

Generación de pronósticos para la precipitación diaria en una serie de tiempo de datos meteorológicos

Forecast generation for daily precipitation in a time series of meteorological data

Geração de prognósticos para a precipitação diária em uma série de tempo de dados meteorológicos

Para citar este artículo / To reference this article / Para citar este artigo: Hernández Leal, E. J., Duque Méndez, N. D. y Moreno Cadavid, J. M. (2016). Generación de pronósticos para la precipitación diaria en una serie de tiempo de datos meteorológicos. *Ingenio Magno*, 7(1), 144-155.

Emilcy Juliana Hernández-Leal

Universidad Nacional de Colombia,
sede Medellín, Facultad de Minas,
Maestría en Ingeniería Administrativa
ejhernandezle@unal.edu.co

Néstor Darío Duque Méndez

Universidad Nacional de Colombia,
sede Manizales, Facultad de Administración,
Grupo de Investigación GAIA
ndduqueme@unal.edu.co

Julián Moreno-Cadavid

Universidad Nacional de Colombia,
sede Medellín, Facultad de Minas,
Grupo de Investigación GIDIA
jmoreno1@unal.edu.co

Fecha de recepción: 13 de abril de 2015

Fecha de aprobación: 8 de junio 2016

Resumen

Los pronósticos de series de tiempo meteorológicas pueden ayudar a los procesos de toma de decisiones llevados a cabo por entidades encargadas de la prevención de desastres y la generación de alertas tempranas, ante la posibilidad de ocurrencia de eventos naturales que conlleven situaciones de riesgo para las comunidades. Para la realización de estos pronósticos, se cuenta con un número considerable de métodos, que van desde los ingenuos o *naïves*, hasta los que emplean técnicas más complejas, como las propias de la inteligencia artificial. En este estudio experimental se trabajó una serie de tiempo meteorológica de la estación Agronomía de Manizales, la cual presenta datos de las variables *precipitación, temperatura media, brillo solar y humedad relativa*. Se emplearon pronósticos por el método *naïve*, por redes neuronales artificiales y con sistemas neurodifusos; también se hizo una comparación de estos contra una regresión lineal múltiple, con el fin de verificar su precisión. Los resultados obtenidos en este estudio muestran, por una parte, que es posible refinar los modelos generalmente usados para lograr resultados más concluyentes; por otra, que se puedan extender a otras estaciones de monitoreo de la región, incluyendo nuevas variables tanto explicativas como por predecir.

Palabras clave: análisis de datos, meteorología, métodos ingenuos (*naïves*), pronósticos, redes neuronales artificiales, sistemas neurodifusos.

Abstract

Meteorological time series forecasts can help decision-making processes carried out by entities in charge of disaster prevention and early warning generation before the possibility of natural events involving situations which are dangerous for communities. There are a considerable number of methods for these forecasts, ranging from simplistic or Naïve methods to those which employ more complex techniques such as those using artificial intelligence. This experimental study worked with a meteorological time series from the station agronomy in the city of Manizales, which provides data on the variables: precipitation, average temperature, sunlight and relative humidity. Forecasts were employed with the Naïve approach, with artificial neuronal networks and with neuro-fuzzy networks; also comparing these with a multiple linear regression, with the goal of verifying their precision. The results obtained in this study show firstly that it is possible to refine the models generally used in order to achieve more conclusive results and secondly that they can be extended to other monitoring stations in the region, including new variables, both explanatory and predictive.

Keywords: Data Analysis, Meteorology, Simplistic (Naïve) Methods, Forecasts, Artificial Neuronal Networks, Neuro-fuzzy Systems.

Resumo

Os prognósticos de séries de tempo meteorológicos podem ajudar nos processos de tomada de decisão executados pelas entidades de previsão de desastres e da geração de alertas com antecedência, diante da possibilidade de ocorrência de eventos naturais que acarretam situações de risco para as comunidades. Para a realização destes prognósticos há um número considerável de métodos, desde os ingênuos ou *naïve* até aqueles que utilizam técnicas mais complexas como a inteligência artificial. Neste estudo experimental foi empregada uma série de tempo meteorológica da estação chamada Agronomia da Cidade de Manizales- Colômbia, a qual armazena os seguintes dados de variáveis: precipitação,

temperatura média, brilho solar e umidade relativa. Os prognósticos pelo método naïve, redes neurais artificiais e com sistemas neuro difusos foram utilizados; fazendo também uma comparação dos mesmos frente a uma regressão múltipla, destinada a verificar a precisão. Os resultados obtidos neste estudo mostram por um lado, que é possível refinar os modelos utilizados geralmente para atingir resultados mais conclusivos e, por outro, que sejam extensivos a outras estações de monitorização da zona, incluindo novas variáveis, tanto explicativas, quanto, variáveis que permitem prever.

