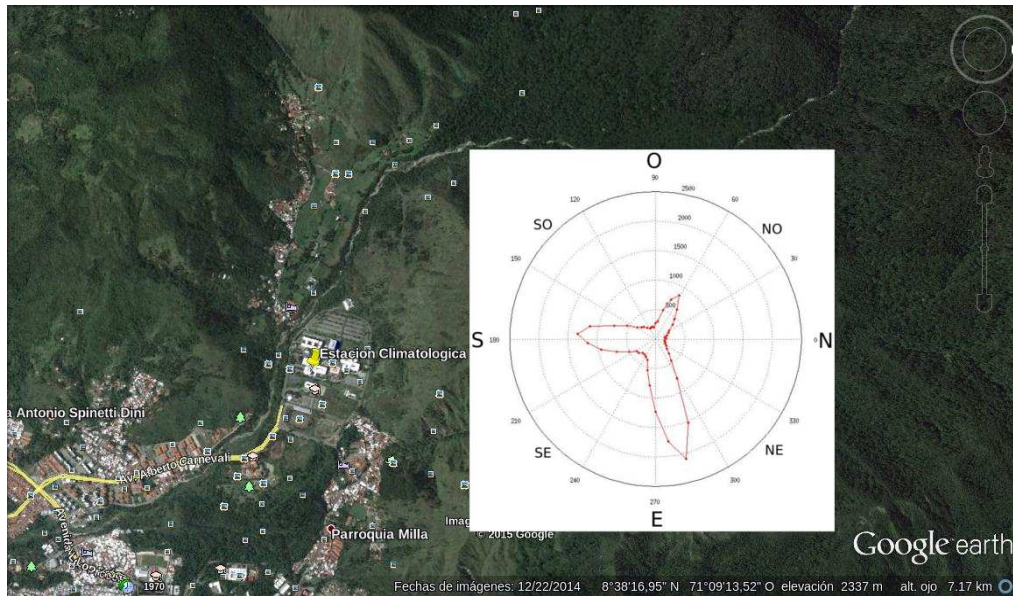


Figura 7: Histograma polar de la dirección del viento en La Hechicera-Mérida-Venezuela

para el entrenamiento, test y fase de producción de la red. Los datos fueron estandarizados de acuerdo a la siguiente transformación lineal:

$$x^* = \frac{x - \bar{x}}{\sigma} \quad (2.1)$$

Siendo x^* el nuevo vector de datos normalizado, x la variable de entrada, \bar{x} y σ su valor medio y desviación estándar respectivamente. En este tipo de normalización x^* tendrá valor medio cero y varianza unidad, con lo que se evitan tendencias de las entradas fuera de los rangos considerados como normales, debido a desplazamientos de la línea base de los instrumentos de medición. Por otra parte, al desplazar los datos a media cero y dividirlos por su desviación, sus rangos dinámicos son los más apropiados en el entrenamiento de las RNA, cuando se usa como función de transferencia la tangente hiperbólica, como es nuestro caso [21]. Se realizó una depuración de los datos para descartar cualquier inconsistencia o errores, la mayor parte de los datos eliminados son los debidos a posibles fallas eléctricas y/o comunicación provocada por el hardware. En las regiones marcadas con círculos negros en las figuras 3 y 4 se pueden apreciar estas anomalías que deben ser excluidas, para ello se usaron los siguientes criterios:

- Inspección Visual: A través de la observación en algunos casos resultaba sencillo determinar cuáles datos debían ser eliminados de la matriz.
- Desviación estándar: Se usó el criterio de la desviación estándar asumiendo que los datos con una desviación superior a $\pm 3\sigma$ fueron descartados.
- Media aritmética: Se tomó la media de los datos y aquellos que presentaron un comportamiento fuera de lo normal se descartaron.
- Longitud de las matrices de datos: Aquellos intervalos de tiempo comprendidos entre las horas relevantes para el estudio que no tenían la longitud adecuada (25 datos) también se excluyeron.

