

19



OFICINA ESPAÑOLA DE  
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 539 407**

21 Número de solicitud: 201301205

51 Int. Cl.:

**G06F 17/18** (2006.01)

**G06F 17/10** (2006.01)

12

PATENTE DE INVENCION CON EXAMEN PREVIO

B2

22 Fecha de presentación:

**27.12.2013**

43 Fecha de publicación de la solicitud:

**30.06.2015**

88 Fecha de publicación diferida del informe sobre el estado de la técnica:

**23.07.2015**

Fecha de la concesión:

**09.05.2016**

45 Fecha de publicación de la concesión:

**17.05.2016**

73 Titular/es:

**LÓPEZ LINEROS , Miriam (100.0%)  
C/ Benacazón 17  
41928 Palomares del Río (Sevilla) ES**

72 Inventor/es:

**LÓPEZ LINEROS , Miriam ;  
ESTÉVEZ GUALDA, Javier;  
GIRÁLDEZ CERVERA, Juan Vicente;  
MADUEÑO LUNA , Antonio ;  
RUANO, Antonio Eduardo De Barros y  
FERREIRA, Pedro Miguel Frazao Fernandes**

54 Título: **Procedimiento para la validación, detección de errores y corrección de los datos procedentes de sensores de nivel en ríos**

57 Resumen:

Procedimiento para la validación, detección de errores y corrección de los datos procedentes de sensores de nivel en ríos.

La presente invención tiene por objeto un procedimiento para la validación, la detección de errores y la corrección de los datos proporcionados por los sensores de nivel de los ríos monitorizados en las cuencas hidrográficas. El procedimiento que se describe y que consta de 4 etapas (re/entrenamiento, selección de mejor dato disponible, incremento de la base de datos y presentación de datos), se ha concebido para ser implementado en un dispositivo hardware del tipo P.C., FPGA o microprocesador como un proceso recurrente, desarrollado en torno a una red neurona no lineal autoregresiva (NNAR), que es reentrenada a cada entrada de datos procedentes de los sensores, tomando para ello la base de datos validados que se está generando. El procedimiento incluye además una doble corrección, la primera considerando la naturaleza discreta de los datos que proporcionan los sensores y la segunda una corrección no causal de los mismos.

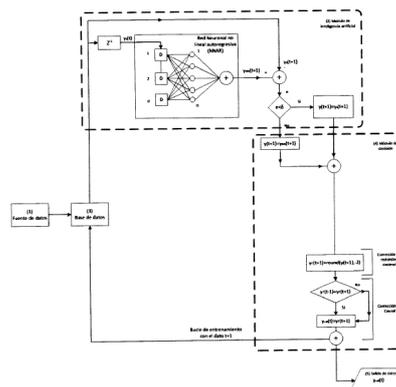


Figura 2

ES 2 539 407 B2

## DESCRIPCIÓN

Procedimiento para la validación, detección de errores y corrección de los datos procedentes de sensores de nivel en ríos.

**5 Objeto de la invención**

La presente invención tiene por objeto un procedimiento para la validación, la detección de errores y la corrección de los datos proporcionados por los sensores de nivel de los ríos monitorizados en las cuencas hidrográficas. El procedimiento que se describe y que consta de 4 etapas (re/entrenamiento, selección de mejor  
10 dato disponible, incremento de la base de datos y presentación de datos), se ha concebido para ser implementado en un dispositivo hardware del tipo P.C., FPGA o microprocesador como un proceso recurrente, desarrollado en torno a una red neuronal no lineal auto-regresiva (NNAR), que es reentrenada a cada entrada de  
15 datos procedentes de los sensores, tomando para ello la base de datos validados que se está generando. Esta técnica mejora sensiblemente los resultados obtenidos por técnicas convencionales llegando a niveles de detección de fallos superior al 90%. En el mejor de los casos, los métodos de validación convencionales son capaces de detectar un 13% de errores. Este procedimiento que como efecto técnico da solución muy eficiente al problema de la calidad e  
20 integridad de las series temporales de datos de nivel de ríos, es implementable en los equipos informáticos de los Sistemas Automáticos de Información hidrológica (SAIH) de las cuencas hidrográficas.

