

Aplicaciones tecnológicas en la logística de transportes portuarios. Las terminales de contenedores

Autor:
Rodríguez García, Tomás

Revista:
Revista Transporte y Territorio

2016, 14, 5-26



Artículo

Aplicaciones tecnológicas en la logística de transportes portuarios. Las terminales de contenedores



Tomás Rodríguez García

Departamento de Ingeniería Civil, Universidad Politécnica de Madrid, España

Recibido: 13 de abril de 2015. Aceptado: 16 de noviembre de 2015.

Resumen

Ante la necesidad de manejar una gran información de datos surgen nuevas técnicas basadas en la *minería de datos* con objeto de descubrir patrones. En este caso patrones de predicción necesarios para poder hacer un uso rápido y eficaz de estos datos. En este documento se citan algunos modelos de predicción basados en la *minería de datos* y que han sido analizados en diversos estudios para valorar su aceptación. Los modelos citados en el artículo son: *redes bayesianas* (RB) y *redes neuronales artificiales* (RNA). Al final del documento se incluyen algunos ejemplos de investigaciones realizadas con RB y RNA donde se han analizado previsiones a nivel internacional de puertos con terminales de contenedores.

Palabras clave

Planificación
Logística
Transporte
Terminal de contenedores

Abstract

Technological applications in transport logistics port. Container terminals. Given the need to handle large data information emerging new techniques based on *data mining* in order to discover patterns. In this case prediction patterns needed to enable rapid and effective use of these data. In this paper prediction models based on *data mining* and have been analyzed in several studies to evaluate its acceptance are cited. These models are *bayesian networks* (RB) and *artificial neural networks* (ANN). The paper concludes with some examples of investigations realized with RB and RNA where forecasts have been analyzed international container ports terminals.

Keywords

Planning
Logistics
Transport
Container terminal

Palavras-chave

Planejamento
Logística
Transporte
Terminal de contêineres

Introducción

La situación de crisis mundial de los últimos años genera en los puertos con terminales de contenedores en un ámbito internacional la necesidad de planificar a corto plazo con los medios existentes, intentando evitar con el fin de evitar altas inversiones económicas que resulten muy poco productivas. Asimismo, los requerimientos de espacio previstos en estas nuevas necesidades generan impactos ambientales y vertebran el entorno, hecho que se puede evitar mediante una acertada planificación.

Las terminales de contenedores son zonas claves en el ámbito del comercio de las materias primas y por tanto uno de los claros exponentes de la situación económica del entorno, siendo su tráfico un claro ejemplo de la realidad económica del momento.

Sobre los activos de que se dispone en los puertos con terminales de contenedores, existen numerosos datos y estadísticas (Banco mundial, Drewry, IAPH, entre otros). Debido al gran número de variables e información contenida en ellas, el manejo de estos datos se haría ingobernable si no fuera por las nuevas aplicaciones tecnológicas que han aparecido en las últimas décadas. Estas técnicas de predicción basadas en la *minería de datos* han sido empleadas con éxito en otros sectores como la medicina, telecomunicaciones y sistemas de transportes en general entre otros. En el caso de los sistemas de transporte se pueden observar en los cuadros 1 y 3 los trabajos realizados en este ámbito.

De un modo más amplio en los últimos años estas técnicas de predicción se han empezado a utilizar en estudios de investigación en sistemas de transportes portuarios y en concreto en los puertos con terminales de contenedores con objeto de poder planificar a corto plazo no solo los activos de las terminales y la prognosis de TEU que es necesario mover, sino también la posible congestión en los puertos si no se realizara inversión alguna (Rodríguez et al., 2013 y 2014). Estas predicciones tanto de tráfico como de activos necesarios en los puertos son indispensables no solo a largo plazo donde existe una mayor posibilidad de demora de decisión y análisis más profundo, sino también en predicciones a corto plazo donde se necesita una respuesta más rápida para que las medidas a adoptar puedan ser operativas y fructíferas.

El objeto del presente artículo es dar a conocer estas técnicas predictivas basadas en la minería de datos, así como algunos resultados obtenidos en trabajos de investigación realizados en los últimos años. Para ello el documento se estructura en varias partes diferenciadas; una primera donde se hace un pequeño resumen de las características de los puertos y de las técnicas predictivas comentadas (RB y RNA), así como de los trabajos realizados con las mismas en sistemas de transportes y más en concreto los realizados en el ámbito portuario, una segunda donde se comenta la metodología utilizada con las RB y RNA, una tercera donde se comentan algunos de los resultados obtenidos en los últimos años con estas técnicas y como punto final una cuarta donde se citan conclusiones de las posibilidades de estos modelos de cara a un futuro ya que estas técnicas aún se encuentran en periodo investigación o inicios de implementación en los modelos de predicción utilizados en casos reales. Cabe destacar que en algunos pliegos de concursos públicos ya se solicitan estudios de planificación con estas técnicas como es el caso del análisis de demanda a largo plazo de los puertos estatales en la región de Valparaíso en el año 2014 donde se citan como referencia los trabajos de Rodríguez et al. (2013) *Forecasting models in ports transport systems. Are ANNs applications the solution?* y Al-Deek (2001) *Comparison between neural networks and multiple regression approaches for developing freight planning models with specific applications to sea-ports*.

Características de las terminales portuarias de contenedores

Las terminales de contenedores son intercambiadores intermodales con unas capacidades de manipulación y almacenamiento vinculadas entre sí, sobre la base de los tráfico de TEU que se pueden gestionar.

En las terminales de contenedores se realizan operaciones de carga y descarga de los contenedores, su almacenamiento temporal para su posterior intercambio entre modos de transporte (camiones y ferrocarril principalmente), para por último realizar su traslado al punto de destino.