En las figuras 8 (a) y (b) se muestran los pares entrada/salida correspondientes a las variables Radiancia (a) en el intervalo [6:00 a 12:00] am y Temperatura (b) de [12:15 a 6:15] pm.

En las figuras 9 (a) y (b) se muestran las variables climáticas Humedad (a) y Velocidad del viento (b), en el intervalo (6:00 a 12:00) am.

2.3. Diseño y validación de la Red Neuronal

La red diseñada para nuestro propósito es una red perceptrónica multicapa entrenada con el algoritmo estándar de Retropropagación [21], usando como función de transferencia la tangente hiperbólica y tasa de aprendizaje 0.25. El

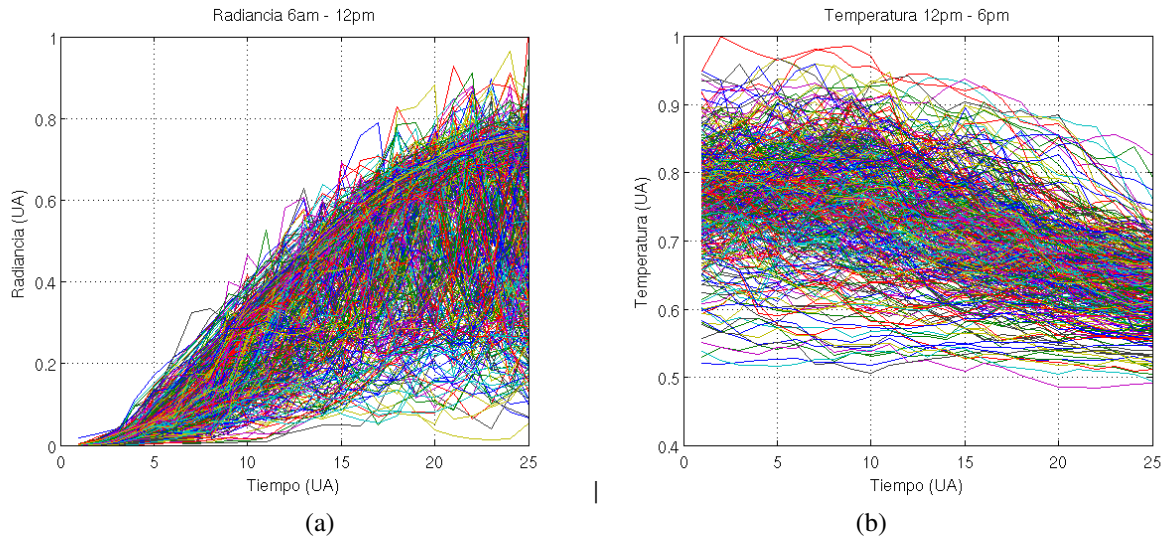


Figura 8: Radiancia (a) de [6:00 a 12:00] am y Temperatura (b) de [12:15 a 6:15] pm