**Estado de la técnica**

25 La validación de datos hidro-meteorológicos consiste en una serie de procedimientos que aseguran la calidad de la información generada, identificando valores incorrectos y detectando problemas que requieren tareas de mantenimiento (Estévez et al., 2011). La Organización Meteorológica Mundial presentó recientemente las características básicas y los principios generales para  
30 el control de calidad de datos meteorológicos (WMO, 2010). Estos procedimientos están basados en las comprobaciones que se aplican a cada registro: tests de rango (comprueba que el dato esté dentro de unos límites establecidos: físicos o instrumentales), de salto temporal (comprueba el exceso de  
35 variabilidad en un tiempo determinado), de persistencia temporal (la escasa o nula variabilidad) y de consistencia espacial (analiza la coherencia del parámetro con localizaciones cercanas). Se trata de contrastar si existe algún tipo de

incongruencia meteorológica que pueda ser detectada mediante estos métodos. El test de rango y los tests de consistencia temporal utilizan datos de una misma localización (Wade, 1987; Meek and Hatfield, 1994; Eischeid et al., 1995; You et al., 2007). Los tests de coherencia espacial emplean datos de estaciones vecinas  
 5 frente a los cuales se comparan los datos de la estación a validar (Gandin, 1988; Reek et al., 1992; Eischeid et al., 2000; Feng et al., 2004; You and Hubbard, 2006).

Hubbard et al. (2005) aplicaron los fundamentos de estos mismos métodos pero basados en decisiones estadísticas, empleando umbrales mensuales para los  
 10 diferentes tests y estableciendo diferentes intervalos de confianza.

Existen en la literatura procedimientos específicos para variables meteorológicas concretas, como la radiación solar (Allen, 1996; Geiger et al., 2002), velocidad de viento (Graybeal, 2005) o precipitación (You et al., 2007), basados bien en distribución de frecuencias o en alguno de los principios comentados  
 15 anteriormente (rango, salto, etc.).

En cambio, no existe en la literatura científica ningún procedimiento de control de calidad específico para la validación de datos procedentes de sensores de niveles en ríos, si bien la aplicación de los procedimientos convencionales en variables meteorológicas adaptados a esta variable puede resultar adecuada. Al mismo  
 20 tiempo, los diferentes modelos hidrológicos que utilizan estos datos y que se aplican a diferentes escalas espacio-temporales precisan cada vez más de unos datos de calidad para obtener resultados fiables y con garantías.

### **Bibliografía**

- 25 Allen, R.G., 1996. Assessing integrity of weather data for reference evapotranspiration estimation. *Journal of Irrigation and Drainage Engineering ASCE* 122, 97–106.
- Eischeid JK, Baker CB, Karl T, Diaz HF. 1995. The quality control of long-term climatological data using objective data analysis. *J. Appl. Meteorol.* 34: 2787–2795.
- 30 Eischeid JK, Pasteris PA, Diaz HF, Plantico MS, Lott NJ. 2000. Creating a serially complete, national daily time series of temperatura and precipitation for the western United States. *J. Appl. Meteorol.* 39: 1580–1591.
- Estévez, J., Gavilán, P., Giráldez, J.V. 2011. Guidelines on validation procedures for meteorological data from automatic weather stations. *J. Hydrol.* 402, 144-154.
- 35 Feng, S., Hu, Q., Wang, W., 2004. Quality control of daily meteorological data in China 1951–2000: a new dataset. *Int. J. Climatol.* 24: 853–870.

- Gandin LS. 1988. Complex quality control of meteorological observations. *Mon. Weather Rev.* 116: 1137–1156.
- Geiger, M.L., Diabate, L.M., Wlad, L., 2002. A web service for controlling the quality of measurements of global solar irradiation. *Solar Energy* 73, 475–480.
- 5 Graybeal, D.Y., 2005. Relationships among daily mean and maximum wind speeds with application to data quality assurance. *International Journal of Climatology* 26, 29–43.
- Hubbard, K.G., Goddard S, Sorensen WD, Wells N, Osugi TT. 2005. Performance of quality assurance procedures for an Applied Climate Information System. *J.*
- 10 *Atmos. Oceanic Technol.* 22: 105–112.
- Meek, D.W., Hatfield, J.L. 1994. Data quality checking for single station meteorological databases. *Agric. For. Meteorol.* 69: 85–109.
- Reek T, Doty SR, Owen TW. 1992. A deterministic approach to the validation of historical daily temperature and precipitation data from the Cooperative Network.
- 15 *Bull. Am. Meteorol. Soc.* 73: 753–765.
- Wade, C.G., 1987. A quality control program for surface mesometeorological data. *J. Atmos. Oceanic Technol.* 4: 435–453.
- WMO. 2010. *Manual on the Global Observing System, GlobalAspects, Vol. 1, WMO (Series), Vol. 544*, 2010 edn. World Meteorological Organization: Geneva,
- 20 Switzerland.
- You, J., Hubbard, K.G., 2006. Quality control of weather data during extreme events. *J. Atmos. Oceanic Technol.* 23: 184–197.
- You J, Hubbard KG, Nadarajah S, Kunkel KE. 2007. Performance of quality assurance procedures on daily precipitation. *J. Atmos. Oceanic Technol.* 24: 821-
- 25 834.