Palavras Chave: análise de dados, meteorologia, métodos ingênuos, prognósticos, redes neurais artificiais, sistemas neuro difusos.

1. Introducción

La predicción de condiciones atmosféricas asociadas al clima de una ciudad forma parte de las fases fundamentales para la realización de análisis de riesgo y para la generación de alertas tempranas ante la posibilidad de fenómenos adversos (Benadero, 2001). Para la realización de predicciones se necesita contar con la recopilación de datos que permitan la generación de modelos y su validación. En esta medida, en la ciudad de Manizales, el Instituto de Estudios Ambientales (IDEA), adscrito a la Universidad Nacional de Colombia, se ha concentrado en el desarrollo de proyectos en el campo ambiental, caracterizados por afrontar problemáticas ambientales en búsqueda de la construcción de un desarrollo sostenible para la ciudad y la región (IDEA, 2014).

Dentro de dichos proyectos se encuentran las Redes de Estaciones Hidrometeorológicas, con las que se lleva a cabo un monitoreo continuo en diferentes puntos estratégicos de de Manizales y Caldas; cuentan con el apoyo de la entidad pública, la empresa privada y la academia, y son un proyecto pionero de la región cafetera (Pachón, 2011). Entre sus fines se encuentran la presentación del estado del clima en tiempo real y la elaboración de análisis e indicadores del comportamiento de las variables hidrometeorológicas monitoreadas.

Precisamente, una de estas variables es la precipitación, que es una de las más predominantes y presenta mayor correlación con eventos naturales como los

deslizamientos, los cuales han afectado a la región durante décadas. En relación con lo anterior, Rodríguez, Torres y León (2000) afirman que la importancia de conocer y poder pronosticar la precipitación radica en la correspondencia que esta tiene con sucesos como movimientos de remoción de masa, inundaciones y avalanchas, que pueden permitir adoptar medidas preventivas y de mitigación para dichos eventos.

En este contexto, en este artículo se muestran los resultados de la aplicación de tres métodos de pronóstico para la variable *precipitación*, aplicados a una serie de tiempo de datos meteorológicos, así como su comparación contra la regresión lineal múltiple. Se pretende que este trabajo sirva de referencia para el proyecto de monitoreo ambiental del IDEA. Los métodos aplicados son: pronóstico ingenuo (*naïve*), red neuronal artificial (RNA) y sistema neurodifuso (ANFIS).

La estructura del artículo es la siguiente: en la sección II se presentan los antecedentes referentes al origen de la serie de tiempo y el análisis exploratorio que se realizó sobre los datos recolectados. La sección III contiene una breve descripción de los métodos de pronósticos utilizados. Por su parte, en la sección IV se muestran los resultados de la predicción arrojada por los métodos y se hace una comparación de estos. Por último, en la sección V se traen a colación las conclusiones y recomendaciones para trabajos futuros.

2. Antecedentes

A continuación se presenta información de la estación meteorológica objeto de estudio y se detalla el proceso de ETL (extraer, transformar, cargar) realizado a los datos analizados.

A. La estación y sus datos

Los datos analizados provienen de la información recolectada por la estación meteorológica Agronomía, ubicada en Manizales, Caldas (figura 1). La zona que comprende este departamento está ubicada en la región andina colombiana, delimitada por las cordilleras Central y Occidental; se ubica en el sistema tropical, en la zona de baja latitud ecuatorial o intertropical (Ocampo y Vélez, 2015).

