

# Método de predicción a corto-plazo de $f_oF2$ basado en modelado neuroborroso para su aplicación en sistemas de comunicación por satélite de alta precisión

Juan Manuel CÓRDOBA, Diego MARÍN, José Manuel ANDÚJAR

Departamento de Ingeniería Electrónica, Sistemas Informáticos y Automática.  
Universidad de Huelva, España  
juanm.cordoba@diesia.uhu.es ; diego.marin@diesia.uhu.es ; andujar@diesia.uhu.es

Íñigo BLANCO, Benito A. DE LA MORENA

INTA (Instituto Nacional de Técnica Aeroespacial), Estación de Sondeos Atmosféricos "El Arenosillo". Huelva, España  
blancoai@inta.es ; morenacb@inta.es

(Recibido, 12 febrero 2008; recibido en forma revisada, 6 marzo 2008; aceptado, 20 marzo 2008)

## RESUMEN

En los últimos años se está prestando una atención detallada a la influencia que la ionosfera ejerce en la determinación de la posición mediante el uso de sistemas globales de navegación por satélite. En este campo, la predicción a corto-plazo de las condiciones ionosféricas está adquiriendo una gran relevancia. En este trabajo se presenta una metodología para predecir con 1-24 horas de adelanto la frecuencia crítica de la capa F2 de la ionosfera,  $f_oF2$ . El método propuesto está basado en técnicas de inteligencia artificial, concretamente, en modelado neuroborroso. Estas técnicas no han sido muy utilizadas en modelado ionosférico, y su potencialidad y eficacia en este campo están aún por descubrir. La capacidad natural que las técnicas neuroborrosas muestran para modelar sistemas complejos no lineales justifica su aplicación. Los modelos neuroborrosos desarrollados se han aplicado, usando observaciones de  $f_oF2$  de la Estación de Slough, para predecir (1-24 horas de adelanto) bajo condiciones de calma o moderada actividad geomagnética. Los resultados obtenidos muestran una desviación relativa media entre las observaciones reales y las predichas entre el 4 y 10%, lo que es bastante aceptable desde un punto de vista práctico. Una primera evaluación del método para modelar  $f_oF2$  durante periodos de tormentas severas ha mostrado que las predicciones son eficientes únicamente a muy corto plazo (1-3 horas). El objetivo final será comprobar la eficiencia del modelado neuroborroso para predecir con más de 3 horas de adelanto durante periodos perturbados.

**Palabras clave:** ionosfera, predicción a corto-plazo, modelado neuroborroso, frecuencia crítica  $f_oF2$ .

## ABSTRACT

Nowadays, a special attention is being given to the ionosphere influence on the position determination using global navigation satellite system. In this framework, short-term forecasting of ionospheric conditions is gaining a new importance.

This work presents a new methodology to predict with 1-24 hours in advance the ionospheric F2-layer critical frequency,  $f_oF2$ . The proposed method is based on artificial intelligence techniques, specifically, on neuro-fuzzy modelling. Neuro-fuzzy techniques have not been extensively used in ionospheric modelling but its application in this field can be efficient and provide successful results. It is well known by scientific community the natural capability that these techniques show to model highly non-linear and complex systems.

The method has been tested under quiet and moderately geomagnetic conditions using  $f_oF2$  data from Slough ionosonde station, providing  $f_oF2$  forecast (1-24 hours in advance) with relative mean deviation between 4-10%, which is quiet acceptable from practical point of view. A first evaluation of neurofuzzy techniques to model  $f_oF2$  during severe storm periods has revealed good prediction accuracy for only small (less than 3 hours) lead time prediction. The final purpose will be to check the efficiency of neurofuzzy modelling to predict  $f_oF2$  with more than 3 hours in advance during disturbed geomagnetic activity periods.

**Key words:** ionosphere, neurofuzzy modelling, short-term prediction, F2 layer critical frequency  $f_oF2$ .

## 1. INTRODUCCIÓN

La importancia que el conocimiento preciso de la región F2 ionosférica tiene para su aplicación en sistemas de comunicaciones terrestres ha motivado que haya existido un permanente interés en su estudio y modelado. Además, en los últimos años, se está prestando una atención detallada a la influencia que la ionosfera, como medio ionizado, ejerce en los sistemas globales de navegación por satélite (GNSS) (Jakowski *et al.*, 2005; Béniguel y Adam, 2007; Warnant *et al.*, 2007a, b y c). En este sentido, se ha de mencionar que el conocimiento y predicción a corto plazo de la frecuencia crítica de la capa F2 ionosférica,  $f_oF2$ , adquiere una especial importancia. Esta frecuencia puede ser utilizada para calcular perfiles de densidad electrónica y contenido total de electrones que se aplica para estimar el retardo experimentado por las señales emitidas por satélites cuando atraviesan la ionosfera. Este retardo puede producir, por ejemplo, un error en la medida de posicionamiento dada por sistemas de navegación. Además, los perfiles de densidad electrónica determinados a partir de la frecuencia  $f_oF2$  pueden ser utilizados, como condición del estado ionosférico de base, en el cálculo de las irregularidades ionosféricas que dan lugar al centelleo de la señal del satélite que degrada la información necesaria para el posicionamiento. Este problema ha cobrado mayor relevancia en el marco del Proyecto Galileo y esta influencia se está analizando a partir de tres modelos ionosféricos básicos (NeQuick, Costprof y NeUo-plas) desarrollados en la Universidad de Graz y en el Centro Internacional de Física Teórica de Trieste (Hochegger *et al.*, 2000; Radicella y Leitinger, 2001). En este campo, la predicción a corto-plazo de las condiciones ionosféricas cobra una nueva importancia.

