



Una técnica de pronóstico de señales basada en redes neuronales

Jorge Eduardo Ortiz T, Profesor Asistente, Departamento de Ingeniería de Sistemas, Universidad Nacional de Colombia
jorgeo@ing.unal.edu.co, Alex Buitrago, Ingeniero de Sistemas, Universidad Nacional de Colombia

INTRODUCCIÓN

El creciente interés por construir sistemas de procesamiento de señales mediante redes neuronales, especialmente durante los últimos veinte años, se debe a la posibilidad de avances significativos en campos poco explorados y cuyo manejo resulta de naturaleza compleja. Uno de estos campos es la *predicción de señales*. Una señal es una colección de valores que, generalmente, representan mediciones sucesivas de un evento del mundo real, los valores se toman durante un tiempo específico a intervalos regulares, representando una muestra del evento que se desea estudiar o de las características propias del mismo. La predicción de una señal consiste en obtener un conjunto de valores que, según un margen de error aceptable, constituyen una estimación del comportamiento futuro de la señal. El proceso de predicción es mucho más que la posición simplista de aventurar valores; puesto que requiere la construcción de un modelo adecuado de la dinámica del sistema a tratar.

Se han desarrollado procedimientos matemáticos para el tratamiento de este tipo de problemas. Entre los más conocidos se encuentran: los métodos *Autoregresivos de Promedio Móvil* (ARMA) y *Autoregresivos Integrados de Promedio Móvil* (ARIMA). Estos métodos, denominados clásicos en el contexto del problema, se utilizan muy

comúnmente, en especial los ARIMA, en el diseño de modelos de sistemas. Las investigaciones de redes neuronales en este campo son relativamente nuevas y los resultados obtenidos son prometedores. Sin embargo, como lo han demostrado algunos resultados, el uso de redes neuronales no necesariamente desplazará los métodos clásicos, sino que por el contrario, un análisis riguroso del sistema podría incluir ambas metodologías (o inclusive integrar otras).

En este artículo se realiza una comparación del desempeño de ambos métodos de predicción en el campo específico de las señales económicas; sin embargo, se concluye que su utilidad es clara en todas las áreas de la ciencia, tales como epidemiología, tratamientos de enfermedades, desarrollo y empleo de medicamentos etc., y de buena parte de todas las actividades humanas.

REDES NEURONALES

Concepto de red neuronal artificial

Una red neuronal artificial (RNA) es básicamente un conjunto de elementos interconectados denominados neuronas, los cuales están distribuidos en tres zonas: neuronas de entrada, neuronas intermedias y neuronas de salida. Las neuronas se interconectan e interactúan con el fin de lograr un comportamiento deseado para el sistema, tal como se muestra en la figura No1.

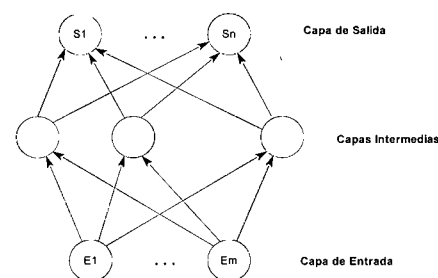


Figura No 1. Composición de una RNA.

Existen problemas que son irresolubles en este momento por medio de modelos matemáticos y que requieren de métodos no tradicionales de cálculo para obtener una respuesta. La gran mayoría de los sistemas reales tienen un comportamiento no lineal, lo que sugiere utilizar métodos que los trabajen tal como son o que por medio de una transformación emulen un comportamiento lineal. Las redes neuronales al ser, por definición, no lineales y al comportarse como un sistema dinámico se presentan como una solución a este tipo de problemas.

Las redes neuronales presentan las siguientes ventajas comparativas:

1. Son sistemas en general no lineales, de procesamiento masivamente paralelo.
2. Sistemas que aprenden asociaciones capaces de reconocer tramas de datos que contienen altos niveles de ruido.
3. El aprendizaje se basa en las características del sistema.

Método de Poda

El método de poda consiste en disminuir la complejidad de una RNA, sin que ésta pierda sus características propias. Se utiliza para encontrar una RNA adaptada a una función específica. Inicialmente, se parte de una red compleja (Feedforward o recurrente) para llegar a una lo más simplificada posible, eliminando sinapsis, neuronas y hasta niveles completos que no se necesitan o que no influyen de manera relevante dentro de la funcionalidad de la RNA.