Dicha estación presenta registros de mediciones de variables meteorológicas desde 1956; sin embargo, para este trabajo se ha tomado el periodo 1990-2004, ya que durante estos años se presenta buena regularidad en la transmisión de los datos diarios. La selección de esta estación se fundamenta en la cantidad de datos históricos con que cuenta. Además, ha sido considerada una estación climática de referencia obligatoria (Pachón, 2011), debido a que fue la primera estación de monitoreo que entró en funcionamiento en la ciudad. Las variables monitoreadas por la estación Agronomía se presentan en la tabla 1.

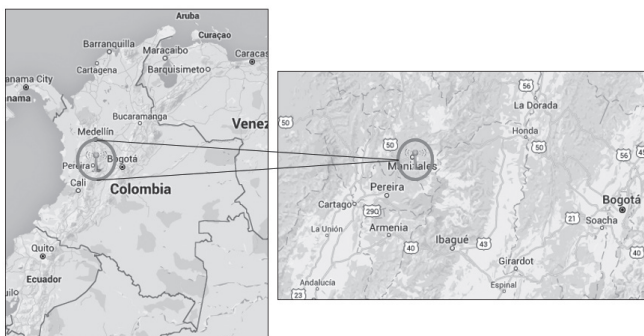


Figura 1. Información espacial de Manizales

Fuente: IDEA (2014).

Tabla 1. Resumen de variables estudiadas

Variable	Rangos históricos diarios
Temperatura media	– Temperatura máxima registrada: 29 °C
	– Temperatura mínima registrada: 8 °C
Brillo solar	– Brillo solar máximo registrado: 11,8 horas de sol
	– Temperatura mínima registrada: 0 horas de sol
Humedad relativa	– Humedad relativa máxima registrada: 96%
	– Humedad relativa mínima registrada: 45,67%
Precipitación	– Precipitación acumulada máxima registrada: 134 mm
	– Precipitación acumulada mínima registrada: 0 mm

Fuente: autores.

El total de los registros de la base de datos que se trabajó es de 5412, correspondientes a las mediciones diarias del periodo 1990 a 2004. La variable objeto del pronóstico fue la *precipitación diaria*, en tanto las variables explicativas fueron la *temperatura media*, el *brillo solar* y la *humedad relativa*. Se decide hacer el pronóstico de la variable *precipitación*, ya que, como se mencionó, esta es determinante para la ocurrencia de fenómenos adversos asociados al clima de una ciudad.

B. Proceso de ETL realizado

En Duque, Orozco y Vélez (2014) se menciona el desarrollo de un modelo conceptual para un esquema de almacenamiento de series de datos hidroclimatológicas a través de una bodega de datos. Es importante resaltar que en este trabajo se ratifica la importancia de contar con unos datos validados y que hayan sido sometidos

a un proceso de ETL previo a los análisis. Esto tiene por fin garantizar coherencia en cuanto a unidades y periodicidad y conseguir datos con integridad y consistencia.

De acuerdo con lo anterior, y de manera previa a la aplicación de los métodos de pronóstico, estos datos fueron sometidos a un proceso de limpieza y análisis exploratorio, por medio del cual se normalizaron para lograr estandarizar las diferentes unidades en que se tenía cada variable. Asimismo, se revisó la autocorrelación y la correlación parcial de la variable por predecir (precipitación), con el fin de determinar las variables de rezago (Makridakis, 2004). La figura 2 presenta las gráficas de comportamiento de las variables *temperatura del aire*, *precipitación* y *humedad relativa* para el periodo 1990-2004.

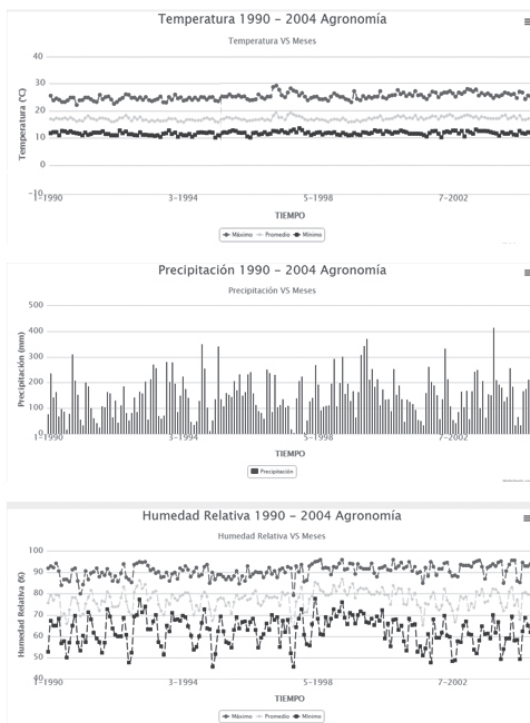


Figura 2. Comportamiento de las variables a través de la serie de tiempo.