Las terminales de contenedores se caracterizan por tener varios subsistemas relacionados entre sí. Estos subsistemas se pueden denominar:

- » Carga-descarga: zona donde se trasladan los contenedores de lado tierra al lado mar y viceversa.
- » Almacenamiento: zona donde se depositan los contenedores entre periodos de manipulación. Esta zona es la que demanda una mayor superficie o extensión en la terminal. La tipología de almacenamiento y los equipos de manipulación, podrán condicionar en gran medida la extensión y tipología de la misma.
- » Recepción y entrega: en esta zona se producen los intercambios de modo de transporte, pudiendo pasar a transporte por carretera o a transporte por ferrocarril.
- » Interconexión: en este subsistema intervienen los transportes y movimientos internos dentro de la terminal para el traslado, acomodo o conexión entre los anteriores subsistemas.

Todos estos subsistemas se encuentran ampliamente estudiados y analizados en diversos trabajos como los de Camarero et al., 2007; González, 2007; Martín Alcalde, 2008; González et al., 2009; y Burns, 2012 entre otros.

En el primero de estos trabajos, Camarero y González realizan un análisis de las zonas que se pueden considerar en las terminales de contenedores (zona de operaciones, zona de almacenamiento y zona de servicio), así como de los distintos subsistemas a considerar según su estudio y los agentes intervinientes en cada uno de ellos (subsistema de atraque, subsistema de carga y descarga, subsistema de almacenamiento, subsistema de movimiento interno o interconexión y subsistema de entrega y recepción). Así mismo, en este trabajo realizan una clasificación de las terminales sobre la base del sistema de transferencia de los contenedores (terminales multipropósito, muelles de contenedores y terminales de contenedores) y del tipo de tráfico (terminales *feeder*, terminales de trasbordo y terminales de importación-exportación).

En los otros dos trabajos, los autores (González, MN. en el primero y Camarero, A. y González, MN. en el segundo), realizan un estudio del sistema portuario español para la caracterización de las terminales de contenedores y la obtención de parámetros de diseño en cada una de las zonas de una terminal (operación, almacenamiento y de servicios) y de los subsistemas considerados (atraque-carga y descarga, almacenamiento,...).

Martín Alcalde realiza un estudio de optimización de la operativa del subsistema de recepción y entrega, donde recoge los distintos subsistemas considerados por el autor (conexión buque-muelle, almacenaje, interconexión y transferencia de contenedores y recepción y entrega).

Más recientemente, en el año 2012 James Burns Mas en su trabajo final de grado *Terminales de contenedores: sistemas de operación*, realiza una descripción de las áreas funcionales de operaciones, clasificándolas en tres áreas principales; área entre muelle y playa de acopio, playa de acopio y área de operaciones terrestres. Como se puede observar apenas difiere en términos generales de las consideradas por los demás autores.

A nivel internacional Steenken junto a otros dos autores más, en su trabajo del año 2004 realizan una recopilación de la literatura existente hasta ese momento, donde describen y clasifican los principales procesos de logística y operaciones en las terminales de contenedores. En este trabajo diferencia las áreas de operación de los subsistemas considerados donde dichas áreas se resumen en zona de operaciones con barcos, zona de almacenamiento y zona de operaciones de interconexión con otros modos de transporte. Entre estas zonas sitúa las áreas de operaciones de muelle y las de movimiento interior.

En el caso de libros de referencia en el diseño de terminales portuarias, el Handbook of Terminal Planning en su edición del año 2011, considera tres áreas funcionales: *Quayside*, *Yard* y *Landside*. En esta consideración se engloban las áreas consideradas por otros autores como González y Martín. Por lo tanto como se puede observar en los trabajos comentados las áreas o subsistemas considerados a lo largo de los años han sido similares.

Modelos de predicción en sistemas de transportes

En los últimos años se están desarrollando modelos de pronóstico en los sistemas de transporte con diferentes técnicas de predicción. Entre las técnicas más desarrolladas en este ámbito de los sistemas de transportes en los últimos años se encuentran los desarrollados con modelos basados en *redes bayesianas* (RB) y modelos con *redes neuronales artificiales* (RNA) entre otros.

A continuación se incluye información sobre los dos modelos de predicción comentados (RB: redes bayesianas y RNA: *redes neuronales artificiales*).

RB (Redes Bayesianas)

Las redes bayesianas son herramientas estadísticas que representan un conjunto de incertidumbres asociadas sobre la base de las relaciones de independencia condicional que se establecen entre ellas. Siguiendo a Kadie, Hovel y Horvitz, se dice que una red bayesiana es un conjunto de variables, una estructura gráfica conectando estas variables y un conjunto de distribuciones de probabilidad condicional. Codifica incertidumbre asociada a cada variable por medio de probabilidades y, gracias al teorema de Bayes, esta incertidumbre es susceptible de ser modificada sobre la base de observaciones (o evidencias) sobre el modelo.

Grafos o representación gráfica

Una red bayesiana tiene dos dimensiones: una cualitativa y otra cuantitativa (Cain, 2001; Garbolino y Taroni, 2002; Martínez y Rodríguez, 2003; Nadkarni y Shenoy, 2004 y Nadkarni y Shenoy, 2004). Una red bayesiana es un grafo; esto es, una representación gráfica de un problema. Se puede definir grafo como un par $G=(V,E)$, donde V es un conjunto finito de vértices, nodos o variables y E es un subconjunto del producto cartesiano $V \times V$ de pares ordenados de nodos llamados enlaces o aristas.