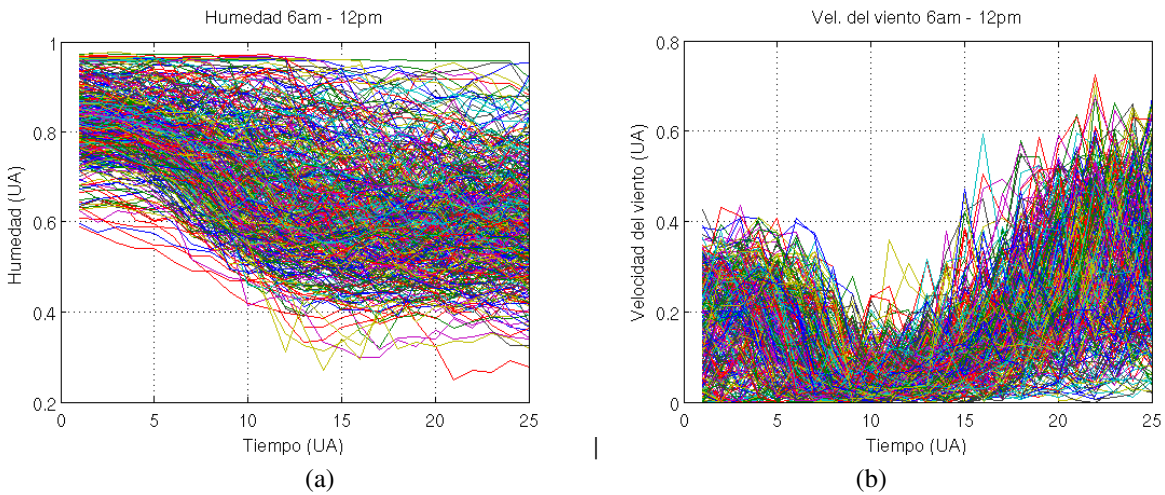


Figura 9: Humedad (a) y Velocidad del viento (b) de (6:00 a 12:00) am

cuadro 3 muestra el número de neuronas por capa. Las únicas neuronas de cómputo son las correspondientes a las capas ocultas: S_1 a S_4 , las neuronas de la capa de entrada (S_{in}) y las de la salida (S_{out}) son nodos que sólo contienen la longitud del número de entradas y/o salidas correspondientes al par entrada/salida del parámetro climatológico usado en cada caso, pero estas neuronas no procesan información.

Para la validación de la red se idearon dos métodos, basados en la generación sintética de los pares de entrenamiento entrada/salida: **El primero** hace uso de las funciones periódicas seno y coseno para simular el comportamiento de los valores reales de Radiancia (figura 5 (a)) y Temperatura (figura 5 (b)). El primer intervalo de tiempo (entrada de la red), el de la mañana comprendido entre las 6:00 am y 12:00 pm y el segundo (salida de la red), el de la tarde que va desde las 12:15 pm hasta las 6:15 pm. La función Seno (ver figura 10 (a)) en el intervalo $[0, \pi/2]$ representa el lapso de la mañana y la función Coseno (ver figura 10 (b)) en el intervalo $(\pi/2, \pi]$ representa el lapso de la tarde. Se generaron las funciones (Seno y Coseno), en el intervalo $[0, \pi/2]$ y la función coseno definida entre $(\pi/2, \pi]$.

Se generaron 40000 patrones de cada una de estas funciones, agregando diferentes niveles de ruido comprendidos entre 0 % y 100 % de los cuales se tomaron el 80 % para la fase de entrenamiento de la RNA y el 20 % restante para la fase de producción.

De igual modo se implementó un **segundo método** basado en los Polinomios de Legendre (figura 11 (a)) para comprobar la capacidad de predicción de la RNA con funciones mas complejas. El intervalo $[-1 a 0]$ se usa como de

Capa	Neuronas
Entrada(S_{in})	25
S1	16
S2	15
S3	16
S4	13
Salida(S_{out})	25

Cuadro 3: Número de neuronas por capa en la RNA

éstos de la red y la derivada (figura 11 (b)) del polinomio en el intervalo (0 a 1) se usa como salida, estos dos intervalos simulan un parámetro climático en el intervalo [6:00 a 12:00] am y [12:15 a 6:15] pm respectivamente.




