

Predicción de tráfico mediante co-evolución de Redes Neuronales de Funciones de Base Radial y selección de variables de entrada

V. M. Rivas¹, Elisabeth Parras-Gutierrez¹, M. G. Arenas², P. A. Castillo², P. García Sánchez², J.J. Merelo², P. García-Fernández³

¹ Dept. de Informática, Universidad de Jaén, Jaén, España

² Dept. Arquitectura y Tecnología de los Computadores, Universidad de Granada, España

³ Dept. Electrónica y Tecnología de los Computadores, Universidad de Granada, España

vrivas@ujaen.es

Resumen Este trabajo presenta un novedoso sistema de detección de flujo de tráfico, y muestra los resultados del algoritmo L-Co-R en la predicción de la serie temporal que el citado flujo de tráfico representa. La predicción de la serie temporal se ha realizado comparando con algoritmos existentes y muestra la adecuación del algoritmo, L-Co-R, ante el problema de la predicción de la serie temporal captada.

1. Introducción

El desarrollo de nuevos sistemas que informen de las condiciones del tráfico y del flujo de vehículos en las carreteras, es una apuesta de la Dirección General de Tráfico (DGT) dentro del territorio nacional y de las administraciones homólogas fuera del territorio nacional. Ejemplos de esta apuesta son los proyectos desarrollados para informar lo más exactamente posible acerca del estado del tráfico, como el que lleva a cabo Google Maps que proporciona desde hace no mucho tiempo (2011) información del estado del tráfico en las ciudades más importantes de algunos países, aunque el proyecto inicial empezó sólo en algunas ciudades de EEUU (2009). Otros ejemplos nacionales son la apuesta de la DGT por la investigación en tráfico financiando proyectos y promocionando encuentros sobre movilidad y seguridad vial.

Paralelamente a esta circunstancia, la población actual está evolucionando y se está convirtiendo en una población permanentemente informada, conectada y ubicua, puesto que en España existen actualmente más de 52 millones de clientes de telefonía móvil (<http://goo.gl/WTPN3>). Esta característica permite que casi cualquier conductor utilice a diario esos dispositivos de comunicación y por lo tanto lo lleven siempre con ellos mismos para comunicarse tanto de forma hablada como escrita, informarse, consultando cualquier dato que les pueda interesar (gracias a las tarifas de datos), o utilizando cualquier otro servicio accesible desde el dispositivo.

En España existían en 2012 165.568 Km de vías (último dato oficial publicado) [1], lo que da una idea muy clara de la complejidad de una red, puesto que, aunque sea sólo por su extensión, necesita muchísimo trabajo para su coordinación, su mantenimiento y su gestión en general. Por lo que al organismo que gestiona la red le es de mucha utilidad tener información lo más precisa posible, por básica que sea, sobre los usuarios que la utilizan, para poder preveer situaciones de saturación, o de evacuación en caso de alguna emergencia. Datos tan básicos como el número de vehículos que pasan por cada vía o a qué hora hay más afluencia para intentar regular la señalización de cada vía podrían facilitar el trabajo de los operarios.

En este trabajo se presenta un sistema de recogida de información de estado del tráfico y se analizan los datos recogidos incluyendo una predicción inicial de las series temporales de datos recogidas. Una serie temporal es un conjunto de datos ordenados de forma cronológica que sirve de base para realizar una predicción de valores futuros dentro de esa misma serie temporal. La predicción de series temporales es un campo de investigación activo dentro de áreas como la estadística o la investigación operativa [5], [4], y son datos presentes tanto en el campo de la ingeniería como en la biología, economía o las ciencias sociales entre otras.

La captación de datos se basa en la detección de dispositivos *bluetooth* (BT), en diferentes vías, lo que nos proporciona una descripción de las condiciones de tráfico en tiempo real y un conjunto de datos válidos para utilizarlos con técnicas de predicción de series temporales. La captación de datos incluye tanto dispositivos BT empotrados en algún tipo de vehículo como dispositivos de usuarios particulares que lleven el bluetooth activado. El principal dato recolectado de cada dispositivo es la dirección MAC que se encripta y se almacena, lo que permite identificar de forma unívoca el dispositivo, pero no el usuario, por lo que la privacidad de la persona usuaria del dispositivo está totalmente reservada. Esta identificación única puede permitir la identificación del dispositivo en varios puntos de la ciudad, lo que puede dar una idea del tipo de desplazamientos que ese usuario ha realizado.