Por otro lado, una red bayesiana es un tipo concreto de grafo que se denomina grafo dirigido acíclico (GDA). Es dirigido porque los enlaces entre los vértices de la estructura están orientados y es acíclico porque no pueden existir ciclos o bucles en el grafo; esto es, si se empieza a recorrer un camino dirigido desde un nodo nunca se podría regresar al punto de partida.

Se puede decir que las redes bayesianas son una representación gráfica del principio de independencia condicional en términos probabilísticos. Este principio quedaría enunciado del siguiente modo: sean tres conjuntos X , Y y Z de variables; se diría que los conjuntos X e Y son (condicionalmente) independientes dado el conjunto Z si y solamente si $P(x|z) = P(x|yz)$ o dicho de otro modo, dos variables X e Y , son independientes en términos probabilísticos de una tercera Z si y solamente si $P(xy|z) = P(y|z)$.

La consecuencia fundamental de este principio es que la probabilidad de X es la misma condicionándola a Z o condicionándola a Z e Y .

Tipos de conexiones

Cualquier red bayesiana podría descomponerse en tres tipos de conexiones básicas, cada una con propiedades diferentes en el proceso de propagación de probabilidades. En primer lugar, las conexiones seriales o cadenas causales representan un conjunto de variables asociadas linealmente que denota dependencia entre las variables (Figura 1).




Figura 1. Conexión en serie.
Fuente: Elaboración propia.

En las conexiones divergentes, también conocidas como clasificadores ingenuos de Bayes, se tiene un nodo padre (o clase) que proyecta sus arcos sobre varios hijos (Figura 2a). Este tipo de conexión es el más apropiado para representar procesos de diagnóstico médico (Hensher y Ton, 2000) y son útiles para estimar el conocimiento asociado a conceptos en función del comportamiento del usuario.




Figura 2. Conexión divergente (a) y conexión convergente (b).
Fuente: Elaboración propia.

Por último, en las conexiones convergentes varias variables apuntan con sus arcos hacia una variable de convergencia (Figura 2b). En este tipo de conexiones las variables madre son independientes entre sí.

Elementos esenciales

Existen tres elementos esenciales que caracterizan la dimensión cuantitativa de una red bayesiana: el *concepto de probabilidad* como un grado de creencia subjetiva relativa a la ocurrencia de un evento, un *conjunto de funciones de probabilidad condicionada* que definen cada variable en el modelo y el *teorema de Bayes* como herramienta básica para actualizar probabilidades con base en experiencia.

Las redes bayesianas utilizan el teorema de Bayes como herramienta básica para actualizar probabilidades con base en las evidencias aportadas sobre el modelo. En primer lugar hay que compilar la red para que se cree una representación interna de las probabilidades del modelo. De esta manera se estima lo que se conoce como distribución previa (o distribución a priori) del modelo. A continuación se van añadiendo evidencias sobre el estado de las variables del modelo y se va obteniendo sucesivamente lo que se conoce como distribuciones posteriores (o a posteriori).

De esta forma, en una red bayesiana cada variable es entendida como una función de probabilidad condicionada o una función de densidad condicionada a los valores que toman las variables de las que depende.

La ventaja de utilizar un GDA para construir un modelo probabilístico es que siempre se tiene la posibilidad de conocer la verosimilitud del modelo factorizándolo. Así pues, para cada variable $v \in V$, tenemos que especificar las distribuciones condicionales de X_v dados sus padres $X_{pa(v)}$. Si entendemos que esta densidad es $P(x_v | x_{pa(v)})$, entonces la densidad global conjunta se deriva de $P(x) = \prod_{v \in V} P(x_v | x_{pa(v)})$.

En una red bayesiana, cada nodo corresponde a una variable, que a su vez representa una entidad del mundo real. Los arcos que unen los nodos indican relaciones de influencia causal.

En el Cuadro 1 se citan los trabajos realizados con *redes bayesianas* relacionados con los sistemas de transportes con objeto de que se pueda valorar el número de trabajos

desarrollados en dicho sistema y los relativos a las *redes bayesianas*. En este cuadro se incluyen los trabajos relacionados con el ámbito portuario o marítimo donde se puede apreciar que su peso es representativo respecto al resto de estudios realizados en sistemas de transportes.

Cuadro 1. Trabajos desarrollados con RB en sistemas de transportes marítimos.