### **Descripción de las figuras**

La Figura 1 muestra en bloques los elementos que se requieren para la aplicación de este procedimiento: (1) es la fuente de datos, constituida por el/los sensor/es

30 de nivel del río/ríos de la cuenca. (2) es el módulo de inteligencia artificial que a partir de datos validados es capaz de abstraer el comportamiento del río y su probable evolución en un futuro cercano. (3) es la base de datos constituida por una serie inicial validada, y por aquellos otros obtenidos a partir de la decisión

35 experta del procedimiento de validación entre aquellos procedentes directamente del sensor/es o de la salida del módulo de inteligencia artificial. Con la llegada de

un nuevo dato, el módulo de inteligencia artificial reconfigura su comportamiento. (4) es el módulo de decisión cuya salida alimenta la interfaz de salida de datos del sistema (5) y sirve de realimentación para incrementar la base de datos.

La Figura 2 muestra en detalle el modo preferente de realización de la invención  
5 para el caso del análisis de los datos procedentes de un solo sensor de nivel.

### **Descripción de la invención**

El procedimiento objeto de esta invención, se basa en emplear un conjunto hardware/software capaz de validar los datos procedentes de los sensores de  
10 nivel instalados en ríos, detectar de manera eficiente la presencia de datos erróneos en series de datos de nivel de ríos y proponer una corrección aceptable de forma que el dato artificial generado se aproxime con gran probabilidad al dato real que debería haberse obtenido. Las técnicas convencionales si bien trabajan adecuadamente para otros parámetros hidro-climáticos, y es posible su  
15 adaptación para niveles en ríos, no dejan de ser una aproximación para resolver este caso concreto. El procedimiento que se propone surge de un análisis pormenorizado de los datos reales de los niveles de ríos a través de la experiencia de expertos que se encargan de realizar esta tarea. El procedimiento que se va a describir es una abstracción de ese proceder manual. Como se ha mostrado en la  
20 Figura 1, consta de un primer módulo con inteligencia artificial que ha sido entrenado para conocer la naturaleza del sistema en estudio, en este caso analizar los datos de los sensores de nivel de ríos, y un segundo módulo capaz de tomar una decisión sobre los datos proporcionados por el sensor y por el módulo de inteligencia artificial, de manera que se realiza una estimación de alta calidad del dato más probable de la serie de niveles. Los nuevos datos validados son  
25 incorporados en la base de datos que sirve para reentrenar el módulo inteligente de forma que el proceso global se toma cíclico y es fácilmente adaptable a un algoritmo recurrente asegurando con ello el mejor desempeño posible.

### **30 Modo preferente de realización de la invención**

Esta descripción (figura 2), se corresponde a un mero ejemplo de realización práctica que no limita en absoluto la invención. Consta de 4 etapas:

- 1.- Etapa de entrenamiento de la red neuronal no lineal autoregresiva (NNAR).
- 2.-Selección del dato más probable de la serie de niveles.
- 35 3.-Adición del nuevo dato a la base de datos.

4.-Salida de datos del sistema e inicio nuevamente de la etapa 1 con la base de datos incrementada en un dato.