Fuente: IDEA (2014).

Por su parte, en las figuras 3 y 4 se muestran las representaciones de la autocorrelación y de la correlación parcial para la variable por predecir, respectivamente. Los datos fueron analizados en el *software* Matlab, en el que también fueron generadas las gráficas.

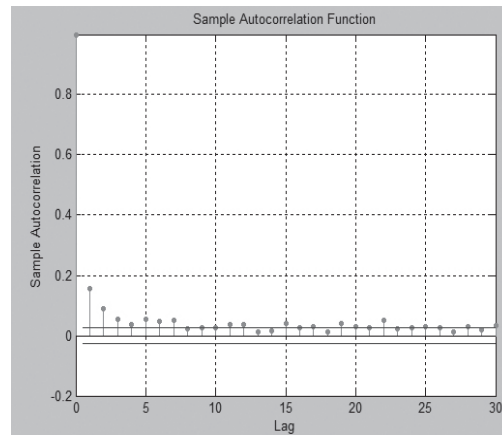


Figura 3. Autocorrelación

La variable de rezago escogida, para acompañar a las demás variables explicativas, fue la precipitación en el periodo $t-1$ y $t-2$. Lo anterior se fundamenta en el análisis de los comportamientos de la autocorrelación y la correlación parcial que se muestran en las figuras 3 y 4.

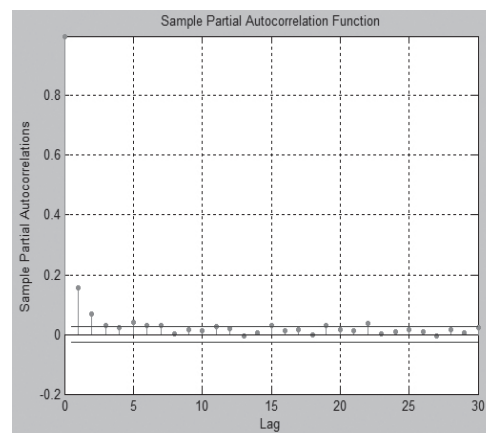


Figura 4. Correlación parcial

Fuente: autores a través de Matlab.

Una vez efectuado este análisis exploratorio y la preparación de la base de datos, se procedió a realizar los pronósticos con los métodos de pronóstico seleccionados: a) el método de pronóstico ingenuo (*naïve*), que fue aplicado debido a que permite tener un punto de referencia para la comparación de los resultados de otros métodos; b) el método de la red neuronal artificial, que fue elegido para corroborar las ventajas descritas en trabajos relacionados (Velásquez, 2011; Velásquez y Franco, 2012); c) el sistema neurodifuso (ANFIS), ya que se quieren explorar los resultados de sus predicciones para variables con patrones aleatorios, como es el caso de la precipitación.

3. Descripción de los métodos de pronósticos

Los métodos de pronóstico utilizados se conceptualizan brevemente a continuación.

A. Método de pronóstico ingenuo (*naïve*)

En estadística es conocido también como *modelo de caminata aleatoria* (Makridakis, 2004). Consiste en tomar como pronóstico la información disponible más reciente en relación con el valor real; es decir, si se inicia en un estado 0, el siguiente dato en la serie de tiempo será el estado +1 (Rincón, 2012). Si se lleva al caso de estudio de la serie de tiempo de datos meteorológicos, el pronóstico para el día 1 será la precipitación registrada en el día 2, y así sucesivamente. Siguiendo a Makridakis (2004), esto se puede resumir en la siguiente ecuación:

$$P_{t+1} = Y_t \quad (1)$$

Donde:

P_{t+i} = pronóstico del periodo $t+i$

t = periodo actual

i = número de periodos adelantados pronosticados

Y_t = último valor real

B. Red neuronal artificial (RNA)

Haykin (2001) afirma respecto a este método:

Una red neuronal artificial es un procesador distribuido de forma masivamente paralela, propensa, de manera natural, a almacenar el conocimiento debido a la experiencia, y hacerlo disponible para su uso. Este tipo de redes se relaciona con el cerebro, por la manera como se adquiere conocimiento mediante un proceso de aprendizaje y la cohesión que se presenta entre las neuronas (peso sináptico), la cual se emplea para almacenar conocimiento (citado en Prieto, Hernández y Novales, 2014).