Fuente: Elaboración propia

AUTORES	AÑO	TÍTULO
Friedman, N., & Goldszmidt, M.	1996	Building classifiers using Bayesian networks
Jara-Díaz, S., Martínez-Budría, E., Cortes, C., & Vargas, A.	1997	Marginal costs and scale economies in Spanish ports
Tebaldi, C., & West, M.	1998	Bayesian inference on network traffic using link count data
Cain, J.	2001	Planning improvements in natural resource management. guidelines for using Bayesian networks to support the planning and management of development programmes in the water sector and beyond
Bromley, J., Jackson, N. A., Clymer, O. J., Giacomello, A. M., & Jensen, F. V.	2005	The use of hugin® to develop Bayesian networks as an aid to integrated water resource planning
Janssens, D., Wets, G., Brijs, T., Vanhoof, K., Arentze, T., & Timmermans, H.	2006	Integrating Bayesian networks and decision trees in a sequential rule-based transportation model
Castillo, E., Menéndez, J. M., and Sánchez-Cambronero, S.	2008	Traffic estimation and optimal counting location without path enumeration using Bayesian networks
Castillo, E., Menéndez, J. M., & Sánchez-Cambronero, S.	2008	Predicting traffic flow using Bayesian networks
Trucco, P., Cagno, E., Ruggeri, F., & Grande, O.	2008	A Bayesian Belief Network modelling of organizational factors in risk analysis: A case study in maritime transportation
Klemola, E., Kuronen, J., Kalli, J., Arola, T., Hanninen, M., Lehtikoinen, A., ... & Tapaninen, U.	2009	A cross-disciplinary approach to minimizing the risks of maritime transport in the Gulf of Finland.
Kaluza, P., Kölzsch, A., Gastner, M. T., & Blasius, B.	2010	The complex network of global cargo ship movements.
Hofleitner, A., Herring, R., Abbeel, P., & Bayen, A.	2012	Learning the dynamics of arterial traffic from probe data using a dynamic Bayesian network
Cancelas, N. G., Flores, F. S., & Orive, A. C.	2013	Modelo de eficiencia de las terminales de contenedores del sistema portuario español
Camarero, A., González-Cancelas, N., Soler, F., & López, I.	2013	Utilización de redes bayesianas como método de caracterización de parámetros físicos de las terminales de contenedores del sistema portuario español
Flores, F. S., Cancelas, N. G., Orive, A. C., Gárate, J. L. A., & Monzón	2014	Diseño de un modelo de planificación de zonas de actividades logísticas mediante el empleo de redes bayesianas
Li, K. X., Yin, J., Bang, H. S., Yang, Z., & Wang, J.	2014	Bayesian network with quantitative input for maritime risk analysis

Redes neuronales artificiales

Las *redes neuronales artificiales* (RNA) son nuevas tecnologías en programación basadas en sistemas informáticos para el análisis y estudio del aprendizaje y procesamiento automático que se fundamentan en los sistemas neuronales de los animales. Estas tecnologías están basadas en el comportamiento del cerebro humano. Una RNA es un modelo computacional basado en la estructura y funciones de las redes neuronales biológicas. La información que fluye a través de la red afecta la estructura de la RNA, porque una red neuronal cambia - o aprende, en un sentido - sobre la base de la entrada y la salida.




Figura 3. Arquitectura de una red neuronal artificial. Fuente: Elaboración propia.

En las redes neuronales artificiales, la unidad fundamental es el elemento procesador, PE (*process element*). Este, está compuesto por un número determinado de variables de entrada y una o varias salidas.

El elemento procesador combina el conjunto de señales de entrada, mediante una suma normalmente, para procesar dicho resultado en una función de transferencia, denominada función de activación, que tendrá como resultado el valor de la señal de la variable de salida.

La interconexión de las neuronas se realiza con una determinada arquitectura (Figura 3). Cada conexión entre neuronas recibe un determinado peso que ponderará cada entrada. Con esto, la salida es la suma de las salidas de las neuronas que están conectadas a ella y multiplicada por el peso de cada conexión.

Las RNA se consideran las herramientas de modelado de datos estadísticos no lineales donde se ajustan las relaciones complejas entre entradas y salidas o se encuentran los patrones que las relacionan.

Estructura básica de una RNA

La estructura de la red neuronal se caracteriza por ser un conjunto de unidades elementales (elementos procesados) que se conectan de una forma concreta, hecho de gran relevancia en la RNA. Estos elementos procesados se organizan en niveles o capas, que es el conjunto de neuronas con entradas y salidas. Las entradas provienen de la misma fuente y las salidas se focalizan al mismo destino.

Los elementos a tener en cuenta en una estructura básica de una *red neuronal artificial* son los siguientes:

- » Unidad de proceso
- » Estado de activación
- » Función de salida o de transferencia
- » Conexiones
- » Propagación hacia adelante

- » Propagación hacia atrás
- » Regla de activación
- » Regla de aprendizaje

Modos de entrenamiento

El entrenamiento en una RNA se realiza con el objetivo de conseguir a través de la red diseñada, donde se han marcado unas entradas y unas salidas con unas reglas de interconexión y unos pesos en las mismas, unos resultados esperados o mínimamente sólidos.

Durante este entrenamiento los pesos de las interconexiones deben converger hacia los valores que cada entrada hace más acertada la salida deseada. Los algoritmos de entrenamiento, así como los procedimientos de ajuste de los valores dados a las conexiones de las RNA se clasifican principalmente en dos grandes grupos: entrenamientos supervisados y entrenamientos no supervisados principalmente (Matich, 2001 y Gestal, 2007).

Entrenamiento supervisado

Las redes neuronales de entrenamiento supervisado son las más populares. Los datos para el entrenamiento están constituidos por varios pares de patrones de entrenamiento de entrada y de salida.

El aprendizaje supervisado, requiere el emparejamiento de cada vector de entrada con su correspondiente vector de salida. El entrenamiento consiste en presentar un vector de entrada a la red, calcular la salida de la red, compararla con la salida deseada, y el error o diferencia resultante se utiliza para realimentar la red y cambiar los pesos de acuerdo con un algoritmo que tiende a minimizar el error, con el fin de conseguir que la salida se aproxime a la deseada.

Las parejas de vectores del conjunto de entrenamiento se aplican secuencialmente y de forma cíclica. Se calcula el error y el ajuste de los pesos por cada pareja hasta que el error para el conjunto de entrenamiento entero sea un valor pequeño y aceptable.

El aprendizaje supervisado, puede llevarse a cabo mediante tres formas:

- » Aprendizaje por corrección de error
- » Aprendizaje por refuerzo
- » Aprendizaje estocástico

El entrenamiento se realiza a través de un agente externo y consiste en presentar un vector de entrada a la red, calcular la salida, compararla con el objetivo deseado y utilizando el error para realimentar a la red volver a realimentar la red para conseguir el objetivo buscado reduciendo el error. De este modo se puede cambiar el peso con objeto de minimizar dicho error.