Sin embargo, a pesar de este interés mostrado por la comunidad científica, el modelado y predicción de los parámetros que caracterizan la región F2 de la ionosfera continúa siendo en la actualidad un problema desafiante. Los efectos de las tormentas negativas en la capa F2, los cuales son cruciales en las comunicaciones por radio HF, no pueden ser modelados satisfactoriamente. Los modelos teóricos no son apropiados debido a que la concentración de electrones en la región F2 depende de muchas entradas y parámetros incontrolados, por lo que las aproximaciones empíricas deberían ser las recomendadas para uso práctico

(Anderson *et al.*, 1998). El problema radica en que los modelos empíricos de  $f_oF2$  existentes pueden ser aplicados únicamente a períodos de calma geomagnética en los que las condiciones son muy similares a la media mensual. Durante períodos perturbados, la región F2 es muy variable y las variaciones diarias y horarias que tienen lugar son muy grandes. Aunque han sido muchos los métodos desarrollados, desde los basados en la estadística (Muhtarov y Kutiev, 1999; Marín *et al.*, 2000; Muhtarov *et al.*, 2001; Kutiev y Muhtarov, 2003, 2004; Liu *et al.*, 2005; Perrone *et al.*, 2007), a los basados en redes neuronales (Wintoft y Cander, 1999, 2000; McKinnell y Pool, 2000; Tulunay *et al.*, 2001, 2004; Oyeyemi y Pool, 2004; Oyeyemi *et al.*, 2005), y varios los modelos globales y regionales presentados (Bilitza, 2001; Araujo-Pradere *et al.*, 2002; Araujo-Pradere y Fuller-Rowell, 2003; Bilitza, 2003), la fuerte variabilidad del fenómeno y el gran número de procesos que intervienen, hacen que la predicción a corto plazo de  $f_oF2$  siga permaneciendo como un gran reto aún por resolver. Esta problemática se analiza con detalle en Mikhailov *et al.* (2007), donde además se ofrece una revisión actualizada de los distintos tipos de modelos que se han empleado para predecir a corto-plazo este parámetro ionosférico.

En este trabajo se aborda el modelado de la frecuencia crítica  $f_oF2$  desde una nueva metodología basada en técnicas de inteligencia artificial. Concretamente, los autores aplican su experiencia en modelado de sistemas complejos (Andújar *et al.*, 2004; Andújar y Bravo, 2005; Andújar y Barragan, 2005; Andújar *et al.*, 2006a y b), para desarrollar una herramienta capaz de predecir la frecuencia  $f_oF2$  a partir de modelos neuroborrosos. Este tipo de técnicas no han sido utilizadas de forma extensiva en ionosfera pero su aplicación en este campo podría proporcionar excelentes resultados.

Las técnicas neuroborrosas de modelado permiten elaborar un modelo de comportamiento de sistemas complejos y altamente no lineales, donde la información puede ser inexacta o poco concreta, y para los cuales el uso de técnicas clásicas no resulta eficiente. Por una parte, incorporan de los modelos borrosos la facilidad de comprensión y conexión con el sistema físico que pretende modelar, y por otra, la capacidad de adaptación y aprendizaje de los modelos basados en redes neuronales. Sin embargo, mientras que los modelos basados en redes neuronales pueden ser considerados como “caja negra”, los modelos neuroborrosos permiten incorporar el conocimiento de un experto en diferentes partes del proceso de modelado. Además, los modelos neuroborrosos tienen la posibilidad de elaborar el modelo directamente a partir de datos de entrada/salida obtenidos del sistema. Estos aspectos son de particular importancia en el caso de la ionosfera, debido a que hay mucha bibliografía disponible sobre el tema, y un gran volumen de datos de sondeos realizados durante décadas.

El trabajo se divide en las siguientes secciones: *modelos borrosos*, donde se revisan las bases de estos modelos y se explican de forma detallada los fundamentos del modelado neuroborroso; *datos y metodología*, donde se especifica la fuente de los datos usados en este estudio y se aborda la metodología empleada para desarrollar los modelos utilizados; *resultados*, donde se ilustran los principales resultados obtenidos en las predicciones de  $f_oF2$  y, finalmente, *conclusiones y trabajos en curso y referencias*.

## 2. MODELOS BORROSOS

Las técnicas de modelado basadas en lógica borrosa se aplicaron por primera vez a sistemas reales a mediados de los años 70 (Mamdani, 1974; Mamdani y Assilian, 1975). La principal característica de estos modelos borrosos, denominados modelos *Mamdani*, es que permiten introducir de forma directa el conocimiento de un experto por medio de reglas. En el caso de un sistema con una entrada y una salida, estas reglas tienen la siguiente estructura:

$$\text{Si } (x \text{ es } A) \text{ Entonces } (y \text{ es } B) \quad (1)$$

donde  $A$  y  $B$  son conjuntos borrosos. Así, por ejemplo, en el diseño de un sencillo modelo meteorológico, conocimiento del tipo “Si la concentración de nubes es escasa, la probabilidad de lluvia es baja”, puede ser representado directamente con una regla del tipo “Si (*concentracion\_nubes* es *escasa*) Entonces (*probabilidad\_lluvia* es *baja*)”. Las variables *concentracion\_nubes* y *probabilidad\_lluvia* son descritas por medio de conjuntos borrosos que, en este caso, podrían ser por ejemplo *escaso*, *medio*, *alto* o *muy alto*.