PREDICCIÓN DE SEÑALES

Modelo Clásico

Durante el siglo XX y a partir de los trabajos de autores como Yule (1927), Box y Jenkins (1970), se han desarrollado una serie de modelos matemáticos muy difundidos en la actualidad. Estos modelos buscan expresar relaciones de valores actuales de las series de tiempo con datos de valores pasados. Formalmente, el modelo clásico se presenta por la ecuación:

$$\phi(B)(1 - B)^d x_t = \theta(B)r_t$$

La fórmula anterior se puede interpretar como la relación que dice que el valor actual de la señal depende de sus valores y ruidos pasados. El problema matemático para los métodos clásicos radica en hallar un modelo apropiado capaz de representar las características del sistema en estudio, para lo cual se utilizan una serie de técnicas de análisis cuyo tratamiento es avanzado y no serán descritas aquí. Una vez se tiene el modelo, los parámetros del mismo son estimados con el fin de obtener una dependencia funcional entre los valores de la serie.

Modelo De Redes Neuronales

Una red neuronal, por ser característicamente no lineal, puede ser expresada como un modelo genérico de aproximación de funciones. Tal afirmación se presenta de forma matemática en la ecuación (1), donde f puede ser cualquier tipo de función relacionando la salida x_t a un conjunto de variables de entrada.

$$x_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-d}) + g(r_t, r_{t-1}, \dots, r_{t-k}) \quad (1)$$

Estos modelos tienen la ventaja de explotar la no linealidad, sin embargo, pueden ser en sí mismos sumamente complicados para efectos del análisis matemático. En el caso particular de este estudio el parámetro k será tomado como cero y la función de dependencia del ruido (g) será la función identidad. Esto significa que el ruido que se le incorpora a la señal la afecta directamente.

ANÁLISIS DE DIMENSIÓN

Descripción

Al considerar una RNA como un sistema que relaciona valores pasados y futuros de una señal, podemos representarla tal como se muestra en la ecuación (2), donde $x(t)$ representa las muestras de valores pasados presentados a la RNA e $y(t)$ la respuesta de ésta última. Ver figura No 2.

$$y(t) = f(x(t)) \quad (2)$$



Figura No 2 Representación Sistémica de una RNA

De la figura No 2 se deduce que la primera consideración importante en la construcción de una RNA como predictor de una serie de tiempo, es la selección del vector de entrada, el cual no es otro que una ventana de valores pasados que se correlacionan de forma apropiada para el cálculo de valores futuros.

La selección del vector de entrada no es inmediata y, dada su importancia, se debe utilizar un método adecuado. Hong Pi y Carsten Peterson (1994) diseñaron el método de la prueba δ (δ -test), el cual establece dependencias funcionales dada una secuencia de medidas. Este método se basa en el cálculo de probabilidades condicionales y posterior derivación de las dependencias entre variables.

ANÁLISIS DE RESULTADOS

En esta sección se presentan las predicciones obtenidas a través de las metodologías Box & Jenkins y de redes neuronales para una señal de devaluación, una señal de naturaleza evidentemente económica, pero de amplio conocimiento para cualquier profesional. Los resultados del método Box & Jenkins fueron calculados utilizando el sistema estadístico SCA mientras que los resultados presentados para las redes neuronales fueron obtenidos mediante el Software KAISER desarrollado en la Facultad de Ingeniería de la Universidad Nacional de Colombia.

SEÑAL DE DEVALUACIÓN

La devaluación es la variación porcentual mensual de la tasa de cambio; definida esta última como el valor diario del dólar en pesos colombianos. Para propósito de este estudio, la serie de devaluación es tomada mensualmente durante el periodo comprendido entre enero de 1992 y mayo de 1998. El horizonte de predicción es de siete meses: noviembre de 1997 a mayo de 1998.

MODELO CLÁSICO

Se utilizó para efectos del análisis clásico un modelo de promedio móvil multiplicativo de orden dos, como se muestra a continuación. En pocas palabras, ello significa que los valores futuros de la señal dependerán de los valores inmediatamente anterior y de los valores del ruido de tres periodos atrás:

$$(1 - B)x_t = (1 - \theta_1 B)(1 - \theta_2 B^2)r_t$$

ANÁLISIS DE DIMENSIÓN

Los resultados del proceso de la prueba δ o análisis de dimensión se presentan en la Tabla No. 1.

Tabla No. 1. Dimensión para la serie de devaluación

Retardo	Relevancia
1	63.13
13	3.02
15	15.11
18	7.49
21	4.42
27	4.15
31	2.393

Se descartaron los retardos $t-31$ y $t-13$ debido a que presentaban la menor relevancia. Los valores incluidos en esta tabla muestran que, por ejemplo, para pronosticar el valor actual de la señal de devaluación es más importante conocer el anterior valor. No es significativo conocer el valor de dos periodos atrás (dato que no aparece en la tabla por tener una relevancia muy baja) y que el dato de 15 periodos atrás es también muy importante aunque menos que el primero.