El error y ajuste de los pesos de cada pareja de vectores se calcula hasta que dicho error se considere lo suficientemente pequeño y aceptable.

Ese proceso se repite con todo el conjunto de entrenamiento, hasta que la red obtenga un error aceptable o ningún error. Al final del entrenamiento, cuando el aprendizaje de la red no converge, se aumenta el número de épocas de entrenamiento, se altera el número de neuronas de cada capa o el número de capas de la red.

Entrenamiento no supervisado

Los sistemas neuronales con entrenamiento supervisado han tenido éxito en muchas aplicaciones y sin embargo tienen muchas críticas debido a que desde el punto de vista biológico no son muy lógicos. Resulta difícil creer que existe un mecanismo en el cerebro que compare las salidas deseadas con las salidas reales.

Los sistemas no supervisados son modelos de aprendizaje más lógicos en los sistemas biológicos. Estos sistemas de aprendizaje no supervisado no requieren de un vector de salidas deseadas y por tanto no se realizan comparaciones entre las salidas reales y salidas esperadas.

El conjunto de vectores de entrenamiento consiste únicamente en vectores de entrada. El algoritmo de entrenamiento modifica los pesos de la red de forma que produzca vectores de salida consistentes. El proceso de entrenamiento extrae las propiedades estadísticas del conjunto de vectores de entrenamiento y agrupa en clases los vectores similares.

Se consideran dos tipos de aprendizaje no supervisado:

- » Aprendizaje hebbiano
- » Aprendizaje competitivo y cooperativo

El objetivo de este aprendizaje es que las informaciones similares formen parte de la misma categoría y por lo tanto activen la misma neurona de salida. Las categorías son creadas por la misma red, dado que es aprendizaje no supervisado.

Este tipo de entrenamiento no requiere agente externo para ajustar los pesos de las conexiones entre las neuronas.

Las redes con este tipo de entrenamiento encontrarán las relaciones en los datos de entrada únicamente con estos valores. El algoritmo de entrenamiento modificará los pesos de la red hasta producir valores de vectores de salida consistentes. La red aprende a adaptarse basándose en las experiencias recogidas de los patrones de entrenamiento anteriores

Se muestran a la red solo las entradas, dejando de lado las salidas deseadas. Se utiliza un esquema tal que, para cosas similares, la red responde de modo similar.

El objetivo de este tipo de aprendizaje es que los valores similares formen parte de una misma categoría y activen la misma neurona de salida. Estas categorías las genera la red al tratarse de un aprendizaje no supervisado.

Arquitectura de red

Se pueden distinguir varios tipos de arquitectura de *red neuronal artificial* (García Baez, 2006) en función de:

- » Las capas de entrada, ocultas y de salida
- » Conectividad entre las capas
- » Simultaneidad

Tipologías de RNA

Dentro de las posibilidades de redes neuronales artificiales, existen más de 50 modelos y variantes, en función del modelo de la neurona, la arquitectura de la red, el tipo

de conexión y el algoritmo de aprendizaje. Una clasificación por tipo de aprendizaje y arquitectura sobre la base de los criterios comentados hasta ahora sería la recogida en el Cuadro 2.

Cuadro 2. Modelos de redes por tipo de aprendizaje y arquitectura. Fuente: Elaboración propia

APRENDIZAJE	ARQUITECTURA	
	Unidireccional	Realimentada
Supervisado	Perceptrón Adalina Madalina Perceptrón multicapa BackPropagation General Regression Neural Net. Correlación en cascada Learning Vector Quantization Máquina de Boltzmann	BSB Fuzzy Cog Map
No supervisado	Linear Associative Memory Optimal LAM Maps of Kohonen Neocongnitron	ART Hopfield BAM

Las redes neuronales *feedforward* corresponden a la clase de RNA más estudiada por el ámbito científico y la más utilizada en los diversos campos de aplicación.

Las diferentes clases de RNA se distinguen entre sí por los siguientes elementos:

- » Las neuronas o nodos que constituye el elemento básico de procesamiento.
- » La arquitectura de la red descrita por las conexiones ponderadas entre los nodos.
- » El algoritmo de entrenamiento, usado para encontrar los parámetros de la red.

Del mismo modo que se hizo para el caso de las *redes bayesianas* y con objeto de intentar dar un enfoque de los trabajos realizados en general con RNA y relacionados con los sistemas de transportes en las últimas décadas se incluye una relación de los mismos en el Cuadro 3. Como se puede observar para este caso existen numerosos trabajos con este tipo de técnicas si bien son pocos los trabajos relacionados con el ámbito portuario. En estos trabajos se analizan las posibilidades y metodologías de trabajo de estos modelos de predicción. Al día de hoy estos modelos se encuentran en auge y están siendo de gran aceptación, como consecuencia de sus buenos resultados y diversidad de posibilidades.