Figura 10: Función Seno (a) y Coseno (b) con 0 % de ruido




Figura 11: $P(x)$ de Legendre (a) y su derivada (b) con 10 % de ruido

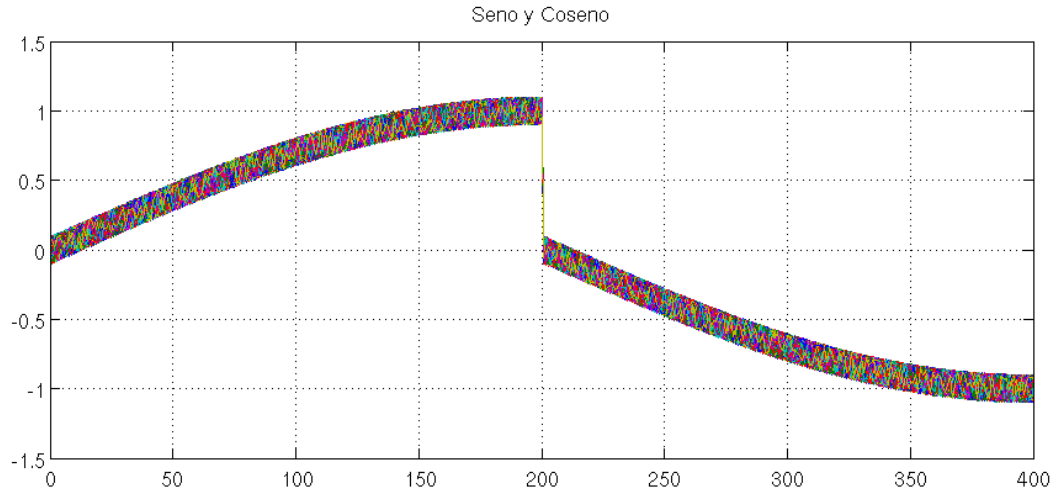


Figura 12: Funciones Seno y Coseno con 10 % de ruido

2.4. Resultados

1. Método de validación usando Seno y Coseno

Este método de validación buscaba probar la capacidad de la RNA para estimar (predecir) el valor de la función Coseno en el intervalo $[\pi, 2\pi]$, usando sólo como entrada su función primitiva Seno en el intervalo $[0, \pi)$, esto debido a la similitud que presenta el comportamiento de estas funciones con la evolución inter-diaria de la Radiancia y la Temperatura. Se generaron artificialmente 1000 patrones de cada una de las funciones Seno y Coseno, usando el 80 % para la fase entrenamiento, el restante 20 % para la fase de producción. Para verificar la robustez de la RNA, se añadió ruido a los patrones, desde 0 hasta 100 % en intervalos de 2.5 % (ver cuadro 4).

La figura 16 (a) muestra la eficiencia vs el nivel de ruido porcentual para la RNA Sen-Cos. La correlación es lineal negativa como era de esperarse, observándose un aumento progresivo en la barra de dispersión del error al aumentar éste, significa que: para ruido pequeño $< 20\%$ la calidad de la predicción es muy buena $> 95\%$ con $\pm 2\%$ de desviación y que para ruidos grandes $> 70\%$ la robustez del método se mantiene siendo como máximo $72\% \pm 10\%$ con 100 % de ruido.

En la figura 13 (a) y (b) se pueden apreciar los resultados para la fase de producción de la red para el método que usa los pares de entrada/salida Seno y Coseno.




Figura 13: Producción Seno (a) y Coseno (b) con 10 % de ruido

2. Método de validación usando los Polinomios de Legendre $P_l(x)$

En este método buscamos la mejor estimación (predicción) para la derivada de los polinomios de Legendre $P_l(x)$ en el intervalo $[0, 1]$ a partir de las funciones primitivas de estos polinomios dando sólo el intervalo $[-1, 0)$, de igual forma que en el método *Sen - Cos* se agregó ruido para hacer más difícil la labor de predicción de la RNA. En las figuras 14 (a) y (b) se muestran dos ejemplos de predicciones calculadas por la RNA usando 10 y 50 % de ruido usando los polinomios de Legendre.