Un nuevo enfoque de modelo borroso fue propuesto en Takagi y Sugeno (1985), surgiendo el llamado modelo *Takagi-Sugeno* (*TS*), también conocido como Takagi-Sugeno-Kang (*TSK*) (Nguyen *et al.*, 1995; Yen y Langari, 1999), modelo quasi-lineal o modelo borroso lineal (Babuska, 1995; Babuska y Verbuggen, 1995). El modelo Takagi-Sugeno (en adelante *TSK*) difiere del modelo Mamdani en la forma de las reglas. Estas, para el modelo *TSK*, son del tipo:

$$\text{Si } (x \text{ es } A) \text{ Entonces } (y = f(x)) \quad (2)$$

donde  $f(x)$  puede ser una función no lineal.

Mientras que el modelo Mamdani se caracteriza por su interpretabilidad, el modelo *TSK* se caracteriza por su precisión. Debido a esta precisión, los modelos *TSK* han sido ampliamente utilizados para el modelado de sistemas (Jang *et al.*, 1997; Yen y Langari, 1999; Andújar *et al.*, 2004; Andújar y Bravo, 2005; Andújar y Barragan, 2005; Andújar *et al.*, 2006a y b).

Como se expondrá en la sección siguiente, la tarea fundamental en la obtención de un modelo borroso de un sistema consiste en la identificación de sus parámetros, de modo que al final, el modelo represente de la forma más fiel posible al sistema modelado.

### 2.1. MODELADO NEUROBORROSO

Considérese el sistema definido por:

$$\begin{aligned} y_1 &= f_1(x_1, x_2, \dots, x_n) \\ y_2 &= f_2(x_1, x_2, \dots, x_n) \\ y_m &= f_m(x_1, x_2, \dots, x_n) \end{aligned} \quad (3)$$

o de forma abreviada:

$$y = f(x) \tag{4}$$

Un modelo borroso equivalente al sistema anterior puede ser representado mediante un conjunto de reglas borrosas de la forma dada en (5):

$$R(l): \text{ Si } x_1 \text{ es } A_1^l \text{ y } x_2 \text{ es } A_2^l \dots x_n \text{ es } A_n^l \\ \text{ENTONCES } y_i^l \text{ es } g_i^l(x, \theta_i^l) \tag{5}$$

donde  $l = 1 \dots M$  es el número de reglas del modelo borroso del sistema;  $A_k^l$  el conjunto borroso definido en el universo de discurso de la variable de entrada  $x_k$ ,  $k=1, \dots, n$ , e y la  $i$ -ésima ecuación del proceso ( $i = 1 \dots m$ ).

Si el consecuente de la ecuación (5) es *TSK* con término afín (Takagi y Sugeno, 1985; Sugeno y Kang, 1998), éste puede ser escrito como en (6):

$$g_i^l(x, \theta_i^l) = a_{0i}^l + a_{1i}^l x_1 + \dots + a_{ni}^l x_n \tag{6}$$

donde  $a_{ki}^l$  representa el coeficiente constante para la variable de entrada  $x_k$  correspondiente a la regla  $l$  de la ecuación  $i$ -ésima. El vector  $\theta_i^l$  representa el conjunto de parámetros adaptables:

$$\theta_i^l = (a_{0i}^l, a_{1i}^l, \dots, a_{ni}^l) \tag{7}$$

Considerando un sistema borroso *TSK* con desborrosificador centro-promedio y método de inferencia producto, el sistema borroso equivalente a la expresión (3) puede ser descrito como (Jang *et al.*, 1997):

$$\hat{y}_i = \frac{\sum_{l=1}^M w_i^l g_i^l(x, \theta_i^l)}{\sum_{l=1}^M w_i^l} \tag{8}$$

donde  $\hat{y}_i$  es la salida estimada del sistema, y  $w_i^l$  es el grado de cumplimiento de la regla  $l$ :

$$w_i^l = \prod_{k=1}^n \mu_{F_k}^l(x_k, \sigma_i^l) \tag{9}$$

donde  $\sigma_i^l$  son los parámetros característicos de la función de pertenencia  $\mu_{F_k}^l(x_k, \sigma_i^l)$  que define al conjunto borroso  $A_k^l$ .

Si las funciones dadas en (3) se sustituyen por la ecuación (8), el ajuste adecuado de todos los parámetros de la base de reglas,  $\sigma_i^l$  y  $\theta_i^l$ , permitiría que el sistema borroso resultante represente un modelo equivalente del sistema real.

Con el fin de poder minimizar el error entre la salida del modelo borroso y la salida del sistema definido por la ecuación (3), se puede aplicar el método del gradiente descendente para el ajuste de los parámetros del modelo borroso (Yen y Langari, 1999).

Sea una función de error en la  $p$ -ésima iteración definida como el error cuadrático medio:

$$J(p) = \frac{1}{2} [y(p) - \hat{y}(p)]^2 \tag{10}$$

donde  $y$  representa la salida del sistema que se pretende modelar e  $\hat{y}$  es la salida el modelo borroso que se pretende obtener. El método del gradiente descendente minimiza la función de coste  $J$  ajustando cada parámetro,  $\sigma_i^l$  y  $\theta_i^l$ , con una cantidad proporcional a la derivada de la función con respecto a cada parámetro. Aplicando pues este método, la ley de adaptación de parámetros que define la parte precedente de la base de reglas responde a (Andújar y Bravo, 2005):

$$\sigma_i^l(p + 1) = \sigma_i^l(p) - \eta \frac{\partial J(p)}{\partial \sigma_i^l(p)} \tag{11}$$

De forma similar, el consecuente de la base de reglas se adapta según:

$$\theta_i^l(p + 1) = \theta_i^l(p) - \eta \frac{\partial J(p)}{\partial \theta_i^l(p)} \tag{12}$$

siendo  $\eta$  el factor de aprendizaje, un factor de escala del término derivativo que afecta al tiempo de convergencia del método.