Cuadro 3. Trabajos desarrollados con RNA en sistemas de transportes portuarios. Fuente: Elaboración propia

AUTORES	AÑO	TÍTULO
Stamenkovich M.	1991	An application of artificial neural networks for autonomous ship navigation through a channel
Lo Z. P. and Bavarian B.	1991	A neural piecewise linear classifier for pattern classification
Dougherty, M.	1995	A review of neural networks applied to transport
Shmueli, D., Salomon, I. & Shefer, D.	1996	Neural network analysis of travel behavior: Evaluating tools for prediction

AUTORES	AÑO	TÍTULO
Park, D. & Rilen, L.R.	1998	Forecasting multiple-period freeway link travel times using modular neural networks
Amin, S.M., Rodin, EY, Liu, A., Rink, K. & García-Ortiz, A.	1998	Traffic prediction and management via RBF Neural Nets and semantic control
Abdelwahab, W. & Sayed, T.	1999	Freight mode choice models using artificial neural networks
Yasdi, R.	1999	Prediction of road traffic using a neural network approach
Faghri, A., Aneja, S. & Vaziri, M.	1999	Estimation of percentage of pass - by trips generated by a shopping center using artificial neural networks
Hensher, D.A. & Ton, T.T.	2000	A comparison of the predictive potential of artificial neural networks and nested logic models for commuter mode choice
Sayed, T. & Razavi, A.	2000	Comparison of neural and conventional approaches to mode choice analysis
Qiao, F., Yang, H. & Lam, W.	2001	Intelligent simulation and prediction of traffic flow dispersion
Al-Deek, HM.	2001	Comparison between neural networks and multiple regression approaches for developing freight planning models with specific applications to sea-ports
Al-Deek, HM.	2001	Which method is better for developing freight planning models at seaports - Neural networks or multiple regression?
Huisken, G. & Van Berkum, E.	2002	Short-term travel time prediction using data from induction loops
Dharia, A. & Adeli, H.	2003	Neural network model for rapid forecasting of freeway link travel time
Vlahogianni, E.I., Golias, J.C. & Karlaftis, M.G.	2004	Short-term traffic forecasting: Overview of objectives and methods
Zhao, C., Liu, K & Lí, D.	2004	Freight volume forecast based on GRNN
Mostafa, M.M.	2004	Forecasting the Suez Canal traffic: a neural network analysis
Murat Celik, H.	2004	Modeling freight distribution using artificial neural networks
Vlahogianni, E.I., Karlaftis, M.G. & Golias, J.C.	2005	Optimized and meta-optimized neural networks for short-term traffic flow prediction: A generic approach
Jeong, R.H. & Rilett, L.R.	2005	Prediction model of bus arrival time for real time applications
Celikoglu, H.B. & Cigizoglu, H.K.	2007	Modeling public transport trips by radial basic function neural networks
Vlahogianni, E.I.	2009	Enhancing predictions in signalized arterials with information on short-term traffic flow dynamics
Tonum, A., Yayla, N. & Gokdag, M.	2009	The modeling of mode choices of intercity freight transportation with the artificial neural networks and adaptive neuro-fuzzy inference system
Gosasang, V., Chandraprakaikul, W. & Kiattisin, S.	2011	A comparison of traditional and Neural Networks forecasting techniques for container throughput at Bangkok port
Moscoso, J.A., Ruiz, J.J., Cerbán, MM.	2011	Técnicas de predicción en el tráfico Ro-Ro en el nodo logístico del estrecho de Gibraltar
Rodríguez G., T; González C., N; Soler F., F.	2013	Setting the port planning parameters in container terminals through artificial neural networks
Rodríguez G., T; González C., N; Soler F., F.	2013	Forecasts of container terminal capacity in a crisis scenario using Neural Networks

Comparativa entre los modelos de predicción

Los modelos de predicción basados en *redes bayesianas* y *redes neuronales artificiales* presentan unas características o capacidades singulares que hacen que estos modelos sean más o menos adecuados sobre la base del tipo de predicción que se desee obtener. Así mismo estos modelos presentan unas ventajas y desventajas más singulares que se adjuntan en el Cuadro 4.

Cuadro 4. Características, ventajas y desventajas de los modelos de predicción

	REDES BAYESIANAS	REDES NEURONALES ARTIFICIALES
Características / Capacidades más representativas de cada red	<p>Modelo probabilístico basado en un grafo acíclico dirigido.</p> <p>Se pueden realizar predicciones para planificación de transportes.</p> <p>Los valores obtenidos con la red son valores dentro de una discretización.</p> <p>Se pueden analizar numerosas variables y datos.</p> <p>Permiten obtener la variable <i>madre</i> que precede sobre las demás en cada caso particular.</p> <p>Los posibles sucesos se representan mediante un grafo.</p>	<p>Se pueden realizar predicciones para planificación de transportes.</p> <p>Los valores obtenidos en la red, son valores continuos.</p> <p>Se pueden analizar numerosas variables y datos.</p> <p>Inspiradas en modelos biológicos.</p> <p>Aprendizaje secuencial y adaptativo.</p> <p>Trabajan en paralelo en el caso de disponer de multiprocesadores (depende el hardware).</p> <p>Al igual que el funcionamiento del cerebro humano en caso de sufrir daños la red por fallos o destrucción de datos es capaz de seguir funcionando en modelo.</p>
Ventajas	<p>Presentan una clara interpretación.</p> <p>El modelo es más fácil de interpretar sobre la base de sus resultados.</p> <p>Son modelos sencillos de usar</p> <p>Su comportamiento es mejor para buscar una relación causal entre las variables.</p> <p>Permiten aprender sobre relaciones de dependencia y causalidad.</p> <p>Permiten combinar conocimiento con datos.</p> <p>Evitan el sobreajuste de los datos.</p> <p>Pueden manejar bases de datos incompletos.</p>	<p>Son modelos sencillos de usar.</p> <p>Estos modelos presentan mejores resultados como técnicas de predicción y diagnóstico.</p> <p>Su aprendizaje es adaptativo según su entrenamiento.</p> <p>Los resultados se pueden obtener en tiempo real.</p> <p>No es necesario elaborar modelos a priori ni especificar funciones de distribución de probabilidad.</p> <p>Son sistemas dinámicos auto-adaptativos.</p> <p>Autoorganización, lo que permite mayor comodidad al usuario.</p> <p>El sistema permite tolerancias de fallos que lo hacen más robusto en el procesamiento.</p>
Desventajas	<p>Existe la posibilidad de que se generen arcos de unión innecesarios.</p> <p>El método de razonamiento se basa en teorías matemáticas por lo que la comprensión del tipo de razonamiento es más difícil que en los modelos que imitan al razonamiento humano.</p> <p>Poca relación entre la forma de razonamiento humano y los métodos de razonamiento probabilístico.</p> <p>Métodos muy condicionados a las decisiones e interpretaciones de quien realiza el modelo.</p>	<p>En sus resultados no presentan razonamientos simbólicos, siendo este un razonamiento <i>oculto</i>.</p> <p>Los factores a considerar en la generación de la red (algoritmos de aprendizaje, neuronas por capa, nº de capas,...) se procesan de modo oculto y no permiten al usuario ver fácilmente qué y cómo se usa para la predicción final.</p> <p>Gran necesidad de recursos en procesamiento de la red según los objetivos y tipo de red, así como por el procesamiento de información en paralelo.</p>