% de ruido	Eficiencia (%)	% de ruido	Eficiencia (%)
0	99,01	52,5	85,65
2,5	98,94	55	85,05
5	98,64	57,5	84,41
7,5	98,08	60	83,74
10	97,48	62,5	82,81
12,5	96,84	65	82,25
15	96,21	67,5	81,33
17,5	95,52	70	80,82
20	94,84	72,5	80,34
22,5	94,08	75	79,26
25	93,45	77,5	78,87
27,5	92,74	80	78,39
30	92,14	82,5	77,24
32,5	91,26	85	76,33
35	90,65	87,5	76,00
37,5	89,92	90	75,22
40	89,38	92,5	74,36
42,5	88,71	95	73,61
45	87,88	97,5	73,43
47,5	87,15	100	71,82
50	86,49		

Cuadro 4: Valores de Ruido y eficiencia para la RNA Sen-Cos

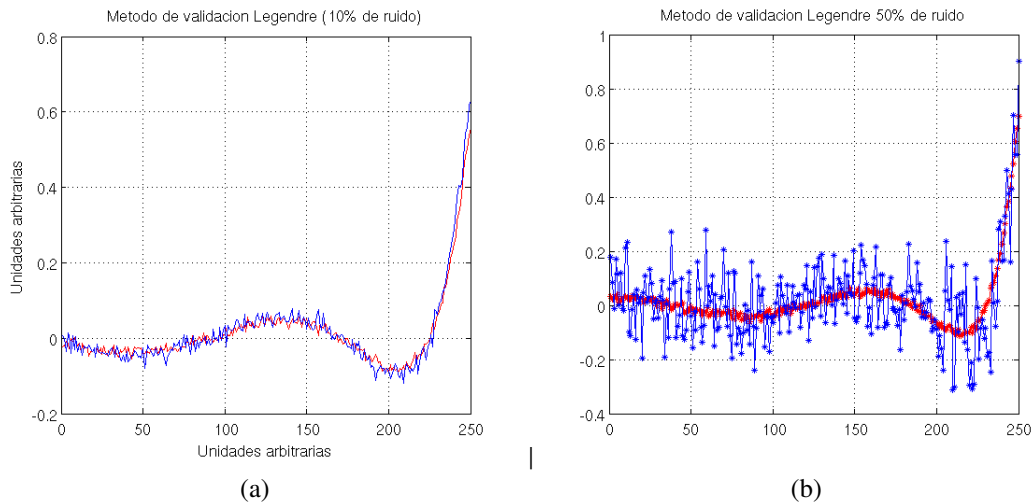


Figura 14: Legendre 10 % (a) y 50 % (b) de ruido, [b (real), r (estimada)]

En las figuras 15 (a) y (b) se observan los gráficos de dispersión realizados para 10 % y 50 % de ruido respectivamente. Se ilustran las respectivas rectas de regresión lineal, con pendientes 0,82 para el comportamiento de la dispersión con ruido 10 % y 0.59 para el 50 % de ruido. Finalmente la figura 16 (b) muestra la eficiencia vs ruido para el caso Polinomios de Legendre. La correlación es lineal negativa como era también de esperarse, observándose un aumento progresivo en la barra de dispersión del error al aumentar éste, por tanto para ruido pequeño < 20 % la calidad de la predicción es muy buena > 95 % con $\% \pm 4$ de error y que para ruidos grandes > 70 % la robustez del método se mantiene siendo como máximo 72 % ± 10 % con 100 % de ruido.

3. **Predicción de la Temperatura a partir de la Radiancia.** Una vez realizada la validación adecuada de la RNA con datos numéricos artificiales, se generó una base conocimiento con el total de 454 días de medición, de los cuales se tomaron 80 % (363 días) de datos para el entrenamiento y un 20 % (90 días) para la fase de producción,