Si usamos funciones de pertenencia Gaussianas en la parte del antecedente de la regla, esto es, si:

$$\mu(x) = \exp\left(\frac{-(x - \gamma)^2}{2\beta^2}\right) \tag{13}$$

se obtienen las siguientes reglas de adaptación para los centros  $\gamma$  de la función Gaussiana (Andújar y Bravo, 2005):

$$\gamma_i^l(p + 1) = \gamma_i^l(p) - 2\eta e(p) \cdot \frac{\prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p))}{\sum_{l=1}^M \left[ \prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p)) \right]} \frac{(x_i(p) - \gamma_i^l(p))}{(\beta_i^l(p))^2} \tag{14}$$

Los anchos  $\beta$ , de la función de pertenencia Gaussiana se ajustarán según:

$$\beta_i^l(p + 1) = \beta_i^l(p) - 2\eta e(p) \cdot \frac{\prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p))}{\sum_{l=1}^M \left[ \prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p)) \right]} \frac{(x_i(p) - \gamma_i^l(p))^2}{(\beta_i^l(p))^3} \quad (15)$$

donde

$$e(p) = y(p) - \hat{y}(p) \quad (16)$$

es la señal de error, y  $\mu_{F_i}^l$  representa la función de pertenencia i-ésima de la regla  $l$ .

Al término afín del consecuente *TSK* le corresponde la regla de adaptación:

$$a_0^l(p + 1) = a_0^l(p) - 2\eta e(p) \cdot \frac{\prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p))}{\sum_{l=1}^M \left[ \prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p)) \right]} \quad (17)$$

El resto de los términos del consecuente *TSK* se adapta según:

$$a_i^l(p + 1) = a_i^l(p) - 2\eta e(p) \cdot \frac{\prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p)) x_i(p)}{\sum_{l=1}^M \left[ \prod_{i=1}^n \mu_{F_i}^l(x_i(p), \sigma_i^l(p)) \right]} \quad (18)$$

El algoritmo 1 implementa la ley de adaptación de parámetros descrita. En él,  $m$  es el número de reglas,  $n$  el número de entradas,  $\gamma$  los centros de las funciones de pertenencia Gaussianas,  $\beta$ , sus anchos,  $e$  el error,  $MSE$  la función de coste (*Medium Square Error*),  $\eta$  el factor de aprendizaje,  $x$  las entradas, y la salida,  $y'$  el consecuente,  $r$  el margen de tolerancia, y  $\varepsilon$  el límite de error.

La adaptación del factor de aprendizaje se realiza en las funciones  $Inc(\eta, r)$  y  $Dec(\eta, r)$  de acuerdo con la expresión:

$$\eta(p + 1) \begin{cases} inc_{-\eta} x \eta(p) & J(p) \leq J(p-1) \\ dec_{-\eta} x \eta(p) & J(p) \geq r x J(p-1) \\ \eta(p) & J(p-1) \leq J(p) < r x J(p-1) \end{cases} \quad (19)$$

La función  $Fx$  implementa el consecuente *TSK* con término afín u otro.

### Algoritmo 1

```

 $\gamma, \beta, y', e = \text{bp}(\eta, m, n, \gamma, \beta, x, y, r, \epsilon)$ 
for each epoch
  for each training point
     $y'(p) = \text{Compute\_Fx}$ 
     $e(p) = y(p) - y'(p)$ 
     $\gamma = \text{Update\_Centres}$ 
     $\beta = \text{Update\_Widths}$ 
     $y' = \text{Update\_Consequents}$ 
  endfor
  error (epoch) = MSE (e)
  if (error (epoch) <  $\epsilon$ ) Or (Stable (error (epoch)))
    return ( $\gamma, \beta, y'$  error)
  endif
  if (error (epoch) < error (epoch-1))
    Inc ( $\eta, r$ )
  endif
  if (error (epoch) > error (epoch-1))
    Dec ( $\eta, r$ )
  endif
endfor
return ( $\gamma, \beta, y', \text{error}$ )
end

```

El método de ajuste de parámetros descrito está basado en uno de los más importantes algoritmos de aprendizaje de las redes neuronales: *Backpropagation (BP)*, de ahí que esta técnica de modelado se denomine neuroborrosa (Yen y Langari, 1999).

## 3. DATOS Y METODOLOGÍA

### 3.1. DATOS

En este estudio se han seleccionado, haciendo uso de la base de datos del *WDC-C1* del *Rutherford Appleton Laboratory* (Chilton, UK), valores horarios de la frecuencia crítica  $foF2$  para la Estación de Slough (UK) (51.5°N , 359.4°E) correspondientes a los periodos de tiempo 1970, 1980-1981 y 1992, todos ellos de alta actividad solar.



Como se explicará a continuación, tener las observaciones divididas en tres periodos es necesario para la construcción de un modelo borroso (Yen y Langari, 1999).

El primero de estos conjuntos temporales es el que recoge los valores comprendidos entre el 1 de marzo de 1980 y el 28 de febrero de 1982, ambos inclusive. Este primer conjunto de valores se supone desconocido con el fin de poder realizar una predicción sobre los mismos con la metodología propuesta y, mediante comparación con los valores reales observados, poder evaluar la eficiencia de los modelos desarrollados. La elección de este periodo para la evaluación del método está motivada por la excelente calidad de los datos que contiene (existen 207 huecos, ausencia de datos, que suponen únicamente un 1.2% del número total de observaciones). A este primer conjunto se le denomina conjunto de test.