Concretamente el dispositivo utilizado para la captación de datos es Intelify (<http://www.intelify.net/>) que ofrece una solución compacta para captar dispositivos BT y transmitir la información a un servidor remoto manteniendo un índice de detección adecuado (incluye un 8.5 % de error en la captación). Intelify es un dispositivo autónomo que puede ser instalado en el área donde se desean captar datos. Dispone de varios sensores y capta la información para enviarla a través de una conexión 3G. Los datos recopilados que se incluyen en este trabajo han sido captados por 5 puntos diferentes (nodos 1-5) durante un total de 60 días.

La información que se capta se organiza en una entidad que podemos denominar *paso*. Un *paso* será un dispositivo detectado en un determinado nodo de captación a una determinada hora de inicio y que se terminó de captar a una determinada hora de fin. Es decir, con cuatro datos, nodo, dispositivo, hora de inicio y hora de fin se puede categorizar un paso. La mac del dispositivo incluye

la identificación de la marca, modelo y algunas características más del dispositivo que ayuda a su categorización dentro del abanico de dispositivos captados por Intelify.

En este primer trabajo se han aplicado varios algoritmos de predicción de series temporales ya validados en la bibliografía y se presentan los resultados iniciales para predicción a corto plazo (1 día) sin modificar, tratar o adecuar la serie de datos inicialmente recopilada por el dispositivo de captación.

El objetivo final de este proceso de investigación inicial es predecir el flujo de tráfico que tendrán las vías monitorizadas con este tipo de dispositivo o cualquier otro que proporcione una información simple y fiable a cerca del paso de vehículos por un determinado punto. Esta predicción permitirá, por ejemplo, poder tomar decisiones acerca del mejor itinerario a elegir para un determinado desplazamiento, tanto para los usuarios de las vías como para las administraciones a la hora de planificar señalización, e intervención en las vías monitorizadas.

El artículo a partir de este punto se organiza en secciones. La sección 2 repasa el estado del arte tanto de los algoritmos de predicción de series temporales como de los dispositivos de captación de datos existentes actualmente. Por su parte, la sección 3 presenta los resultados obtenidos en la predicción a corto plazo del flujo del tráfico. Por último en la última sección se presentan unas conclusiones iniciales y los pasos que se pondrán en práctica como líneas futuras de trabajo.

2. Estado del arte

En esta sección se repasarán de forma resumida los dispositivos de captación de tráfico existentes y posteriormente introduciremos un pequeño estado del arte sobre los algoritmos de predicción de series temporales que están vigentes.

Las tecnologías que permiten detectar el flujo de tráfico se clasifican en dos grupos: intrusivas y no intrusivas. Las intrusivas implican una modificación física de la vía que monitoriza y esta característica se convierte en su principal inconveniente, puesto que la vía debe ser cerrada para su instalación además de un posterior mantenimiento. En cualquier caso estas técnicas sólo cuentan vehículos que atraviesan el sistema de monitorización, sin identificarlos de ninguna forma. En este grupo se incluyen por ejemplo los sensores piezoeléctricos o los tubos neumáticos. Las tecnologías no intrusivas no producen interrupción del tráfico, puesto que su colocación no está físicamente en el pavimento, sino en zonas adyacentes de la vía como paneles informativos, carteles de señalización, puestos de emergencias, etc. En este último grupo se incluyen los radares, la señalización lumínica o las cámaras de monitorización.

El inconveniente principal de este sistema de monitorización es que no permiten identificar los vehículos de forma unívoca para poder construir patrones de desplazamiento o matrices de frecuencia de destinos para un conjunto de orígenes dados.