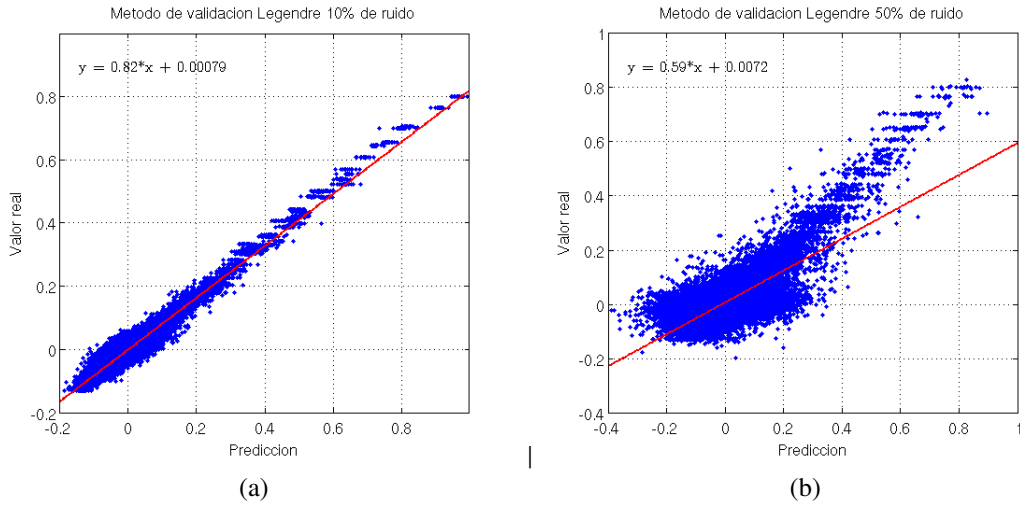


Figura 15: Dispersión Legendre 10 % (a) y 50 % ruido (b)

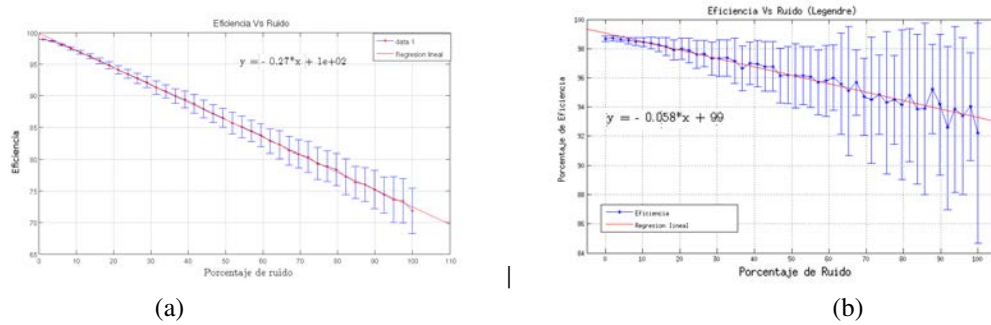


Figura 16: Eficiencia de la red con el método Sen-Cos (a) y Legendre (b)

ejecutándose ésta con diferentes pares entrada-salida conformados por datos climáticos reales debidamente depurados y normalizados para realizar la estimación de la temperatura durante la tarde (12:15 a 6:00) pm a partir de la Radiancia durante la mañana [6:00 a 12:00] am. En la figura 17 se muestran dos ejemplos del comportamiento de los valores estimados de la temperatura obtenidos por la RNA (línea roja) versus los valores reales (línea azul).




Figura 17: Predicción de temperatura a partir de Radiancia, real (azul) estimada (rojo)

Entrada	Salida	E_m (%)
Radiancia	Temperatura	5.25
Temperatura	Temperatura	5.57
Radiancia	Radiancia	16.25
Humedad	Radiancia	10.06
Temperatura	Humedad	9.61
Velocidad del viento	Velocidad del viento	12.24
Temperatura	Velocidad del viento	12.13

Cuadro 5: Resumen de los resultados obtenidos usando datos reales

El gráfico de dispersión (ver figura 18) fué realizado para toda la base de datos e ilustra dos ejemplos de la diferencia entre los valores reales de la temperatura (a) y velocidad del viento (b) y los valores estimados por la red. El valor promedio del histograma de dispersión para la temperatura se centra en -0.21 y su desviación en ± 1.15 grados Centígrados respectivamente, para la velocidad del viento la diferencia se centra en 0.027 y su desviación en ± 0.433 Km/h. El valor negativo en el caso de predicción de la temperatura, expresa el hecho de que el valor estimado está ligeramente por debajo del valor real como puede observarse en la figura 17. Estos resultados están dentro del rango de error en las estimaciones de variables climáticas en los sistemas estándares de predicción de la red mundial de climatología [4, 6].