Algunos trabajos resaltan la posibilidad de aplicar las RNA para el análisis de series temporales. Estas, por medio de la revisión de dependencias entre atributos, detectan patrones que pueden ser utilizados para la predicción (Salini y Pérez, 2006; Cedeño, Ortega e Infante, 2008). En este trabajo se optó por emplear una RNA de tipo FeedForward, cuya arquitectura general se presenta en la figura 5.




Figura 5. Esquema de la RNA

Fuente: autores a través de Matlab.

C. Sistema neurodifuso (ANFIS)

El tercer método consiste en una combinación de RNA con otra técnica de inteligencia artificial ampliamente difundida: la lógica difusa (LD) (Ramírez y Laguna, 2012). Concretamente se trata de un sistema de inferencia neurodifuso adaptativo (ANFIS, por sus siglas en inglés). La primera aproximación realizada sobre la combinación de LD y RNA fue hecha por Jang, que utilizó las RNA para buscar la solución más óptima

mediante el cambio de los parámetros de la FL a través de un algoritmo de aprendizaje (Jodeiri Shokri, Ramazi y Doulati Ardejani, 2014).

Los sistemas neurodifusos suelen usar un algoritmo híbrido como dos pasos: el primero es hacia adelante y se identifican los parámetros de consecuencia por medio de un estimador de mínimos cuadrados; en el segundo se hace una propagación de los índices de error y una actualización de los parámetros de premisa. Al tener este enfoque de tipo híbrido, el sistema neurodifuso suele converger de manera más rápida que el método de propagación que se emplea en el entrenamiento de RNA (López y Hernández, 2010; Peña, Ayala y Aguilar, 2015).

4. Resultados del pronóstico y comparación de los métodos

El *software* con el cual se realizaron los pronósticos de la red neuronal artificial y el sistema neurodifuso fue Matlab; por ello, los nombres de las funciones que se describen a continuación son los dados por esta herramienta.

A. Pronóstico con el método ingenuo (*naïve*)

Como se mencionó en la sección III-A, el método de pronóstico ingenuo consiste en tomar como predicción para el periodo t el último valor real, es decir, el del periodo $t-1$. En este caso de estudio se tomó como predicción de la precipitación diaria para el periodo $t+1$ el valor del día anterior, es decir, la precipitación del periodo t .

Como es de esperarse, este método de pronóstico no es muy acertado, ya que, tratándose de una variable como la precipitación y de una región perteneciente a la zona ecuatorial, donde los eventos de lluvia son tan variantes y no siguen un patrón claro, tomar como pronóstico la precipitación del día anterior es bastante alejado de la realidad. Sin embargo, se ha querido realizar este

pronóstico para tener un punto de comparación adicional a la regresión lineal múltiple. Los resultados, en términos de error, se pueden apreciar más adelante, después de que se presenten los pronósticos de la RNA.

B. Pronóstico con la RNA

En la tabla 2 se muestran las especificaciones de la red construida, en cuanto al tipo, las funciones de entrenamiento y de aprendizaje adaptativo, el número de capas y neuronas, las funciones de transferencia para cada capa y el número de entrenamientos sucesivos.

Tabla 2. Características de la red neuronal

Característica	Descripción
Tipo de red	<i>Feed-forward backprop</i>
Función de entrenamiento	Traingdm
Función de aprendizaje adaptativo	Learngdm
Número de capas ocultas y neuronas	Capa 1 con 5 neuronas Capa 2 con 1 neurona
Función de transferencia capa 1	Tangente (tansig)
Función de transferencia capa 2	Lineal <i>purelin</i>
Cantidad de entrenamientos	20

Fuente: autores.