Respecto al estado del arte de los algoritmos de predicción, existen muchos trabajos relacionados con el tema y que han sido ampliamente utilizados con con-

juntos de datos públicos con los que han sido testeados por sus desarrolladores. Todos los algoritmos de predicción intentan modelar un sistema numérico que represente el comportamiento de la serie y con el pueda predecirla. Estos modelos pueden ser lineales o no lineales. Dentro del grupo de los lineales hay varios, pero el más conocido es el llamado método ARIMA [3]. ARIMA es un modelo simple y cuyo funcionamiento está ampliamente demostrado, pero no funciona muy bien con muchas aplicaciones a series temporales reales, puesto que su ajuste no es fácil y lo debe de realizar operarios especializados. Esta es la principal razón de que surgieran los métodos no lineales.

Los modelos no lineales se ajustan mejor a aplicaciones reales aunque la facilidad de uso sigue siendo escasa [6], de ahí que existan propuestas donde se recomienda que se le debe dar prioridad a la facilidad de uso frente a otros aspectos más técnicos [4].

La predicción de series temporales también se ha abordado desde otros campos, como técnicas de Soft-Computing, [7], [8]; Técnicas Fuzzy [9], [10]; redes neuronales, [11]; Regresión [12]; y sistemas expertos [13]. En nuestro caso nos hemos centrado en métodos no lineales basados en la utilización de Redes Neuronales, puesto que tal y como afirma Tang [14] son métodos que ofrecen una mayor flexibilidad y efectividad a la hora de predecir una serie temporal real.

En concreto el algoritmo desarrollado, L-Co-R [2] utiliza Redes Neuronales de Base Radial (RBFNs). L-Co-R [2] presenta varias ventajas con respecto a otros métodos⁴. La principal es que coevoluciona los datos de entrada de la serie (lag) junto con la red neuronal que se va a utilizar para predecir. Este enfoque coevolutivo no ha sido desarrollado en la literatura, puesto que otros autores coevolucinan las diferentes partes de la red o simplemente no utilizan el enfoque coevolutivo a la predicción sino a otro tipo de problemas como la clasificación. Aún así, si que existen autores que utilizan el mismo tipo de redes de forma no coevolutiva como [16,17,18] que aplican la predicción al precio del aceite de oliva.

Para realizar la predicción se utilizan periodos de tiempo de la serie de tamaño finito llamados "lags". Los lags deben representar perfectamente el comportamiento de la serie y su relación y según el teorema de Takens [19] estableciendo correctamente estos lags, el comportamiento del espacio multidimensional construido a partir de dicho lag, puede representar de forma correcta el comportamiento de la serie temporal real.

Existen métodos automáticos que intentan determinar el lag más adecuado como pueden ser el algoritmo QIEHI [20], [21]. Otros autores han ido más allá, buscando no sólo el lag, sino las características externas que afectan a la serie y que con un preprocesamiento previo de la serie temporal, puede desembocar en la elección de un lag más adecuado para la predicción, [22]. También se ha realizado este estudio después de la predicción, [23], incluyendo un post procesamiento de los datos que modifica el lag de salida del método.

⁴ Estas ventajas y el algoritmo al completo están detallados en la referencia anterior y no se detallan en esta publicación por falta de espacio

En la propuesta que se presenta en este artículo, se utiliza para la predicción un método no lineal que utiliza redes de base radial (RBFs) para determinar de forma cooperativa el lag y la predicción de la serie temporal a la que se aplique el algoritmo, si necesidad de ningún pre o pro procesamiento.

3. Experimentos y resultados

En esta sección se analizan los datos recolectados y se obtienen los resultados estadísticos iniciales a cerca de la predicción realizada.

Debido al gran número de métodos existentes para realizar predicción, hemos seleccionado sólo 6 de ellos para poder realizar comparaciones entre los diferentes resultados. En esta selección se han incluido métodos lineales y no lineales. En concreto la selección es ARIMA, Croston, Theta, Spline y L-Co-R y como método de control hemos seleccionado la media. Todos los métodos excepto L-Co-R están incluidos dentro del paquete estadístico R y son ampliamente conocidos y esta es la razón de por qué han sido seleccionados, puesto que así cualquier otro investigador puede comprobar sus resultados si dispone de R. L-Co-R [2] es un algoritmo coevolutivo desarrollado que ha generado resultados muy buenos dentro de la predicción a corto plazo. Se trata de un método no lineal basado en evolucionar RBFs y Lags simultáneamente para adecuar la red al lag elegido y el lag elegido a la red que el método construye.