La fuente de datos (3) es un sensor de nivel con codificación binaria BCD que envía datos con cadencia diez-minutal a una estación remota que provee a los datos de un sistema de corrección de errores (CRC) antes de enviarlos por satélite al centro de procesado de la cuenca (CPC). El módulo de inteligencia artificial (2), se constituye por un PC, clúster de P.C.'s o FPGA's ya que el proceso de reentrenamiento de la red neuronal es computacionalmente muy intensivo y se ha de realizar como mucho en diez minutos que es el intervalo de tiempo entre cada dos datos consecutivos. El software que se ejecuta consiste en un algoritmo recursivo desarrollado en Matlab 2013 y que implementa una red neuronal no lineal autoregresiva (NNAR) cuyo tamaño y datos tipo delay  $[y(t-1), y(t-2), \dots, y(t-k)]$ , han sido seleccionados previamente a partir del estudio de los datos del punto de medida empleando para ello técnicas meta-heurísticas de optimización (por ejemplo algoritmos genéticos).

El re/entrenamiento de la NNAR se lleva a cabo en 3 etapas haciendo uso de la base de datos seleccionados aleatoriamente:

1. Entrenamiento propiamente dicho con el 75% de los datos: Modificamos pesos y bias de la NNAR con lo que esta aprende la naturaleza del sistema en estudio. De forma práctica este objetivo se alcanza minimizando el error medio cuadrático usando por ejemplo el algoritmo de Levenberg-Marquardt.
2. Validación con el 15% de los datos: Se selecciona el modelo NNAR que presenta mayor nivel de generalización.
3. Test con el 15% restante: Verificamos el correcto funcionamiento de la NNAR ante datos desconocidos.

Las fases 2 y 3 dan la robustez al sistema, siendo los porcentajes de 75%, 15% y 15% meros ejemplos.

El módulo de decisión (4), es una unidad constituida por hardware tipo P.C. o FPGA y compara los datos originales recibidos por el sensor y los estimados por la red neuronal, seleccionando uno de ellos que será incorporado a la base de datos validada (3), de esta manera la red neuronal dispone de una nueva muestra de datos  $(t+1)$ , siendo  $t$  la variable temporal usada por el sistema, para ser reentrenada adaptándose de esta forma y de manera continua a la naturaleza de los datos.

La selección del mejor dato disponible, se determina a partir de la máxima discrepancia admitida (umbral óptimo de selección)  $\delta$  entre el dato procedente del sensor y el estimado por la red neuronal de acuerdo al siguiente criterio:

$$\begin{cases} y(t+1) = y_s(t+1) & y_{NN}(t+1) - y_s(t+1) < \delta \\ y(t+1) = y_{NN}(t+1) & y_{NN}(t+1) - y_s(t+1) \geq \delta \end{cases}$$

5 Siendo:

t: variable temporal usada por el sistema

y: dato seleccionado

$y_s$ : dato de la serie a validar

$y_{NN}$ : predicción de la red neuronal

10  $\delta$ : umbral óptimo de selección

Quedando  $\delta$  fijada a partir del análisis del funcionamiento del algoritmo recurrente con diferentes valores de este parámetro, sobre la muestra de datos procedente de la serie real a analizar que ha sido previamente validada por un experto y a la que se le han añadido errores de valor conocido.

15

A título de ejemplo empleando datos de dos decimales del punto de medida "Villoldo" de la cuenca del Duero y una NNAR con:

$n=5$  (número de neuronas en la capa oculta)

$d=10$  [delay  $\rightarrow y(t-1), y(t-2), \dots, y(t-10)$ ]

20 La máxima discrepancia admitida (umbral óptimo de selección)  $\delta$  está en torno a 0.02.

Es de destacar que este método de incorporación de nuevos datos a la base de datos puede incluir datos que son incorrectos. Para valores de  $\delta$  tanto menores como mayores al umbral (0.02 en el ejemplo), la NNAR se reentrena con un número alto de datos no válidos con lo que su capacidad estimadora se ve mermada si bien su comportamiento es robusto ante esos fallos a diferencia de otras técnicas como los interpoladores basados en splines cúbicos o en funciones de base radial.

25

30 Este módulo emplea dos técnicas adicionales de corrección una vez obtenido el dato seleccionado, una basada en la naturaleza discreta de los datos procedentes del sensor:

$$y_r(t+1) = \text{round}[y(t + 1), -2]$$

Siendo:

$y_r$ : dato seleccionado redondeado (round), según la resolución de los datos de la serie a validar, (en la expresión anterior, y a título de ejemplo, 2 decimales).