Los parámetros seleccionados para el número de neuronas en la capa de entrada corresponden a suma de las tres variables explicativas, más la variable por

pronosticar (cuatro neuronas en total). La decisión de tener dos capas ocultas se tomó tras evaluar diferentes configuraciones y notar que esta era la que más se adaptaba a los datos trabajados. Igualmente se aplicó este criterio para la selección de las funciones de entrenamiento, aprendizaje y transferencia. La capa de salida tiene una sola neurona, ya que es una sola variable la que se desea pronosticar.

La serie de tiempo fue dividida en tres grupos: uno para entrenamiento, otro de prueba y un último de validación. A cada grupo se le asignó un porcentaje de datos: para

entrenamiento 70% y para prueba y validación 15% a cada uno. La división de los datos en estos tres grupos se hizo con el fin de evitar el sobreentrenamiento de la red (Suresh, Dong y Kim, 2010; Wade, McDaid, Santos y Sayers, 2010).

Los resultados obtenidos después de los entrenamientos se pueden apreciar en la tabla 3. El parámetro de desempeño (*performance*) cuantifica un valor para el error que va cometiendo la red; a medida que este parámetro se acerca a cero, indica la disminución en el error.

Tabla 3. Resumen de los entrenamientos realizados a la red

Entrenamiento	Iteraciones	Desempeño	Entrenamiento	Iteraciones	Desempeño
1	23	1,3982	11	6	0,9027
2	69	0,85262	12	10	1,0521
3	6	1,0094	13	6	1,0541
4	6	1,2875	14	6	1,081
5	6	0,9819	15	1000	0,9075
6	10	0,9352	16	6	0,83537
7	6	0,9694	17	8	0,9470
8	12	0,8345	18	6	0,90526
9	6	0,7970	19	12	0,9891
10	6	0,9863	20	12	0,77749

Fuente: autores.

Después de entrenada la red, se hizo un comparativo del pronóstico en relación con la variable de salida real (figura 6).




Figura 6. Pronóstico RNA (rojo) versus variable de salida (azul)

Fuente: autores a través de Matlab.

Las medidas de exactitud de los pronósticos consideradas en este trabajo fueron la raíz del error medio cuadrático (RMSE) y el error porcentual absoluto medio (MAPE). En la tabla 4 se presentan los valores de RMSE y MAPE obtenidos para cada uno de los métodos usados.

Tabla 4. RMSE y MAPE para cada método de pronóstico

Método de pronóstico	RMSE	MAPE
Método ingenuo	12,36	4,28
Regresión lineal múltiple	9,30	1,30
RNA	9,35	4,05
Sistema neurodifuso	1,50	0,14

Fuente: autores.

C. Pronóstico con el sistema neurodifuso (ANFIS)

Para este método se utilizó el complemento ofrecido por Matlab para este tipo de sistemas. Los datos fueron divididos en los mismos tres grupos que se usaron con la RNA (entrenamiento, prueba y validación) y se conservaron también los porcentajes de 70, 15 y 15%, respectivamente. El sistema neurodifuso contó

con una función de pertenencia lineal y un método de optimización híbrido. La generación de reglas se hizo por medio de análisis de clúster. En la figura 7 se presenta la estructura generada para el método en mención.

El modelo utilizado para el ANFIS fue el Sugeno; se seleccionó este método ya que es computacionalmente eficiente y trabaja bien para la optimización y adaptación de técnicas. Para la construcción de cada regla se tiene en cuenta su peso y su fuerza de activación. Las reglas construidas con el modelo Sugeno operan tomando dos entradas (*inputs*); a estas se les aplica la función de pertenencia lineal y posteriormente se hace el AND para obtener la regla. En la figura 8 se presenta la formación de los clústeres y las reglas establecidas.

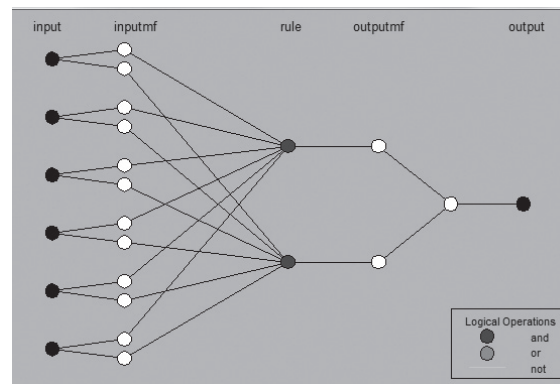


Figura 7. Estructura del sistema neurodifuso

Fuente: autores a través de Matlab.