El segundo de los conjuntos es el que comprende aquellos datos obtenidos entre el 1 de enero de 1970 y el 21 de febrero de 1971 (10.000 valores) y constituirá el llamado conjunto de entrenamiento. La selección y construcción del conjunto de entrenamiento cumple una función primordial en la metodología propuesta ya que posibilita el ajuste de los parámetros del modelo neuroborroso a través del procedimiento expuesto en 2.1. En general, se puede afirmar que el modelado neuroborroso funcionará correctamente si los datos seleccionados para el ajuste de los parámetros del modelo neuroborroso son representativos de las características del sistema que se pretende modelar. En aplicaciones reales, rara vez es posible seleccionar periodos de entrenamiento que sean representativos de todas las cualidades de un sistema y que recojan aquellas características esenciales de un comportamiento futuro desconocido.

Además, en algunas ocasiones, las condiciones del entorno y/o los instrumentos de medida y registro hacen que los datos recogidos sean inexactos. Por lo tanto, para seleccionar un conjunto de entrenamiento, es necesario llegar a un compromiso entre el número de datos que lo compone, intentando utilizar el mínimo imprescindible, y la calidad de los mismos, procurando que sean lo más representativos posible de las características del sistema.

El tercer conjunto de datos utilizados es el comprendido entre el 1 de enero de 1992 y el 31 de diciembre de 1992. Este último conjunto de datos, al que suele denominarse conjunto de validación (*checking*), tiene la misión de evitar un sobreaprendizaje del conjunto de entrenamiento y así evitar un comportamiento local y especializado. Durante la fase de ajuste de los parámetros del modelo borroso (fase de aprendizaje) se tiene en cuenta tanto el error (diferencia) entre las salidas del modelo borroso y los valores del conjunto de entrenamiento, como también estos mismos errores con respecto al conjunto de validación. Por tanto, el sobreaprendizaje puede ser detectado cuando el error (diferencia entre la salida del modelo neuroborroso y los datos del conjunto de validación) comienza a crecer mientras que el error de entrenamiento sigue decreciendo.

### 3.2. METODOLOGÍA

Una vez expuesto el método de aprendizaje (punto 2.1) y la estructuración de los datos necesaria para la construcción del modelo borroso, a continuación se detalla la metodología utilizada. Consta de las siguientes fases:

1. Selección de las variables de entrada del modelo.
2. Diseño general de los modelos iniciales.
3. Ajuste de los modelos neuroborrosos.

En los sistemas de aprendizaje basados en ejemplos, y más concretamente en el modelado borroso, se hace necesario un estudio previo de los datos de entrenamiento con el fin de determinar el número de entradas necesarias y el tamaño del conjunto de entrenamiento necesario para un correcto desempeño del modelo (Costa y Dente, 2001). Para la aplicación de técnicas neuroborrosas a la predicción de la frecuencia crítica *foF2*, se hace necesaria la elaboración de tantos modelos neuroborrosos como horas diferentes de adelanto queramos tener en la predicción. En este trabajo, se aborda dicha predicción con 1, 2, 3, 6, 12, 18 y 24 horas de adelanto. Las variables de entrada para cada uno de los modelos se han seleccionado teniendo en cuenta los resultados de un estudio previo. Este estudio concluye que se pueden determinar como válidos los conjuntos de entrenamiento y validación expuestos en 3.1 y los modelos:

$$\hat{y}(t+n) = f(y(t), y(t-1), y(t-2), y(t-3), y(t-4)) \quad (20)$$

con  $n=1$  para el modelo para 1 hora de adelanto y  $n=2$  para el modelo de 2 horas de adelanto y

$$\hat{y}(t+n) = f(y(t), y(t-1), y(t-2), y(t+n-24), y(t+n-25)) \quad (21)$$

con  $n=3, 6, 12, 18, 24$  para 3, 6, 12, 18 y 24 horas de adelanto respectivamente, siendo  $\hat{y}(t+n)$  el valor predicho de *foF2* por el modelo neuroborroso con  $n$  horas de adelanto a partir del instante  $t$  e  $y(t-m)$  el valor observado de *foF2* en el instante  $t-m$ .

Una vez seleccionadas las entradas, se realiza el diseño de los modelos determinando el número de funciones de pertenencia necesarias y expresando los modelos obtenidos mediante un conjunto de reglas borrosas como las reflejadas en (5). En este estudio se seleccionan 3 funciones de pertenencia para cada una de las entradas. El último paso de la metodología propuesta consiste en aplicar el algoritmo 1 para el ajuste de los parámetros borrosos de cada uno de los modelos.

#### 4. RESULTADOS

En este trabajo, se determina la fiabilidad de los modelos desarrollados por medio de la desviación relativa media (*DRM*) entre los valores de *foF2* observados y las predicciones que los modelos proporcionan para cada tiempo de adelanto. Esto es,

$$DRM (\%) = \frac{\sum_{i=1}^N \frac{|foF2obs_i - foF2pred_i|}{foF2obs_i}}{N} \times 100 \quad (22)$$

donde  $N$  es el número de muestras y  $foF2_{obs_i}$  y  $foF2_{pred_i}$  son los valores de  $foF2$  observado y predicho para la muestra  $i$ , respectivamente.

Este cálculo se ha realizado para 100 periodos temporales, cada uno de ellos compuesto por tres días consecutivos, comprendidos entre el 1 de marzo de 1980 y el 28 de febrero de 1982 (conjunto de test, ver apartado 3.1.). De los 300 días analizados, el 62.1% de los mismos presentan condiciones de calma (índice  $A_p < 10$ ), y el 37.9% restante condiciones de moderada actividad geomagnética (índice  $A_p$  variando entre 10 y 40).