Los experimentos se han realizado utilizando las cinco series de datos descritas en la sección anterior. Los primeros 53 días de la serie se han utilizado para entrenar los diferentes métodos y poder construir el modelo predictivo, mientras que los 7 días restantes se han utilizado para testear la predicción generada. La predicción se genera con un horizonte de 1, es decir conocidos los datos de la serie con n elementos, el algoritmo predice el elemento $n + 1$.

Para cada método y cada serie, se han calculado una serie de medidas de error para poder comparar la predicción de los diferentes métodos:

- *Mean Absolute Error (MAE):*

$$MAE = \text{mean}(| e_t |) \quad (1)$$

- *Mean Absolute Percentage Error (MAPE):*

$$MAPE = \text{mean}(| p_t |) \quad (2)$$

- *Median Absolute Percentage Error (MdAPE):*

$$MdAPE = \text{median}(| p_t |) \quad (3)$$

- *Mean Absolute Scaled Error (MASE):*

$$MASE = \text{mean}(| q_t |) \quad (4)$$

- *Mean Squared Error (MSE):*

$$MSE = \frac{1}{n} \sum_{i=1}^n e_t^2 \tag{5}$$

donde Y_t es el dato observado en tiempo $t = 1, \dots, n$; F_t es la predicción de Y_t ; e_t es el error de predicción (i.e. $e_t = Y_t - F_t$); $p_t = 100e_t/Y_t$ es el porcentaje de error y $q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|}$

Los resultados mostrados del algoritmo L-Co-R son medias de error de 30 ejecuciones con cada una de las series temporales estudiadas

La tabla 1 muestra los diferentes valores de error para cada uno de los métodos y para cada serie. Destacados en el texto aparecen el mejor (menor) valor obtenido para cada nodo y cada medida de error. Tal y como se puede apreciar en la tabla, la tendencia es siempre que el mejor algoritmo es justo el algoritmo L-Co-R puesto que obtiene los menores errores para las medidas MAE, MAPE, MdAPE y MASE (excepto para el nodo 2), aunque para otras medidas como MSE no hay un claro algoritmo ganador.

Los resultados de cada método se han comparado utilizando dos medidas no paramétricas: El test de Friedman y el test de Iman-Davenport mediante las cuales podemos determinar si existen diferencias significativas entre los métodos o no, estableciendo así un ranking de métodos de mejor a peor en el proceso de predicción. Los resultados revelan que existen diferencias significativas cuando el valor $P - value$ es mejor que 0.05.

El ranking formado por los valores resultados de los test no-paramétricos, determinan cual es el mejor método. Una vez que este método se ha encontrado, se puede comparar de nuevo con el método de Holm [25]. En la tabla 3 se resumen los resultados así como la existencia de diferencias significativas entre los métodos. En este caso, los resultados muestran que el algoritmo L-Co-R es el mejor para cuatro de las medidas de error utilizadas (MAE, MAPE, MASE, y MdAPE), aunque no se puede realizar esta afirmación si lo comparamos con el método ARIMA, donde no se encuentran para estas series, diferencias significativas en los resultados de predicción.

4. Conclusiones y trabajo futuro

En este trabajo se presenta la utilización de un dispositivo de captación de emisiones BT para recopilar series temporales relacionadas con el flujo del tráfico en cualquier tipo de vía. Concretamente se han monitorizado 6 vías obteniendo las correspondientes series para cada uno de los dispositivos (Nodo 1-5).