Como se evidencia en la tabla 4, el pronóstico generado por el sistema neurodifuso está más ajustado; sin embargo, el principal inconveniente que se presenta para todos los métodos es el concerniente a los periodos

de tiempo (días) en los que no se presenta ocurrencia de eventos de lluvia, puesto que los métodos no suelen lograr predecir la ausencia de precipitación.




Figura 8. Estructura de clústeres y reglas establecidas

Fuente: autores a través de Matlab.

Ahora bien, en la figura 9 se hace una presentación de los datos del entrenamiento versus la salida generada por el sistema neurodifuso.

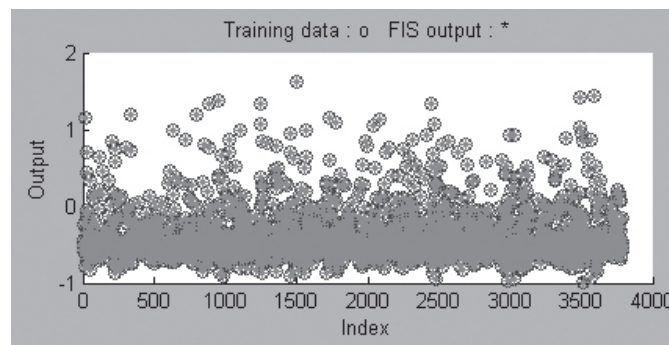


Figura 9. Datos de entrenamiento vs. salida en sistema neurodifuso

Fuente: autores a través de Matlab.

5. Conclusiones

Por medio de esta experiencia se logró hacer una evaluación de dos métodos de pronóstico basados en técnicas de inteligencia artificial y su comparación con el método ingenuo y la regresión lineal múltiple. A partir de ello se pudo determinar que para la serie de tiempo trabajada, los pronósticos que se generaron presentan aún mucha discrepancia con relación a la realidad. Incluso en el modelo ANFIS, que presentó un RMSE y un MAPE pequeños, se encontró que los valores pronosticados para algunos periodos de tiempo (días) se alejan de la realidad.

Müller y García (2010) afirman en este sentido:

La evaluación de una predicción en un determinado periodo se utiliza para corroborar la capacidad del pronóstico realizado sobre la variable de interés, en comparación con el valor observado en dicho periodo (p. 68).

De acuerdo con lo anterior, el grado de ajuste que se logró para la serie de tiempo de los datos históricos de la estación Agronomía no es garantía de una buena capacidad de pronóstico para series de tiempo de otras estaciones de la red de monitoreo—incluso para series futuras de la estación en mención—, ya que aunque se busca minimizar el error, sigue existiendo una brecha entre el valor observado y el valor pronosticado.

Como trabajo futuro se plantea aplicar los métodos de pronóstico realizados a la estación Agronomía a otras estaciones pertenecientes a las redes de monitoreo de Manizales y Caldas. Se tomarían como variables explicativas, además de las estudiadas, otras correspondientes a la velocidad y dirección del viento, la presión barométrica, el nivel, el caudal y la radiación solar.

Se debe considerar también la necesidad de probar cambios en la arquitectura de la RNA, otros algoritmos de entrenamiento y funciones de propagación para perfeccionar la predicción e intentar generalizar los modelos de pronóstico para todas las redes de monitoreo.

Finalmente, se sugiere aumentar el tamaño del dataset de entrenamiento y prueba, por medio de la utilización de varias mediciones del día y la conformación de dataset a partir de los datos de varias estaciones cercanas en la red de monitoreo.

Agradecimientos

Los autores le agradecen al Instituto de Estudios Ambientales (IDEA) de la Universidad Nacional de Colombia, sede Manizales, por la colaboración prestada para la obtención de los datos analizados y sus orientaciones respecto al funcionamiento de las redes de monitoreo ambiental y las estaciones hidrometeorológicas.

Referencias

Benadero, F. R. (2001). Los conocimientos geográficos en la predicción de fenómenos meteorológicos de rango extraordinario. *Boletín de la Asociación de Geógrafos Españoles*, 31, 195-204.