Metodología

La metodología a emplear se subdivide a su vez en dos técnicas básicas que reflejan el modo de operar con este tipo de modelos de predicción que se comentan más adelante.

Estas técnicas pueden emplearse en los procesos de predicción con este tipo de modelos y que de hecho han sido utilizados por alguno de los autores mencionados (Rodríguez et al, 2013 y Camarero et al, 2013 entre otros).

Sistemática utilizada en los estudios de RNA

Fase I: Toma de datos, clasificación y discretización de los valores obtenidos de las terminales.

En esta primera fase se realiza un diagnóstico del estado actual de terminales de contenedores dentro de un ámbito geográfico de lo más variado y disperso en el entorno

de las terminales de contenedores y se recopilan, clasifican y ordenan los datos a procesar. El número de variables a considerar al tratarse de una red neuronal, puede ser casi infinito al poder trabajar con bases de datos de gran tamaño y número de campos.

Fase II: Construcción de la red neuronal artificial.

La construcción de la red neuronal artificial, se puede generar utilizando la aplicación informática Matlab. Se crea la red mediante un algoritmo de aprendizaje. La construcción de la red puede realizarse con cualquiera de las tipología comentadas anteriormente, si bien el resultado según qué tipología se escoja será distinto según los objetivos buscados, ya que los algoritmos de aprendizaje y estructura de la red son diferentes y el proceso de aprendizaje de la red es fundamentalmente lineal. Así mismo se asigna el método de entrenamiento, como partida inicial se definirán los parámetros iniciales del entrenamiento de la red (factor de aprendizaje, variable momento,...) mediante prueba y error o técnicas de inteligencia artificial. Una vez creada la red tras un proceso previo de simulación se entrena la misma presentando unas entradas y salidas conocidas de los datos obtenidos de las terminales de contenedores, con objeto de que la red vaya reajustando su salida mediante la modificación de sus pesos y valores umbrales, de manera que el error de actuación de la red se minimice.

Fase III: Análisis del funcionamiento de la red y de los resultados obtenidos

Antes de cualquier proceso, se debe definir el porcentaje de entrenamiento a considerar, es decir, que se debe indicar qué parte de los datos se consideran para el entrenamiento y cuáles para el test, con objeto de comprobar la efectividad del modelo. Habría que indicar que es aconsejable también realizar el entrenamiento con el 100% de los datos. Durante este proceso, también se define el número de épocas o el número de veces que se han comparado los ejemplos con las salidas de la red para realizar los ajustes en los pesos de las conexiones. Para el análisis de funcionamiento de la red se utilizan las variables de coeficiente de correlación (CC) y error cuadrático medio (MSE).

Fase IV: Validación de la red neuronal.

Una vez que se ha comprobado que las salidas de la red tras el entrenamiento se encuentran dentro de los parámetros considerados como aceptables (Coeficiente de correlación, error cuadrático medio,...), se valida la red. Este proceso de desarrollo de la *red neuronal* se realiza mediante una validación cruzada. Esta validación cruzada consiste dividir los datos de la muestra en dos grupos, donde el primer grupo se utiliza para entrenar a la red y el segundo para validar la red con objeto de comprobar la fiabilidad de la misma.

Fase V: Alcance del estudio.

En la última fase, una vez validada la red neuronal, se realiza un estudio pormenorizado de las distintas terminales de contenedores, evaluando el estado en que se encuentran y sus posibles necesidades a futuro.

Sistemática utilizada en los estudios de RB

Se divide en dos grandes tareas: una para determinar el escenario de trabajo y la segunda para desarrollar el modelo de inteligencia artificial.

Fase I: Determinación del escenario de trabajo.

En esta fase se realiza una diagnosis y estado del arte para identificar el conjunto de variables de medida de la explotación en terminales marítimas de contenedores

mediante el empleo de buscadores especializados y gestores de aplicaciones. Se determinan las variables de la terminal y se seleccionan las mismas obteniendo las variables de estudio.

Fase II: Desarrollo del modelo de inteligencia artificial.

El desarrollo del modelo que se realiza para obtener una red bayesiana a partir de datos es un proceso de aprendizaje que se divide en dos etapas: el aprendizaje estructural y el aprendizaje paramétrico. La primera de ellas consiste en obtener la estructura de la red bayesiana, es decir, las relaciones de dependencia e independencia entre las variables involucradas. La segunda etapa tiene como finalidad obtener las probabilidades a priori y condicionales requeridas a partir de una estructura dada. Para obtener el modelo se realiza una discretización de las variables donde una vez seleccionadas las variables de estudio se realiza la discretización que puede ser mediante métodos supervisados o no supervisados sobre la base del software a utilizar, posteriormente se plasma la construcción del modelo donde se encuentran las relaciones de dependencia entre las variables de forma que se pueda determinar la topología o estructura de la red bayesiana. Por último se estudia la inferencia y clasificación entre los nodos, donde una vez encontradas nuevas evidencias sobre el estado de ciertos nodos, se modifican sus tablas de probabilidad; y a su vez, las nuevas probabilidades son propagadas al resto de los nodos.

