

## Predicción de la actividad solar utilizando redes neuronales

R.A. Calvo<sup>(1)</sup>, H.A. Ceccatto<sup>(2)</sup> y R.D. Piacentini<sup>(2)(3)</sup>

<sup>(1)</sup>IRICE (CONICET-U.N. Rosario), 27 de Febrero 210 bis, 2000 Rosario, Argentina

<sup>(2)</sup>IFIR (CONICET-U.N. Rosario), 27 de Febrero 210 bis, 2000 Rosario, Argentina

<sup>(3)</sup>Observatorio Astronómico de Rosario, CC 606, Parque Urquiza, 2000 Rosario, Argentina

The neural network technique is used for describing the time series of solar activity as measured by the relative Wolf number. The 1700-1991 data is described rather well reproducing the extrema and the oscillations with varying periods. So, it is possible to extrapolate the Wolf number up to the year 2003, in order to predict the mean annual variation and to determine the time position and amplitude of the next minimum and maximum. Results are compared with other empirical techniques.

Las redes neuronales son algoritmos computacionales susceptibles de ser utilizados en el tratamiento de series temporales con comportamiento caótico o muy irregular, tales como las que miden la actividad solar. En el presente trabajo hemos estudiado el comportamiento del número relativo de Wolf, por disponerse de un registro más amplio (más de 250 años)<sup>1,2</sup> que de otras medidas de la actividad solar.

Las redes están formadas por unidades de procesamiento ( $u_j$ ) similares a neuronas, que sólo suman y calculan promedios, y a las que se les asocia un número de activación [ $a_i(t)$ ]. Pueden ser unidades de entrada (input) salida (output) u ocultas (hidden), según que reciban o envíen señales o no tengan relación directa con el exterior, respectivamente.

Estas unidades están relacionadas mediante un patrón de conectividad representado por la matriz  $W$ . Sus elementos representan el módulo y sentido de la conexión de la unidad  $u_j$  con la  $u_i$ . Para cada patrón de entrenamiento (ejemplo con que se entrena la red) los valores de las unidades de entrada son el estímulo a la red, mientras que las de salida son los valores deseados como respuesta a esa entrada.

La regla de propagación, describe en forma directa la manera en que se propagan las señales. En notación vectorial  $net(t) = a(t)W$ , donde  $net_i$  es la señal de entrada neta a la unidad  $i$ . También se necesita una regla (llamada regla de activación) tal que, dadas las señales de entrada y el estado actual de una unidad, se pueda calcular un nuevo estado. Es decir, se requiere una función  $F$  que tome  $a(t)$  y el vector  $net(t)$  y produzca un nuevo estado de activación  $a(t+1)$ . Para una función de activación  $F$  general, la evolución del

sistema viene dada por:

$$\mathbf{a}(t+1) = \mathbf{F}[\mathbf{a}(t), \mathbf{net}(t)] \quad (1)$$

El patrón de conectividad  $\mathbf{W}$  se modifica en función de la experiencia. En el algoritmo de retropropagación que hemos utilizado en el presente trabajo, se emplea el vector de entrada para producir uno de salida y se lo compara con el de salida deseado ("target"). Si hay diferencia, se modifica  $\mathbf{W}$  tratando de minimizar el error (mayores detalles en 3).

Estimamos la cantidad mínima de variables que se requieren para modelizar la dinámica de la actividad solar a través del cálculo de la dimensión de embedding <sup>4,5</sup>. Con este cálculo comprobamos que las variables necesarias para representar al sistema físico son 12, lo que aproximadamente coincide con la periodicidad más importante de la serie. Finalmente utilizamos 12 unidades de entrada, 3 ocultas y 1 de salida. A las unidades de entrada ingresan secuencias de los valores medios de 12 años consecutivos y la de salida proporciona el valor de la media para el año siguiente.

La evolución del error en presentaciones sucesivas del conjunto de aprendizaje (conjunto de ejemplos con que se entrena la red) es en general decreciente. Sin embargo, la capacidad de generalización (predicción) de la red puede no ser función monótona durante el aprendizaje. Conviene por lo tanto usar un conjunto de comparación (cross-validation)<sup>6</sup>, sobre los que no se entrena a la red y que sirven para hacer un seguimiento de la capacidad predictiva. Elegimos un intervalo de puntos al azar sobre toda la estadística, de manera tal que la variancia fuese grande, es decir, consideramos puntos extremos, alejados de la media. Esta elección permite apreciar el error en una zona crítica, como son los extremos y elegir una configuración de la red que generalice apropiadamente estos puntos.

Para la comparación de nuestros resultados con los de otros trabajos, utilizamos la **variancia relativa media**<sup>7</sup> ARV. Finalmente obtuvimos:  
ARV(conj. de entrenamiento)=0.085      ARV(conj. de comparación)=0.065  
Estos valores se comparan favorablemente con los obtenidos por el método autorregresivo de umbral:

$$\text{ARV}(\text{conj. de entrenamiento})=0.097 \quad \text{ARV}(\text{conj. de comparación})=0.097$$

En el método de McNish-Lincoln<sup>8</sup> se utilizan los valores mensuales de la estadística para predecir la actividad solar. En la figura 3 se observan los promedios anuales de esta predicción. Se puede observar como la predicción de la red supera a la de este método (utilizado por la International Astronomical Union), especialmente cerca del máximo de actividad, a pesar de que el método

de McNish-Lincoln emplea 12 veces más información.




Figura 3: Evolución de la actividad solar.

◆ Mc.Nish-Lincoln      □ Red Neuronal      ● Promedios Anuales

Es de destacar que en el intervalo 1980-1991 obtuvimos una variancia relativa media significativamente menor que la de otros períodos, indicando buena predictibilidad. Por consiguiente, es de suponer que los próximos años (1992-2003) resulten predichos con razonable precisión (figura 3).

Los autores deseamos agradecer al Lic. H. Ghielmetti y a la Dra. M. Rovira por el material suministrado.

## REFERENCIAS

<sup>1</sup>International Astronomical Union, *Quarterly Bulletin on Solar Activity*, (1980-1988).

<sup>2</sup>Solar-Geophysical Data Prompt Reports, Nat. Oceanic and Atmospheric Administration, Number 575 Part I, 26-27 (1992).

<sup>3</sup>Rumelhart D. ; Hinton G.E. y McClelland J.L.: "A general framework for parallel distributed processing", en "Parallel distributed processing: explorations in the microstructure of cognition", 1 (1986).

<sup>4</sup>Schuster G. H.: "Deterministic Chaos: An Introduction", Physik-Verlag (1984).

<sup>5</sup>Henderson H. W. y Wells R, "Obtaining attractor dimensions from meteorological data"; *Adv. Geophys.* 30, 205-238 (1988).

<sup>6</sup>Weigend A.S., Huberman B.A., Rumelhart D.E.; "Predicting the future: A connectionist approach", Presentado a la *International Journal of Neural Systems* (1990).

<sup>7</sup>Calvo R.A.: "Utilización de redes neuronales para la predicción de series temporales. Aplicación al estudio de la actividad solar". Tesis. FCEIA. UN Rosario (1991).

<sup>8</sup>Solar-Geophysical Data, Explanation of Data Reports, National Oceanic and Atmospheric Administration, Number 515 (supplement), 9-10 (1987).