Utilizando estas series temporales reales que incluyen el número de dispositivos captados por día, se ha realizado un estudio de las series para predecir a corto plazo (1 día) cual será el flujo de tráfico en cada uno de los nodos. Se han

Nodo 1	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>	<i>MdAPE</i>	<i>MSE</i>
<i>ARIMA</i>	514,83	40,42	1,14	30,76	424860,5
<i>CROSTON</i>	509,91	39,28	1,13	33,8	387403,9
<i>THETA</i>	528,59	41,16	1,17	32,78	443898,5
<i>SPLINE</i>	550,02	43,87	1,21	30,1	488504,9
<i>MEAN</i>	456,95	38,57	1,01	26,11	318623,5
<i>L-Co-R</i>	372,77	23,66	0,81	18,46	231731,8
Nodo 2	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>	<i>MdAPE</i>	<i>MSE</i>
<i>ARIMA</i>	433,52	26,64	1,03	22,38	310105,3
<i>CROSTON</i>	532,87	27,98	1,26	27,89	398979,9
<i>THETA</i>	435,58	26,77	1,03	22,55	312496,1
<i>SPLINE</i>	535,86	34,53	1,27	24,7	447557,4
<i>MEAN</i>	489,57	24,44	1,16	28,64	361070,5
<i>L-Co-R</i>	429,78	11,41	1,04	11,98	311561,7
Nodo 3	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>	<i>MdAPE</i>	<i>MSE</i>
<i>ARIMA</i>	373,17	35,11	1,32	27,54	150293,6
<i>CROSTON</i>	377,42	37,03	1,34	27,89	160970,9
<i>THETA</i>	394,95	38,11	1,4	29,41	175710,7
<i>SPLINE</i>	384,68	38,86	1,36	29,36	184807,2
<i>MEAN</i>	373,18	35,11	1,32	27,53	150307,8
<i>L-Co-R</i>	363,3	10,56	0,84	17,01	182469,9
Nodo 4	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>	<i>MdAPE</i>	<i>MSE</i>
<i>ARIMA</i>	3168,36	40,62	1,04	18,99	21792093
<i>CROSTON</i>	3789,4	56,83	1,25	54,33	25037291
<i>THETA</i>	3085,3	38,14	1,01	25,42	21510757
<i>SPLINE</i>	3758,06	39,45	1,24	43,53	28745309
<i>MEAN</i>	4545,17	92,73	1,5	40,07	26612429
<i>L-Co-R</i>	540,59	6,26	0,07	4,14	1120317,2
Nodo 5	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>	<i>MdAPE</i>	<i>MSE</i>
<i>ARIMA</i>	5012,95	43,8	1,13	20,19	29974781
<i>CROSTON</i>	5583,14	46,32	1,26	26,12	35082013
<i>THETA</i>	5779,37	45,78	1,3	28,25	35859271
<i>SPLINE</i>	5878,35	46,26	1,32	28,69	37288518
<i>MEAN</i>	5013,48	43,81	1,13	20,19	29980578
<i>L-Co-R</i>	4978,08	24,59	0,87	9,37	35875329

Cuadro 1: Valores obtenidos para las cinco medidas de error (MAE, MAPE, MASE, MdAPE y MSE) para los métodos de predicción seleccionados (ARIMA, Croston, Theta, Spline, Mean y L-Co-R) para todos los nodos. En negrita se resalta el mejor resultado para cada caso.

seleccionado 5 métodos de predicción con los que se han calculado 5 medidas de error.

Los resultados obtenidos demuestran que la predicción con el algoritmo L-Co-R a corto plazo es significativamente mejor que las predicciones obtenidas

<i>Error</i>	<i>Friedman P-value</i>	<i>Iman-Davenport P-value</i>
<i>MAE</i>	0.0052	0.0003
<i>MAPE</i>	0.0080	0.0008
<i>MASE</i>	0.0141	0.0030
<i>MdAPE</i>	0.0063	0.0005
<i>MSE</i>	0.0213	0.0066

Cuadro 2: Resultado del valor *P-value* para los test de Friedman y Iman-Davenport para cada medida de error. Un valor de *P-value* menor que 0.05 (todos en este caso) indica que existen diferencias significativas entre los errores calculados para cada método.

con el resto de los métodos para todas las medidas de error seleccionadas menos una.