Cedeño, F., Ortega, J. e Infante, S. (2008). Estimación de datos faltantes en estaciones meteorológicas de Venezuela vía un modelo de redes neuronales. *Revista de Climatología*, 8, 51-70.

Duque-Méndez, N. D., Orozco-Alzate, M. y Vélez, J. J. (2014). Hydro-meteorological data analysis using OLAP techniques. *DYNA*, 81(185).

Instituto de Estudios Ambientales (IDEA) (2014). Recuperado de <http://idea.manizales.unal.edu.co/>

- Jodeiri Shokri, B., Ramazi, H., Doulati Ardejani, F. D. y Sadeghiamirshahidi, M. (2014). Prediction of pyrite oxidation in a coal washing waste pile applying artificial neural networks (ANNs) and adaptive neuro-fuzzy inference systems (ANFIS). *Mine Water and the Environment*, 33(2), 146–156.
- López-Cruz, I. L. y Hernández-Larragoiti, L. (2010). Modelos neuro-difusos para temperatura y humedad del aire en invernaderos de tipo cenital y capilla en el centro de México. *Agrociencia*, 44, 791-805.
- Makridakis, S. (2004). *Métodos de pronósticos*. Ciudad de México: Limusa.
- Müller, O. V. y García, N. (2010). Análisis de la predicción de precipitaciones mediante relaciones canónicas en el NE de Argentina. *Revista Geofísica*, 62, 61-78.
- Ocampo López, O. L. y Vélez Upegui, J. J. (2015). Análisis climatológico para el departamento de Caldas. En *Entendimiento de fenómenos ambientales mediante análisis de datos* (pp. 1-44). Manizales: Universidad Nacional de Colombia.
- Pachón Gómez, J. A. (2011). Distribución de la lluvia y umbrales de alerta temprana con base en la Red de Estaciones Hidrometeorológicas de Manizales. En *200 años de la meteorología y de la climatología en América Latina: memorias*. Bogotá: IDEAM y Universidad Nacional de Colombia.
- Peña Durán¹, J. D., Ayala de la Vega, J. y Aguilar Juárez, I. (2015). Red neuro-difusa para el relleno de datos faltantes en la estación meteorológica Chapingo. *Revista Iberoamericana de las Ciencias Computacionales e Informática*, 4(7).
- Prieto Hernández, Y., Hernández Montero, F. E. y Novales Ojeda, A. (2014). Reducción de ruido aplicando redes neuronales artificiales. *Investigación Operacional*, 35(2), 110–120.
- Ramírez, N. V. y Laguna, M. (2012, diciembre). La lógica borrosa: conjuntos borrosos, razonamiento aproximado y control borroso. *Pistas Educativas*, 100, 55-65.
- Rincón, L. (2012). *Introducción a los procesos estocásticos*. Ciudad de México: Universidad Nacional Autónoma de México.
- Rodríguez, E. A., Torres, J. A. y León Díaz, P. J. (2000). Pronóstico de la precipitación máxima en 24 horas en la zona cafetera. *Ingeniería e Investigación*, 46, 5-11.
- Salini Calderón, G. y Pérez Jara, P. (2006). Estudio de series temporales de contaminación ambiental mediante técnicas de redes neuronales artificiales. *Ingeniare, Revista Chilena de Ingeniería*, 14(3), 284-290.
- Suresh, S., Dong, K. y Kim, H. J. (2010). A sequential learning algorithm for self-adaptive resource allocation network classifier. *Neurocomputing*, 73(16-18), 3012-3019.
- Velásquez Henao, J. D. (2011). Acotación del error de modelos de redes neuronales Aplicados al pronóstico de series de tiempo. *UIS Ingenierías*, 10(1), 65-71.
- Velásquez, J. D. y Franco, C. J. (2012). Pronóstico de series de tiempo con tendencia y ciclo estacional usando el modelo *airline* y redes neuronales artificiales. *Ingeniería y Ciencia*, 8(15), 171-189.
- Wade, J. J., McDaid, L. J., Santos, J. A. y Sayers, H. M. (2010). SWAT: a spiking neural network training algorithm for classification problems. *IEEE Transactions on Neural Networks*, 21(11), 1817-1830.