Los valores  $DRM$  representativos de la precisión de los modelos desarrollados para cada tiempo de adelanto se ofrecen en la tabla 1. Estos valores son el resultado de promediar todas las  $DRM$  obtenidas para cada uno de los 100 periodos de 3 días analizados.


Las mejores predicciones alcanzadas por el método descrito son para 1-3 horas de adelanto, para los que la  $DRM$  es de alrededor del 4-8%. Para tiempos de adelanto mayores, la precisión de la predicción no depende significativamente del tiempo de adelanto, obteniéndose valores de  $DRM$  entre el 9-10%. Estos resultados muestran la eficiencia del sistema de predicción a corto plazo propuesto basado en el modelado neuroborroso de  $foF2$  bajo las condiciones geomagnéticas citadas (condiciones de actividad geomagnética no perturbada).

En la Fig. 1, se representan, a modo de ejemplo, las variaciones de los valores de  $foF2$  observados y predichos con 1, 12 y 24 horas de adelanto para uno de los periodos de calma actividad geomagnética analizado, desde el 1 al 3 de octubre de 1980. Puede apreciarse cómo ambas curvas, observadas y predichas, son muy parecidas, especialmente cuando el tiempo de predicción es de 1 hora.


Un primer análisis realizado para 15 periodos de actividad geomagnética perturbada ( $A_p > 40$ ) ha mostrado que, para tiempos de adelanto de 1-3 horas, la metodología propuesta obtiene precisiones en las predicciones similares a las presentadas para periodos no perturbados. Sin embargo, cuando se predice con tiempos de adelanto superiores, las  $DRM$  aumentan significativamente hasta alcanzar valores que oscilan entre el 20-30%. A pesar de ello, es importante resaltar la gran eficacia del modelo neuroborroso para predecir a muy corto plazo (1-3 horas) incluso bajo condiciones de actividad geomagnética muy perturbadas. Para ilustrar este hecho, en la Fig. 2 se presentan los valores de  $foF2$  observados y predichos con 1 hora de adelanto para tres periodos temporales donde se observaron efectos de fuertes tormentas magnéticas. Como se puede apreciar, la línea de estimaciones sigue con bastante fiabilidad la línea de medidas reales.

**Tabla 1.-** Desviaciones relativas medias en % ( $DRM$ ) de los valores de  $foF2$  observados respecto a los predichos con distintos tiempos de adelanto. Estos valores son el promedio de los valores obtenidos para 100 periodos temporales de calma y moderada actividad geomagnética. La desviación estándar ( $SD$ ) se especifica entre paréntesis.

	Tiempos de adelanto (horas)						
	1	2	3	6	12	18	24
$DRM$	3.92	7.91	8.24	9.11	9.73	9.88	9.92
( $SD$ )	(1.65)	(1.36)	(1.45)	(1.51)	(1.83)	(2.06)	(1.85)



**Figura 1.-** Un ejemplo de las variaciones de  $foF2$  observadas y predichas con 1 hora (panel izquierdo), 12 horas (panel central) y 24 horas de adelanto (panel derecho) para un período de calma geomagnética.



**Figura 2.-** Ejemplos de predicciones a 1 hora para tres periodos de condiciones geomagnéticas muy perturbadas. Se adjunta el índice diario Ap para indicar del nivel de actividad geomagnética. Observar el excelente grado de ajuste entre las observaciones y predicciones.

## 5. CONCLUSIONES Y TRABAJOS EN CURSO

Este trabajo presenta una primera aplicación de las técnicas neuroborrosas al modelado de parámetros ionosféricos. Específicamente, estas técnicas se han aplica-

do a la predicción de la frecuencia crítica de la capa F2,  $f_oF2$ , con 1-24 horas de antelación.

Hasta ahora se ha comprobado la eficiencia del método para predecir a 1-24 horas durante períodos de calma y moderada actividad geomagnética, y a 1-3 horas durante periodos perturbados. Bajo estas circunstancias el método proporciona precisiones en la predicción con desviaciones relativas medias entre el 4-10%, que son valores bastante aceptables desde un punto de vista práctico. Sin embargo, el error cometido en las predicciones aumenta considerablemente para tiempos de adelanto superiores a 3 horas durante episodios de fuertes tormentas magnéticas.

Estos resultados se justifican a partir de la correlación existente entre las observaciones horarias de  $f_oF2$ , con los tiempos característicos que a continuación se mencionan. Se conoce que  $NmF2$  (concentración de electrones máxima en la región F2) presenta una buena correlación entre horas para condiciones normales (no perturbadas). Durante las horas del día el tiempo característico de los cambios de  $NmF2$  debidos a la recombinación es aproximadamente de 1.5 horas, pero durante estas horas la región F2 está fuertemente controlada por la termosfera y el tiempo característico de cambio de sus parámetros representativos (composición neutra, temperatura, vientos) es mucho mayor de 1.5 horas, por lo tanto el intervalo para un aceptable nivel de correlación temporal puede ser entre 3 y 6 horas dependiendo de las condiciones geofísicas. Durante la noche, el tiempo característico con relación a los procesos de pérdidas es superior a 10 horas debido que el coeficiente lineal de pérdida es bajo para esta altura  $hmF2$  (altura de la región F2 para la que la concentración de electrones es máxima), por lo que la correlación entre-horas de  $NmF2$  es muy buena durante las horas nocturnas. Por consiguiente, bajo condiciones “normales”, el método de predicción de  $f_oF2$  debe ser efectivo para predecir con 1-24 horas de antelación con la única ayuda de observaciones previas de  $f_oF2$ , tal y como reflejan los resultados presentados. Sin embargo esta buena correlación entre-horas se rompe durante periodos de tormentas geomagnéticas, y esta es la razón por la que la precisión del método decae bruscamente para tiempos de predicción superiores a 3 horas.