- 5 Y una segunda basada en la no causalidad de los datos analizados para generar los datos que alimentan a la interfaz de salida de datos del sistema (5):

$$\text{si } y_r(t-1) = y_r(t + 1) \text{ entonces } y_r(t) = y_r(t - 1)$$

$$y_{val}(t) = y_r(t + 1)$$

Siendo:

- 10  $y_{val}$ : dato de salida de datos del sistema y de realimentación a la base de datos

El funcionamiento para n sensores es similar, en este caso la NNAR incorpora tantas entradas como número de sensores y la base de datos un registro para cada entrada. El proceso a seguir es idéntico al descrito para un solo sensor.

15

El proceso por el que se incrementa la base de datos puede hacer que el número de registros existentes ya sea incompatible con un proceso computacional en un tiempo inferior a la cadencia de llegada de los datos procedentes del sensor/es, en este caso es posible hacer uso de una parte de la base de datos para llegar a un

20 compromiso entre precisión y velocidad de ejecución.

## REIVINDICACIONES

1. Procedimiento para la validación, detección de errores y corrección de los datos procedentes de sensores de nivel en ríos caracterizado por:

- 5           1. Emplear una red neuronal no lineal autoregresiva (NNAR) de n entradas (una para cada sensor), caracterizada por determinar su topología mediante técnicas meta-heurísticas de optimización (por ejemplo algoritmos genéticos), a partir de los datos registrados del nivel de los ríos.
- 10           2. Emplear un proceso recursivo/iterativo de 4 etapas: (i) entrenamiento con el 75% de los datos y un retrenamiento, (ii) selección de mejor dato disponible, (iii) incremento de la base de datos y presentación de datos, que reentrena la red neuronal no lineal autoregresiva NNAR con la llegada de cada dato procedente del sensor/es de nivel.
- 15           3. Emplear un proceso de selección del mejor dato disponible de acuerdo a la etapa 2 del procedimiento selección del mejor dato disponible, según el siguiente criterio:

$$\begin{cases} y(t+1) = y_s(t+1) & y_{NN}(t+1) - y_s(t+1) < \delta \\ y(t+1) = y_{NN}(t+1) & y_{NN}(t+1) - y_s(t+1) \geq \delta \end{cases}$$

Siendo:

t: variable temporal usada por el sistema

20    y: dato seleccionado

$y_s$ : dato de la serie a validar

$y_{NN}$ : predicción de la red neuronal

$\delta$ : umbral óptimo de selección

25           Según este criterio el dato seleccionado puede ser procedente del propio sensor/es de nivel o de la predicción de la red neuronal, de forma que el nuevo dato formará parte de la base de datos (n registros, uno para cada sensor) Base de datos que, parcialmente puede ser errónea y, con la que la red será nuevamente entrenada, ya sea empleándola al completo o sólo una parte de la misma.

30

4. Emplear dos técnicas adicionales de corrección, una basada en la naturaleza discreta de los datos procedentes del sensor y, otra basada en la no causalidad de los datos analizados:

Técnica basada en la naturaleza discreta de los datos procedentes del sensor:

$$y_r(t+1) = \text{round}[y(t+1), -2]$$

5

Siendo:

$y_r$ : dato seleccionado redondeado (round), según la resolución de los datos de la serie a validar, (en la expresión anterior, y a título de ejemplo, 2 decimales).

10

Y una segunda basada en la no causalidad de los datos analizados para generar los datos que alimentan a la interfaz de salida de datos del sistema (5):

$$\text{si } y_r(t-1) = y_r(t+1) \text{ entonces } y_r(t) = y_r(t-1)$$

$$y_{val}(t) = y_r(t+1)$$

Siendo:

15

$y_{val}$ : dato de salida de datos del sistema y de realimentación a la base de datos