Figura 18: Histograma de dispersión Temperatura (a) y Velocidad del Viento (b)

Un resumen de resultados se puede apreciar en el cuadro 5 realizada sólo para el conjunto de datos usado en la fase de producción, esto es un 20 % de los datos. En este cuadro se presenta el par entrada-salida a la RNA y su correspondiente error medio porcentual (E_m %) dado por:

$$E_m \% = \frac{|V_{real} - V_{est}|}{V_{real}} * 100 \% \quad (2.2)$$

Siendo V_{real} y V_{est} el valor real y el valor estimado por la RNA del parámetro climático en estudio. El máximo error no supera el 17 % en cualquiera de las combinaciones entrada-salida utilizada, ésto manifiesta una clara evidencia de la robustez del método, dado que por ejemplo en la predicción de temperatura usando Radiancia no se supera mas de ± 1.15 grados Celsius de error. Estos resultados son concordantes con la habilidad de la RNA de ser transparente al ruido de los datos como lo demuestran los métodos sintéticos utilizados en esta investigación al añadir hasta un 100 % de ruido a la señal manteniendo su eficiencia en este caso por arriba del 75 % (ver figura 16 (a y b)).

3. Conclusiones

El uso de RNA en la predicción de series temporales es ampliamente conocido en la literatura, sin embargo en el estudio de parámetros climáticos en pequeñas áreas geográficas sigue siendo un propósito de investigación aún abierto. Áreas vinculadas con la agricultura intensiva, demanda energética (tanto eólica como solar), proliferación de plagas, así también en la diseminación de contaminantes radiactivos locales debido a accidentes nucleares y/o propagación de enfermedades infecto-contagiosas, todos altamente dependientes de las condiciones climáticas, suman importancia a este trabajo. Los resultados obtenidos en cuanto a la estimación de los parámetros climáticos dan pie para afirmar que es un método robusto en cuanto a la dependencia señal/ruido, dado que la RNA es capaz de rescatar el comportamiento promedio de la serie temporal aún con niveles de ruido excesivo. El algoritmo usado en este estudio fue el de *Back-propagation*, pero así también existen otros como el *Lavenberg-Marquardt* o las redes neuronales con respuesta finita al impulso (RNRFI) [21, 7], es posible que con cualquiera de ellos se podrían obtener similares y/o mejores resultados usando series temporales de corto plazo. A pesar de que la base de datos real es relativamente pequeña, se hace uso por lo tanto, de la validación del modelo con datos simulados, lo que permite que esta investigación proporcione una metodología general que podría servir de guía para estimar el clima local, de hecho la RNA puede alimentarse con cada día transcurrido e incorporarlo como un nuevo ejemplo, lo que la convertiría en una red de aprendizaje dinámico con sus correspondientes ventajas en cuanto a la actualización permanente de la base de conocimiento.