La principal tarea a la que se enfrentan los autores de este trabajo es la de adaptar el modelo neuroborroso desarrollado para predecir periodos perturbados (para tiempos de adelanto entre 3-24 horas). La aplicación de las técnicas neuroborrosas presentadas para abordar esta problemática puede ser considerada como prometedoras; es bien conocida por la comunidad científica la capacidad natural que muestran los sistemas neuroborrosos para modelar sistemas altamente no-lineales y/o que presenten incertidumbre, donde otras técnicas no funcionan correctamente.

El hecho de disponer de una herramienta capaz de predecir de forma eficiente a 1-3 horas bajo diferentes condiciones geofísicas, incluyendo eventos de tormentas severas, es de particular importancia. Este conocimiento permitirá, junto con las predicciones ya existentes a 3 días del índice  $A_p$  (disponibles en <http://www.sel.noaa.gov/forecast.html>), saber si se ha de predecir bajo condiciones perturbadas o no. Por ejemplo, si el valor predicho ‘fiable’ a 1-3 horas se aparta significativamente del valor de la mediana horaria mensual prevista y el índice  $A_p$  es elevado para el día que se pretende predecir, la metodología expuesta se adaptará para funcionar bajo condiciones de actividad geomagnética perturbada. Esta versión

especial del método está siendo desarrollada en la actualidad. Se basa en la construcción de un modelo borroso específico, entrenado fundamentalmente con días en los que se aprecien los efectos de tormentas magnéticas en el comportamiento de  $f_oF_2$ . Dado que la bondad del modelo neuroborroso obtenido depende directamente de la calidad de los datos del conjunto de entrenamiento, la utilización de un único conjunto de entrenamiento, para el que además el número de días no perturbados es muy superior a los perturbados, hace que el modelo desarrollado sea un modelo general que no refleje el comportamiento perturbado que se pretende detectar. Por otra parte, una inclusión en los modelos de entradas que reflejen el nivel de actividad geomagnética a través de índices como  $A_p$  o  $K_p$  también puede mejorar las predicciones desde un punto de vista estadístico.

## REFERENCIAS

- ANDERSON, D.N., M.J., BUONSANTO, M. CODRESCU, D. DECKER, C.G. FESEN, T.J. FULLER-ROWELL, B.W. REINISCH, R. ROBLE, W. SCHUNK & J.J. SOJKA (1998). Intercomparison of physical models and observations of the ionosphere. *J. Geophys. Res.*, 103, 2179-2192.
- ANDÚJAR, J.M. & A.J. BARRAGAN (2005). A methodology to design stable non-linear Fuzzy control systems” *Fuzzy Sets and Systems* 154(2), 157-181.
- ANDÚJAR, J.M. & J.M. BRAVO (2005). Multivariable Fuzzy control applied to the physical-chemical treatment facility of a cellulose factory. *Fuzzy Sets and Systems* 150(3), 475-492.
- ANDÚJAR, J.M., J.M. BRAVO & A. PEREGRIN (2004). Stability analysis and synthesis of multivariable fuzzy systems using interval arithmetic. *Fuzzy Sets and Systems* 148(3), 337-353.
- ANDÚJAR, J.M., A.J. BARRAGAN, J.M. CORDOBA & I. FERNANDEZ DE VIANA (2006a). Diseño de sistemas de control borroso: modelado de la planta. *Revista Iberoamericana de Automática e Informática Industrial (RIAI)*, 3(1), 75-81.
- ANDÚJAR, J.M., J. AROBA, M.L. DE LA TORRE & J.A. GRANDE (2006b). Contrast of evolution models for agricultural contaminants in ground waters by means of fuzzy logic and data mining. *Environmental Geology*, 49(3), 458-466.
- ARAUJO-PRADERE, E.A. & T.J. FULLER-ROWELL (2003). Validation of the STORM response in IRI2000, *J. Geophys. Res.*, 108, A3, 1120.
- ARAUJO-PRADERE, E.A., T.J. FULLER-ROWELL & M.V. CODRESCU (2002). Storm: an empirical store-time ionospheric correction model 1. Model description. *Radio Sci.*, 37(5), 1070.
- BABUSKA, R. (1995). Fuzzy modelling and control engineering perspective”, *Proc. FUZZ-IEEE/IFES'95, Yokohama, Japan*, 1897-1902.
- BABUSKA, R. & H.B. VERBUGGEN (1995). A new identification method for linguistic fuzzy models, *Proc. FUZZ-IEEE/IFES'95 Yokohama, Japan*, 905-912.
- BÉNIGUEL, Y. & J.P. ADAM (2007). Effects of Scintillations in GNSS. In J. Liliensten (ed.). *Space Weather. Research Towards Applications in Europe*, pp. 203-216. Astrophysics and Space Science Library, 344, Springer Netherlands.