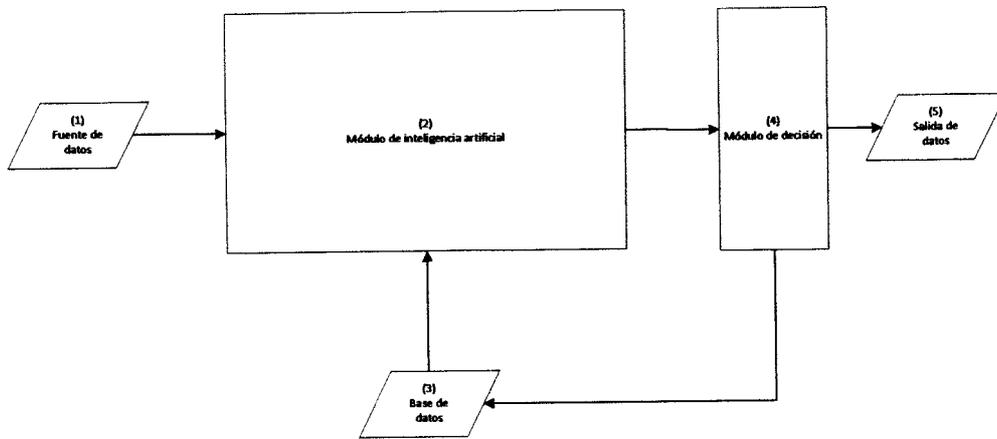


Figura 1

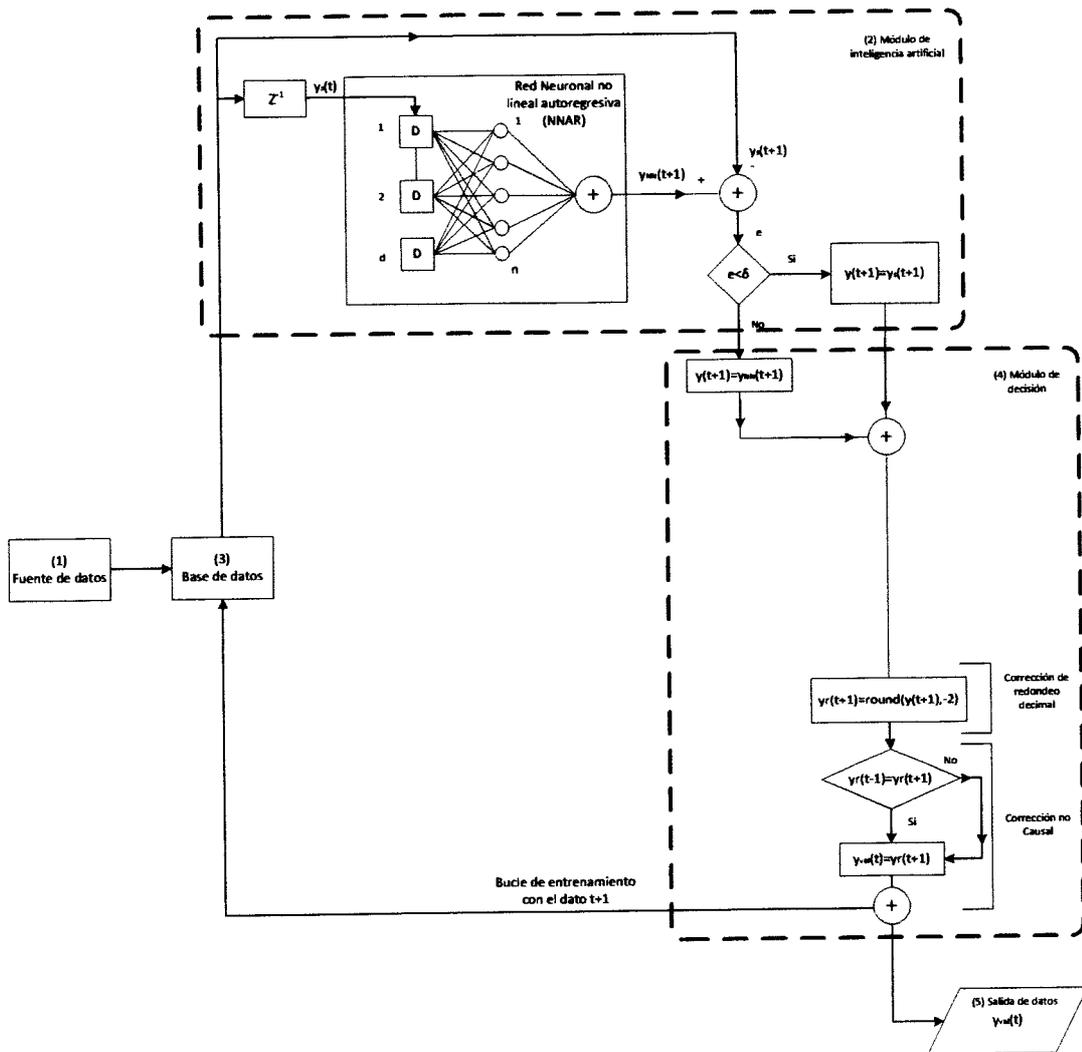


Figura 2



- ②1 N.º solicitud: 201301205  
②2 Fecha de presentación de la solicitud: 27.12.2013  
③2 Fecha de prioridad:

INFORME SOBRE EL ESTADO DE LA TECNICA

⑤1 Int. Cl.: **G06F17/18** (2006.01)  
**G06F17/10** (2006.01)

DOCUMENTOS RELEVANTES

Categoría	⑤6 Documentos citados	Reivindicaciones afectadas
A	CHATTOPADHYAY S et al. Univariate modelling of summer-monsoon rainfall time series: Comparison between ARIMA and ARNN.COMPTES RENDUS - GEOSCIENCE, 20100201 ELSEVIER, PARIS, FR 01.02.2010 VOL: 342 No: 2 Págs: 100-107 ISSN 1631-0713 McKey Doyle; Lézine Anne-Marie. Todo el documento.	1
A	CHATTOPADHYAY G et al. Autoregressive forecast of monthly total ozone concentration: A neurocomputing approach.COMPUTERS AND GEOSCIENCES, 20090901 PERGAMON PRESS, OXFORD, GB 01.09.2009 VOL: 35 No: 9 Págs: 1925-1932 ISSN 0098-3004 Doi: doi:10.1016/j.cageo.2008.11.007 Chen Yan. Todo el documento.	1
A	SHAMSELDIN A Y et al. Neural network river discharge forecasters: an empirical investigation of hidden unit processing functions based on two different catchments.Neural Networks, 2005. Proceedings. 2005 IEEE International Joint Conference on Montreal, Que., Canada 31 Julio-4 Ago. 2005, 20050731 Piscataway, NJ, USA,IEEE, US 31.07.2005 VOL: Págs: 2655-2660 vol. 4 ISBN 978-0-7803-9048-5; ISBN 0-7803-9048-2 Anonymous. Todo el documento.	1
A	KASINATHAN M et al. An Artificial Neural Network approach for the discordance sensor data validation for SCRAM parameters.2009 1st International Conference on Advancements in Nuclear Instrumentation, Measurement Methods and Their Applications: ANIMMA 2009; Marseille, France, 7 - 10 Junio 2009, 20090607 IEEE, Piscataway, NJ 07.06.2009 VOL: Págs: 1-5 ISBN 978-1-4244-5207-1; ISBN 1-4244-5207-4. Todo el documento.	1
A	US 2009113332 A1 (FARAHMAND TOURAJ et al.) 30.04.2009, todo el documento.	1
A	US 2003097230 A1 (GARABEDIAN ARMINCH) 22.05.2003	1

Categoría de los documentos citados

X: de particular relevancia  
Y: de particular relevancia combinado con otro/s de la misma categoría  
A: refleja el estado de la técnica

O: referido a divulgación no escrita  
P: publicado entre la fecha de prioridad y la de presentación de la solicitud  
E: documento anterior, pero publicado después de la fecha de presentación de la solicitud

El presente informe ha sido realizado

para todas las reivindicaciones

para las reivindicaciones nº:

Fecha de realización del informe  
15.07.2015

Examinador  
M. Muñoz Sánchez

Página  
1/4

Documentación mínima buscada (sistema de clasificación seguido de los símbolos de clasificación)

G06F

Bases de datos electrónicas consultadas durante la búsqueda (nombre de la base de datos y, si es posible, términos de búsqueda utilizados)

INVENES, EPODOC, WPI, NPL, XPIEE, XPI3E

Fecha de Realización de la Opinión Escrita: 15.07.2015

**Declaración**

<b>Novedad (Art. 6.1 LP 11/1986)</b>	Reivindicaciones 1	<b>SI</b>
	Reivindicaciones	<b>NO</b>
<b>Actividad inventiva (Art. 8.1 LP11/1986)</b>	Reivindicaciones 1	<b>SI</b>
	Reivindicaciones	<b>NO</b>

Se considera que la solicitud cumple con el requisito de aplicación industrial. Este requisito fue evaluado durante la fase de examen formal y técnico de la solicitud (Artículo 31.2 Ley 11/1986).

**Base de la Opinión.-**

La presente opinión se ha realizado sobre la base de la solicitud de patente tal y como se publica.