Este trabajo abre un abanico de posibilidades de análisis de la gran cantidad de datos captados y la posibilidad de desarrollar métodos de predicción no sólo a corto plazo, sino a medio y largo plazo, lo que facilitará la tarea de previsión del flujo de tráfico en las vías monitorizadas y por consiguiente una mejor gestión del tráfico en dichas vías por parte de las autoridades competentes.

Este trabajo se está desarrollando gracias a la financiación de los proyectos TIC-3903, P08-TIC-3928, CEI2013-P-14, TIN2011-28627-C04-02, y del proyecto FEDER de la Unión Europea con título "Sistema de Información y Predicción de bajo coste y autónomo para conocer el Estado de las Carreteras en tiempo real mediante dispositivos distribuidos" (SIPeSCa) del Programa Operativo FEDER de Andalucía 2007-2013. Asimismo, queremos mostrar nuestro agradecimiento al personal e investigadores de la Agencia de Obra Pública de la Junta de Andalucía, Consejería de Fomento y Vivienda, por su dedicación y profesionalidad.



Referencias

1. Dirección General de Tráfico. Evolución 1970-2012. Ministerio de Fomento, Mayo 2013 http://www.fomento.gob.es/MFOM/LANG_CASTELLANO/DIRECCIONES_GENERALES/CARRETERAS/CATYEVO_RED_CARRETERAS/
2. Elisabet Parras-Gutierrez, M. G. Arenas, V. M. Rivas, M. J. del Jesus, Coevolution of lags and RBFNs for time series forecasting: L-Co-R algorithm, *Soft Computing* 16(6), (2012) 919-942.

<i>Error</i>	<i>Método de Control</i>	<i>Ranking</i>	<i>Método</i>	<i>p</i>	<i>Hipótesis nula</i>
MAE	L-Co-R	1	ARIMA	0.176	Aceptada
		2	MEAN	0.028	Rechazada
		3	THETA	0.007	Rechazada
		4	CROSTON	0.007	Rechazada
		5	SPLINE	2.003E-4	Rechazada
MAPE	L-Co-R	1	ARIMA	0.090	Aceptada
		2	MEAN	0.0.063	Aceptado
		3	THETA	0.011	Rechazada
		4	CROSTON	0.002	Rechazada
		5	SPLINE	3.857E-4	Rechazada
MASE	L-Co-R	1	ARIMA	0.398	Aceptada
		2	MEAN	0.063	Aceptado
		3	THETA	0.028	Rechazada
		4	CROSTON	0.018	Rechazada
		5	SPLINE	7.232E-4	Rechazada
MdAPE	L-Co-R	1	ARIMA	0.176	Aceptada
		2	MEAN	0.042	Rechazada
		3	THETA	0.004	Rechazada
		4	SPLINE	0.002	Rechazada
		5	CROSTON	7.232E-4	Rechazada
MSE	ARIMA	1	L-Co-R	0.500	Aceptada
		2	MEAN	0.398	Aceptado
		3	CROSTON	0.176	Aceptado
		4	THETA	0.176	Aceptado
		5	SPLINE	7.232E-4	Rechazada
SMAPE	ARIMA	1	L-Co-R	0.866	Aceptada
		2	MEAN	0.310	Aceptado
		3	CROSTON	0.091	Aceptado
		4	THETA	0.043	Rechazada
		5	SPLINE	0.006	Rechazada

Cuadro 3: Resultados del test de Holm para cada medida de error. Valores de p menores o iguales a 0.05 indican que los resultados de error calculados por el algoritmo de control y los demás métodos, se pueden considerar significativamente diferentes.

- G. Box, G. Jenkins, Time series analysis: forecasting and control, San Francisco: Holden Day, 1976.
- J. De Gooijer, R. Hyndman, 25 years of time series forecasting, International Journal of Forecasting 22 (3) (2006) 443–473.
- R. Fildes, K. Nikolopoulos, S. Crone, A. Syntetos, Forecasting and operational research: a review, Journal of the Operational Research Society 59 (2008) 1150–1172.
- M. Clements, P. Franses, N. Swanson, Forecasting economic and financial time-series with non-linear models, International Journal of Forecasting 20 (2) (2004) 169–183.
- B. Samanta, Prediction of chaotic time series using computational intelligence, Expert Systems with Applications 38 (9) (2011) 11406–11411.