- BILITZA, D. (2001). International reference ionosphere 2000, *Radio Sci.*, 36(2), 261-275.
- BILITZA, D. (2003). International reference ionosphere 2002: examples of improvements and new features. *Adv. Space Res.*, 31(3), 757-767.
- COSTA, P.J. & J.A. DENTE (2001). Fuzzy systems modelling in practice. *Fuzzy Sets and Systems*, 121, 73-93.
- HOCHEGGER, G., B. NAVA, S.M. RADICELLA & R. LEITINGER (2000). A family of ionospheric models for different uses, *Phys.Chem. Earth (C)*, 25, 307-310.
- JAKOWSKI, N., S. M. STANKOV & D. KLAEHN (2005). Operational space weather service for GNSS precise positioning. *Ann. Geophys.*, 23, 3071-3079.
- JANG, J.S., C.T. SUN & E. MIZUTANI (1997). *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*, Prentice-Hall.
- KUTIEV, I. & P. MUHTAROV (2003). Empirical modelling of global foF2 ionospheric response to geomagnetic activity. *J. Geophys. Res.* 108(A1), 1021.
- KUTIEV, I. & P. MUHTAROV (2004). Modeling the storm-time deviations of foF2 on a global scale. *Adv. Space Res.*, 33, 910-916.
- LIU, R., Z. XU, J. WU, S. LIU, B. ZHANG & G. WANG (2005). Preliminary studies on ionospheric forecasting in China and its surrounding area. *J. Atmos. Solar-Terr. Phys.*, 67, 1129-1136.
- MAMDANI, E. (1974). Applications to fuzzy algorithms for simple dynamic plant. *Proceedings IEEE*, 21, 1585-1588.
- MAMDANI, E. & S. ASSILIAN (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7, 1-13.
- MARÍN D., G. MIRO & A. MIKHAILOV (2000). A method for foF2 short-term prediction, *Phys. Chem. Earth (C)*, 25(4), 327-332.
- McKINNELL, L.A.. & A.W.V. POOL (2000). The development of a neural network based short term foF2 forecast program. *Phys. Chem. Earth (C)*, 25(4), 287-290.
- MIKHAILOV, A.V., V.H. DEPUEV & A.H. DEPUEVA (2007). Short-Term foF2 Forecast: Present Day State of Art. In J. Lilensten (ed.). *Space Weather. Research Towards Applications in Europe*, pp. 169-184. Astrophysics and Space Science Library, 344, Springer Netherlands.
- MUHTAROV, G. & I. KUTIEV (1999). Autocorrelation method for temporal interpolation and short term prediction of ionospheric data. *Radio Science* 34 (2), 459-464.
- MUHTAROV, P., I. KUTIEV, Lj. R. CANDER, B. ZOLESI, G. DE FRANCESCHI, M. LEVY & M.DICK (2001). European ionospheric forecast and mapping. *Phys. Chem. Earth (C)*, 26(5), 347-351.
- NGUYEN, T.H., M. SUGENO, R. TONG & R.R. ANDAGER (1995). *Theoretical aspects of Fuzzy control*, John Willey Sons.
- OYEYEMI, E.O. & A.W.V. POOL (2004). Towards the development of a new global foF2 empirical model using neural networks. *Adv. Space Res.*, 34, 1966-1972.
- OYEYEMI, E.O., A.W.V. POOL & L.A. McKINNELL (2005). On the global model for foF2 using neural networks. *Radio Sci.* 40.
- PERRONE L, M. PIETRELLA & B. ZOLESI (2007). A prediction model of foF2 over periods of severe geomagnetic activity. *Adv. Space Res.*, 39, 674-680.

- RADICELLA, S.M. & R. LETINGER (2001). The evolution of the DGR approach to model electron density profiles, *Adv. Space. Res.* 27, 35-40.
- SUGENO, M. & G.T. KANG (1998). Structure identification of Fuzzy model, *Fuzzy Sets and Systems*, 28, 15-33.
- TAKAGI, T. & M. SUGENO (1985). Fuzzy identification of systems and its applications to modelling and control, *IEEE Transactions on Systems, Man, and Cybernetics*, 15, 116-132.
- TULUNAY, Y.K., E. TULUNAY & E.T. SENALP (2001). An attempt to model the influence of the trough on HF communication by using neural networks. *Radio Sci.*, 36(5), 1027-1041.
- TULUNAY, Y., E., TULUNAY & E.T. SENALP (2004). The neural network technique: an ionospheric example illustrating its application. *Adv. Space Res.*, 33, 988-992.
- WARNANT, R., S. LEJEUNE & M. BAVIER (2007a). Space weather influence on satellite-based navigation and precise positioning. In J. Liliensten (ed.). *Space Weather. Research Towards Applications in Europe*, pp. 129-146. Astrophysics and Space Science Library, 344, Springer Netherlands.
- WARNANT, R., I. KUTIEV, P. MARINOV, M. BAVIER & S. LEJEUNE (2007b). Ionospheric and geomagnetic conditions during periods of degraded GPS position accuracy: 1. Monitoring variability in TEC which degrades the accuracy of Real-Time kinematic GPS applications. *Adv. Space Res.*, 39, 875-880.
- WARNANT, R., I. KUTIEV, P. MARINOV, M. BAVIER & S. LEJEUNE (2007c). Ionospheric and geomagnetic conditions during periods of degraded GPS position accuracy: 2. RTK events during disturbed and quiet geomagnetic conditions. *Adv. Space Res.*, 39, 881-888.
- WINTOFT, P. & Lj.R. CANDER (1999). Short-term prediction of foF2 using time-delay Neural Network. *Phys. Chem. Earth (C)*, 24(4), 343-347.
- WINTOFT, P. & Lj.R. CANDER (2000). Ionospheric foF2 storm forecasting using neural networks. *Phys. Chem. Earth (C)*, 25(4), 267-273.
- YEN, J. & R. LANGARI (1999). *Fuzzy logic: intelligence control, and information*, Prentice-Hall.