**1. Documentos considerados.-**

A continuación se relacionan los documentos pertenecientes al estado de la técnica tomados en consideración para la realización de esta opinión.

Documento	Número Publicación o Identificación	Fecha Publicación
D01	CHATTOPADHYAY S et al. Univariate modelling of summer-monsoon rainfall time series: Comparison between ARIMA and ARNN.COMPTES RENDUS - GEOSCIENCE, 20100201 ELSEVIER, PARIS, FR 01.02.2010 VOL: 342 No: 2 Págs: 100-107 ISSN 1631-0713 McKey Doyle; Lézine Anne-Marie. Todo el documento.	01.02.2010
D02	CHATTOPADHYAY G et al. Autoregressive forecast of monthly total ozone concentration: A neurocomputing approach.COMPUTERS AND GEOSCIENCES, 20090901 PERGAMON PRESS, OXFORD, GB 01.09.2009 VOL: 35 No: 9 Págs: 1925-1932 ISSN 0098-3004 Doi: doi:10.1016/j.cageo.2008.11.007 Chen Yan. Todo el documento.	01.09.2009
D03	SHAMSELDIN A Y et al. Neural network river discharge forecasters: an empirical investigation of hidden unit processing functions based on two different catchments.Neural Networks, 2005. Proceedings. 2005 IEEE International Joint Conference on Montreal, Que., Canada 31 Julio-4 Ago. 2005, 20050731 Piscataway, NJ, USA,IEEE, US 31.07.2005 VOL: Págs: 2655-2660 vol. 4 ISBN 978-0-7803-9048-5; ISBN 0-7803-9048-2 Anonymous. Todo el documento.	31.07.2005
D04	KASINATHAN M et al. An Artificial Neural Network approach for the discordance sensor data validation for SCRAM parameters.2009 1st International Conference on Advancements in Nuclear Instrumentation, Measurement Methods and Their Applications: ANIMMA 2009; Marseille, France, 7 - 10 Junio 2009, 20090607 IEEE, Piscataway, NJ 07.06.2009 VOL: Págs: 1-5 ISBN 978-1-4244-5207-1; ISBN 1-4244-5207-4. Todo el documento.	07.06.2009
D05	US 2009113332 A1 (FARAHMAND TOURAJ et al.)	30.04.2009
D06	US 2003097230 A1 (GARABEDIAN ARMINCH)	22.05.2003

**2. Declaración motivada según los artículos 29.6 y 29.7 del Reglamento de ejecución de la Ley 11/1986, de 20 de marzo, de Patentes sobre la novedad y la actividad inventiva; citas y explicaciones en apoyo de esta declaración**

Se considera D01 el documento más próximo del estado de la técnica al objeto de la solicitud.

**Reivindicaciones independientes**

Reivindicación 1: El documento D01, divulga un método de modelado de una serie temporal para predecir las precipitaciones basado en una red neuronal autorregresiva no lineal. La red se entrena previamente utilizando un algoritmo genético para definir su topología y posteriormente se entrena con un 70% de los datos para determinar los valores Las diferencias con el documento D01 son:

- No se selecciona el mejor dato disponible entre uno real de un sensor y un predicho por la red neuronal
- No se incrementa la base de datos con el mejor dato seleccionado
- No se aplican técnicas de corrección de los valores

Las diferencias mencionadas aportan una mayor robustez al modelo, y por tanto, el problema técnico objetivo, a la luz de D01, consistiría en cómo conseguirla.

El documento D02 por otro lado divulga un método de modelado de una serie temporal para predecir la cantidad total de ozono mensual basado en una red neuronal autorregresiva no lineal usando para la optimización de sus parámetros de entrada un algoritmo genético.

El documento D03 por otro lado divulga un método de modelado de una serie temporal para predecir el caudal de ríos basado en una red neuronal autorregresiva no lineal usando para la optimización de sus parámetros un algoritmo genético combinado con otro de gradiente conjugado.

Por último el documento D04 divulga un método de validación de datos de sensores basándose en redes neuronales y digitalización de los datos.

En ninguno de los documentos D02, D03 o D04 se han encontrado las diferencias mencionadas por lo que la reivindicación 1 posee novedad y actividad inventiva según el art. 6.1 y el art. 8.1 de la Ley de Patentes respectivamente.