Referencias

- [1] T. Carleton; S. Hsiang. Social and economic impacts of climate. *Science*, 353(6304):aad9837, 2016, Disponible: <http://science.sciencemag.org/content/353/6304/aad9837>.
- [2] A. Olmstead; P. Rhode. Responding to climatic challenges: lessons from us agricultural development. In *The economics of climate change: Adaptations past and present*, pages 169–194. University of Chicago Press, 2011.
- [3] T. Palmer. Predicting uncertainty in forecasts of weather and climate. *Reports on Progress in Physics*, 63(2):71, 2000.
- [4] United States Department of Energy (DOE), 2016.
- [5] P. Moonen; T. Defraeye; V. Dorer; B. Blocken; J. Carmeliet. Urban physics: effect of the micro-climate on comfort, health and energy demand. *Frontiers of Architectural Research*, 1(3):197–228, 2012.
- [6] T.F. Stocker. Ipcc (intergovernmental panel on climate change). climate change 2013: The physical science basics. *Cambridge University Press: Cambridge, UK; New York, NY, USA*, 2013.
- [7] R. Duda; P. Hart; D. Stork. *Pattern classification*. Wiley New York, 2 edition, 2001.
- [8] D. Lindley. *Making decisions*. Wiley, 2 edition, 1991.
- [9] S. Roy J. Traiteur; D. Callicutt; M. Smith. A short-term ensemble wind speed forecasting system for wind power applications. *Journal of Applied Meteorology and Climatology*, 51(10):1763–1774, 2012.
- [10] M. Vuckovic; K. Kiesel; A. Mahdavi. The extent and implications of the microclimatic conditions in the urban environment: A vienna case study. *Sustainability*, 9(2):177, 2017, Disponible: <http://www.mdpi.com/2071-1050/9/2/177>.
- [11] National Association of Regulatory Utility Commissioners (NARUC) National Wind Coordinating Collaborative (NWCC) and the Western Governors Association, 2007.
- [12] Ö. Dombaycı; M. Gölçü. Daily means ambient temperature prediction using artificial neural network method: A case study of turkey. *Renewable Energy*, 34(4):1158–1161, 2009.
- [13] A. Litta; S. Idicula; U. Mohanty. Artificial neural network model in prediction of meteorological parameters during premonsoon thunderstorms. *International Journal of atmospheric sciences*, 2013:1–14, 2013.
- [14] M. Behrang; E. Assareh; A. Ghanbarzadeh; A. Noghrehabadi. The potential of different artificial neural network (ann) techniques in daily global solar radiation modeling based on meteorological data. *Solar Energy*, 84(8):1468–1480, 2010.
- [15] I. Seginer. Some artificial neural network applications to greenhouse environmental control. *Computers and Electronics in Agriculture*, 18(2-3):167–186, 1997.
- [16] A. Kémajou; L. Mba; P. Meukam. Application of artificial neural network for predicting the indoor air temperature in modern building in humid region. *British Journal of Applied Science & Technology*, 2(1):23–34, 2012.
- [17] P. McSharry; S. Bouwman; G. Bloemhof. Probabilistic forecasts of the magnitude and timing of peak electricity demand. *IEEE Transactions on Power Systems*, 20(2):1166–1172, 2005.
- [18] A. Parisi; F. Parisi; D. Díaz. Modelos de algoritmos genéticos y redes neuronales en la predicción de índices bursátiles asiáticos. *Cuadernos de economía*, 43(128):251–284, 2006.
- [19] E. Trejos; P. Varela; J. Restrepo. Pronóstico del índice general de la bolsa de valores de colombia usando redes neuronales. *Scientia et Technica*, 1(41):129–134, 2009.
- [20] C. Bocanegra; H. Cybis; M. Jacques; M. Stumpf. Modelo de redes neuronales artificiales para determinar la velocidad en vías con fiscalización electrónica de la velocidad. In *VI Congreso de Ingeniería del Transporte*, 2004.
- [21] E. Rich; K. Knight. *Artificial Intelligence*. McGraw-Interamericana de España, 2 edition, 1994.
- [22] ADCON Telemetry. Products. adwave user manual, 2018, Disponible: <http://www.adcon.com/products/sensors>.

Sobre los autores

Misael Darío Rosales Ramírez

Doctor en Física. Profesor- investigador de la Universidad de los Andes, Laboratorio de Física Aplicada, Venezuela. Correo: misael@ula.ve - [ORCID](#)

Cesar Augusto Mora Benavídes

Licenciado en Física. Analista de Sistemas en la Fundación para el Desarrollo de la Ciencia y la Tecnología FUNDACITE - Mérida. Venezuela. Correo: carlosg@ula.ve - [ORCID](#)

Carlos Eduardo Guada Barráez

Doctor. Profesor- investigador de la Universidad de los Andes, Laboratorio de Geofísica, Venezuela. Correo: camobe@gmail.com - [ORCID](#)