METODO DE PODA

Al utilizar el método de poda, se eliminaron diez neuronas de la capa intermedia y sus respectivas conexiones, al igual que otros enlaces entre neuronas. La red resultante se muestra en la figura No 3.




Figura No 3. Topología de la RNA para la serie de devaluación.

PRONÓSTICO

La predicción generada por la red neuronal fue mejor que aquella derivada del modelo ARIMA. Los resultados de la RNA estuvieron relativamente cercanos en relación con el pronóstico del método clásico, aunque el último valor se encuentra lejano. No obstante, se observa que la RNA interpretó en forma correcta la tendencia de la serie de devaluación. El comportamiento de los pronósticos frente a la serie real se presenta en la figura No. 4, en tanto que los valores comparativos de las predicciones se relacionan en la Tabla No. 2.




Figura No 4. Pronósticos para la Serie de Devaluación.

En este caso sería de gran utilidad la búsqueda de un modelo ARIMA equivalente con el cual se podría lograr un mejor ajuste del mismo. El error de la red neuronal es relativamente bajo hasta la muestra 77 en la que el error crece de manera repentina. Para el caso del modelo ARIMA, el error resulta excesivamente grande a partir de la muestra 72.

Tabla No. 2. Predicciones para la Serie de Devaluación.

Observación	ARIMA	RNA	Original
71	2.38	2.95	2.50
72	3.42	0.81	0.17
73	3.33	1.26	2.02
74	3.33	0.68	1.73
75	3.33	0.90	0.81
76	3.33	0.27	0.26
77	3.33	-1.93	1.88




Figura No 5. Error Cuadrático Medio para la serie de devaluación.

DISCUSIÓN Y CONCLUSIONES

La información recolectada a través de métodos de predicción de series de tiempo puede ser usada para prevenir posibles comportamientos no deseados en el sistema y tomar medidas que favorezcan la estabilidad del mismo. Muchos problemas, en áreas como la salud, pueden fácilmente ser modelados por redes neuronales para obtener pronósticos de comportamientos futuros del sistema.

Los modelos de redes neuronales tienen la ventaja de ser inherentemente no lineales y de lograr adaptarse a las condiciones del sistema en estudio. Estos métodos presentan ciertas fortalezas que no necesariamente desplazan el uso de

los métodos tradicionales de predicción. Por el contrario, estos se pueden convertir en procedimientos complementarios para un análisis más riguroso del sistema. A partir de los resultados obtenidos en el estudio de una señal de naturaleza económica, se observa cómo las redes neuronales logran dilucidar la tendencia de las series. Por su parte, los métodos clásicos poseen la ventaja de representar matemáticamente el sistema.

El análisis de dimensión fue utilizado para obtener las variables más relevantes en las series estudiadas. Esta información se usó para definir la capa de entrada a la red neuronal. En los casos en que el método fue aplicado, se obtuvieron resultados mucho mejores que aquellos generados por el método de ensayo y error. Al emplear el análisis de dimensión en la construcción de las redes neuronales se alcanzaron niveles de error adecuados para continuar con el proceso de predicción.

Con el método de poda se logró disminuir la complejidad de la red generada, controlando así el efecto del sobredimensionamiento de las mismas. Al aplicar este método fueron transformadas topologías convencionales, como la feedforward y recurrente, logrando arquitecturas específicas para cada caso. Sin embargo, su empleo no garantiza un mayor grado de exactitud en la predicción.

RECOMENDACIONES BIBLIOGRÁFICAS

1. **Box G P, Jenkins GM.** Time Series Analysis : Forecasting and Control. San Francisco : Holden Day.1970.
2. **Freeman J, Skapura D.** Redes Neuronales: Algoritmos, aplicaciones y técnicas de programación. ADDISSON - WESLEY. 1997; .1 32, 93-132.
3. **Shumway R H.** Applied Statistical Time Series Analysis. Prentice Hall. 1998.
4. **Hong Pi, Carsten P.** Hong Pi y Carsten Peterson. Finding the Embedding Dimension and Variable Dependencies in Time Series. En: Neural Computation. 1994; 6, (3): 509-520.
5. **Yule, G U.** On a method of investigating periodicities in disturbed series with special reference to Wolfer's sunspot numbers. Phil. Trans. Roy. Soc. Londres. 1927; 226; (267-298).