


Predicción de Pluviosidad en la Sabana de Bogotá con una Red Neuronal



RESUMEN

Este artículo presenta la red neuronal multicapa como herramienta para el aprendizaje y predicción de series de tiempo. Después de un breve marco teórico, se aplica la red neuronal a la serie de Pluviosidad tomada de los registros del HIMAT para la Sabana de Bogotá (estación meteorológica del aeropuerto El Dorado).

INTRODUCCION

La red neuronal como modelo computacional se está utilizando en control, electrónica, robótica y tratamiento de señales.

Algunas características de las redes neuronales son:

- (1) No requieren programación. Las redes aprenden mediante el procesamiento de una serie de ejemplos.

26

Ing. J. Alberto Delgado R.
Profesor Asistente
Departamento de Eléctrica
Universidad Nacional

- (ii) Debido a su rasgo no lineal pueden clasificar los patrones de entrada en categorías complejas.
- (iii) Pueden realizar generalizaciones, esto es, tienen capacidad para clasificar correctamente patrones de entrada nuevos.

1.- NEURONA ARTIFICIAL

La figura 1 muestra un modelo E/S de la neurona natural. El bloque no lineal que sigue al nodo de suma se denomina función de activación. Cuando la suma ponderada de todas las entradas a la neurona excede el umbral μ , se dispara y su salida toma el valor constante de +1. En caso contrario, la salida es -1.




Fig. 1 Modelo Entrada / salida de una neurona biológica. La función no lineal que sigue al nodo de suma se denomina función de activación

2.- RED NEURONAL

La figura 2 es una red neuronal multicapa 2-2-1. Esto es, tiene dos nodos de entrada, dos neuronas ocultas y una neurona de salida. Cada neurona de la figura 2, corresponde a un bloque similar a la figura 1, excepto que la función de activación es la tangente hiperbólica (función tipo S).

En la red neuronal todos los elementos de proceso actúan en paralelo para integrar los datos, una red reúne gran cantidad de conocimiento cuando toma una decisión y puede ponderar muchas opciones a la vez.

Al entrenar la red neuronal los pesos de las conexiones se modifican para reproducir los ejemplos. El peso,

$$w_{ij}^{(1)}$$

corresponde a la conexión que llega a la neurona i de la capa l desde la neurona o nodo j de la capa l-1. Recuerde que el nodo cero siempre toma el valor constante de +1 y se utiliza para el ajuste del umbral en cada neurona.

El algoritmo más conocido para el entrenamiento de redes neuronales multicapa es el de propagación inversa (Back Propagation). Este opera como sigue: Cada ejemplo o patrón que se presenta a la red es propagado hacia adelante; en la capa de salida se calcula el error cuadrático en base a la salida real de la red y la salida deseada, también se calculan las derivadas del error respecto de las neuronas de salida. Luego estas derivadas se propagan hacia atrás, para obtener las derivadas respecto de las neuronas ocultas. Una vez se tienen todas las derivadas se actualizan los pesos de las conexiones usando el método del gradiente. Debido a que las derivadas del error cuadrático se propagan en sentido inverso a las entradas, el algoritmo se conoce como propagación inversa.




Fig. 2 Red neuronal multicapa 2 - 2 - 1. La función de activación es la tangente hiperbólica.

El entrenamiento de la red finaliza cuando el error cuadrático para todos los ejemplos es menor que el error especificado.

3.- APLICACION [5]

Se analizó la serie de Pluviosidad para la Sabana de Bogotá tomada de los registros del HIMAT (estación meteorológica del aeropuerto El Dorado). Esta serie expresada en "días de lluvia/mes" se extiende desde 1972 hasta 1990.

3.1.- Red Neuronal Multicapa

El programa para simular la red neuronal contiene la función de activación en cada neurona,

$$f(s) = \frac{1}{1 + e^{-s}}$$

Por lo tanto fue necesario normalizar la serie en el intervalo [0,1], dividiendo cada dato por treinta, el número promedio de días en un mes.

La red neuronal realiza una autoregresión no lineal,

$$(X_K, X_{K+1}, \dots, X_{K+m}) = f(X_{K-1}, X_{K-2}, \dots, X_{K-n})$$

El índice m indica el número de meses de la predicción y el índice n señala el número de meses que se toman como base. Esto es, la red recibe n entradas y genera m salidas.

Debido al rango enorme de posibilidades se fijó el número de neuronas de salida en doce ($m = 12$), y se dejó libre para el proceso de búsqueda el número de neuronas en las capas de entrada y oculta.

3.2.- Criterio de Selección

Para cada año de predicción se calcula un error ϵ_i ,

$$\epsilon_i = \frac{\sum_{k=1}^{12} (X'_k - X_k)^2}{12}$$

donde X'_k representa el valor predicho por la red y X_k es el valor conocido

Luego para el intervalo de predicción (p años) se calcula el error total E dado por,

$$E = \sum_{i=1}^p \epsilon_i$$

Se selecciona la red neuronal que produce el menor valor de E.

3.3.- Resultados

Después de múltiples estudios la estructura seleccionada fue 48-12-12 para un intervalo de aprendizaje de diez años y con un error total, $E = 10.38$ [días/mes] sobre el intervalo de predicción de nueve años ($p = 9$).

La gráfica 3 muestra la serie original de Pluviosidad y la serie generada por la red para la predicción desde el año 11 hasta el año 19.

La figura 4 corresponde a la predicción sobre un intervalo no conocido: desde el año 1991 hasta el año 2000.

CONCLUSIONES

Las redes neuronales son modelos computacionales adecuados para

el aprendizaje de mapas de datos a datos. La ventaja principal es el entrenamiento con ejemplos, lo cual permite utilizar la experiencia para realizar análisis y predicciones en nuevos problemas.

La predicción realizada para la Pluviosidad en la Sabana de Bogotá durante los años 1991 - 2000 debe tomarse como una posibilidad generada con el modelo tipo RED NEURONAL que considera fenómenos no-lineales. Sin embargo, esta predicción no se puede calificar como perfecta.

REFERENCIAS

- (1) Kiloh, L.G., McComas, A.J. y Osselton, J. W.: *Clinical Electroencephalography*, Butterworths, Londres, 1972.
- (2) Hertz, J., Krog, A. y Palmer, R.: *Introduction to the Theory of Neural Computation*, Addison-Wesley Publishing Company, California, 1991.

- (3) Widrow, B. y Lehr, M.: **30 Years of Adaptive Neural Networks : Perceptron, Madaline and Backpropagation**, Proc. IEEE, vol. 78, No. 9, pp. 1415-1441, Septiembre 1990.
- (4) Hecht-Nielsen, R.: **Theory of the Backpropagation Neural Network**, Proc. IEEE-ICNN, I(593-605), IEEE Press, New York, 1989.
- (5) Torres, S.L. y Alfonso, J.N.: **Análisis de Series de Tiempo con Redes Neuronales Aplicado a Descargas Atmosféricas**, Proyecto de Grado, Facultad de Ingeniería, Departamento de Eléctrica, Universidad Nacional de Colombia, Santafé de Bogotá, Agosto de 1992.
- (6) Delgado, A.: **Elementos de Redes Neuronales y Algoritmos Genéticos**, NEURALES LTDA., Marzo 1992.




Fig. 3 Series de Pluviosidad real y predicha por la Red Neuronal para los años 11 a 19.




Fig. 4 Predicción de la Pluviosidad en la Sabana de Bogotá para los años 1991-2000, según modelo tipo Red Neuronal.

"Tenemos que obedecer a la más grande de las leyes, la del cambio. Esa es la ley más poderosa de la naturaleza".

Edmundo Burke