8. S. Zhu, J. Wang, W. Zhao, J. Wang, A seasonal hybrid procedure for electricity demand forecasting in china, *Applied Energy* 88 (11) (2011) 3807–3815.
9. W. Qiu, X. Liu, H. Li, A generalized method for forecasting based on fuzzy time series, *Expert Systems with Applications* 38 (8) (2011) 10446–10453.
10. C. Wang, A comparison study between fuzzy time series model and arima model for forecasting taiwan export, *Expert Systems with Applications* 38 (8) (2011) 9296–9304.
11. T. Yu, K. Huarng, A neural network-based fuzzy time series model to improve forecasting, *Expert Systems with Applications* 37 (4) (2010) 3366–3372.
12. K. Kavaklioglu, Modeling and prediction of turkey's electricity consumption using support vector regression, *Applied Energy* 88 (1) (2011) 368–375.
13. P. K. Dash, A. C. Liew, S. Rahman, G. Ramakrishna, Building a fuzzy expert system for electric load forecasting using a hybrid neural network, *Expert Systems with Applications* 9 (3) (1995) 407–421.
14. Z. Tang, C. de Almeida, P. Fishwick, Time series forecasting using neural networks vs. box-jenkins methodology, *Simulation* 57 (5) (1991) 303–310.
15. V. Rivas, J. Merelo, P. Castillo, M. Arenas, J. Castellano, Evolving rbf neural networks for time-series forecasting with evrbf, *Information Sciences* 165 (3-4) (2004) 207 – 220.
16. H. Hippert, J. Taylor, An evaluation of bayesian techniques for controlling model complexity and selecting inputs in a neural network for short-term load forecasting, *Neural Networks* 23 (3) (2010) 386–395.
17. C. Lee, C. Ko, Time series prediction using rbf neural networks with a nonlinear time-varying evolution pso algorithm, *Neurocomputing* 73 (1-3) (2009) 449–460.
18. M. Perez-Godoy, P. Pérez-Recuerda, M. Frías, A. Rivera, C. Carmona, M. Parras, Co²rbfn for short and medium term forecasting of the extra-virgin olive oil price, in: J. González, D. Pelta, C. Cruz, G. Terrazas, N. Krasnogor (Eds.), *Proceedings of Nature Inspired Cooperative Strategies for Optimization*, Vol. 284, Springer Berlin/Heidelberg, 2010, pp. 113–125.
19. F. Takens, *Dynamical Systems and Turbulence*, Lecture Notes In Mathematics, Vol. 898, Springer, New York, NY, 1980, Ch. Detecting strange attractor in turbulence, pp. 366–381.
20. R. Araújo, A quantum-inspired evolutionary hybrid intelligent approach fo stock market prediction, *International Jorunal of Intelligent Computing and Cybernetics* 3 (10) (2010) 24–54.
21. R. Araújo, Hybrid intelligent methodology to design translation invariant morphological operators for brazilian stock market prediction, *Neural Networks* 23 (10) (2010) 1238–1251.
22. R. García-Pajares, J. Benitez, G. Sainz Palmero, Feature selection form time series forecasting: a case study, in: *Proceedings of 8th International Conference on Hybrid Intelligent Systems*, 2008, pp. 555–560.
23. A. Maus, J. C. Sprott, Neural network method for determining embedding dimension of a time series, *Communications in Nonlinear Science and Numerical Simulation* 16 (8) (2011) 3294–3302.
24. R. Fildes, The evaluation of extrapolative forecasting methods, *International Journal of Forecasting* 8 (1) (1992) 81–98.
25. S. Holm, A simple sequentially rejective multiple test procedure, *Scandinavian Journal of Statistics* 6 (2) (1979) 65–70.