A partir de la red construida mediante inferencia se pueden obtener las probabilidades que pueden adoptar las discretizaciones de las diferentes variables, ello permite obtener escenarios eficientes de manera que si la eficiencia, se entiende como la capacidad de alcanzar los objetivos programados con el mínimo de recursos disponible, logrando así su optimización, se obtienen diferentes escenarios para los diferentes nodos.

Ejemplos de análisis con RB y RNA en puertos con terminales de contenedores

En varios trabajos entre los años 2013 y 2015 (Rodríguez et al, 2013), se han realizado estudios del comportamiento con modelos de *redes bayesianas* y de *redes neuronales artificiales* en el caso de predicción a corto plazo en puertos con terminales de contenedores. Debido a la limitación de extensión del documento, se resumen a continuación algunos de los resultados obtenidos en dichos estudios. Se invita a los lectores que deseen ampliar información a consultar dichos estudios de estos autores y que se incluyen en las referencias.

Estos trabajos se han analizado con estas técnicas de predicción basándose en datos de 33 puertos a nivel internacional entre los años 2003 y 2013. Los puertos analizados han sido: Brisbane, Vancouver, Antofagasta, Iquique, San Antonio, Valparaíso, Qingdao, Shanghái Total, Xiamén, Tianjin, Yantián, Busán, Kwangyang, Guayaquil, Acajutla, , Puerto Quetzal, Hong Kong KCTY, Hong Kong RTT, Yokohama, Ensenada, Lázaro Cárdenas, Manzanillo, Balboa, Callao, Singapur, Kaohsiung, Keelung, Long Beach, Los Ángeles, Oakland, Seattle, Tacoma, y Portland

Las variables y algunos de los datos de los puertos seleccionados tanto para el caso de los estudios con RNA como con RB son los incluidos en el Cuadro 5. En este cuadro debido a su gran extensión se incluyen solo a título de ejemplo algunos datos del año 2003, si bien en el proceso se han utilizado todos los relativos entre los años 2003 y 2013.

Cuadro 5. Ejemplo de clasificación de variables y datos utilizados en el estudio. Fuente: Elaboración propia

Date	Cod_port	Cod_country	Long_berth	Term_surface	Cranes	TEU
2003	1	1	1.610,00	48,50	9,00	639.570,00
2003	2	2	3.803,00	158,33	46,00	1.539.058,00
2003	3	3	1.230,00	1,50	14,00	47.266,00
2003	4	3	3.143,00	5,38	2,00	135.267,00
2003	5	3	1.155,00	37,14	10,00	524.376,00
2003	6	3	2.611,00	23,54	14,00	319.368,00
2003	7	4	3.367,00	113,60	48,00	1.332.746,00
2003	8	4	2.281,00	82,50	64,00	11.280.000,00
2003	9	4	1.110,00	71,50	27,00	2.331.000,00
2003	10	4	2.450,00	100,44	20,00	3.015.000,00
2003	11	4	2.350,00	118,00	30,00	5.258.106,00
2003	12	5	11.040,00	301,33	120,00	10.407.809,00
2003	13	5	700,00	42,00	14,00	1.184.842,00
2003	14	6	1.515,00	23,50	5,00	468.599,00
2003	15	7	270,00	4,90	3,00	65.576,00
2003	16	8	400,00	47,80	3,00	174.108,00
2003	17	9	5.754,00	217,00	67,00	13.100.000,00
2003	18	9	3.000,00	65,00	30,00	5.919.000,00
2003	19	10	5.440,00	173,36	88,00	2.504.627,00
2003	20	11	486,00	70,00	4,00	44.836,00
2003	21	11	286,00	18,50	6,00	1.646,00
2003	22	11	2.205,00	30,80	24,00	709.209,00
...

Entre las bases de datos a consultar a nivel internacional para puertos y en concreto para obtener variables de las terminales portuarias se analizaron las siguientes bases de datos de organismos, autoridades portuarias, gobiernos, instituciones gubernamentales, consultoras, asociaciones,...

Algunas de las bases de datos o estadísticas a consultar para trabajos de esta índole son las siguientes:

- » Autoridades portuarias o puertos analizar en el estudio
- » Organismos nacionales (Gobiernos, entes públicos,...)
- » Organizaciones supranacionales y comisiones (COTRACAM, CAN, CIP, OEA, CEPAL, UNCTAD, OAS, MPB, ...)
- » Consultoras (Drewry Shipping Consultants, Ocean Shipping Consultants, Lloyds, IPC, ...)
- » Asociaciones internacionales (IAPH, WSC, BPO, ESPO, PIANC, AAPA, IMO, ...)
- » Revistas y publicaciones del sector (JOC, Maritime journal, Worldofshipping,...)

En el trabajo de análisis se ha partido de las siguientes premisas:

- » No se invierte en ningún activo, obteniendo los TEU a corto plazo. Se analizan los resultados que deben ser análogos a los esperados por organismos internacionales

Una vez desarrollados los modelos de predicción con las fases comentadas en la metodología se obtienen los siguientes resultados.



Figura 5. Previsiones de tráfico en puertos y su posible saturación. Fuente: Elaboración propia



Figura 6. Previsiones de necesidades de grúas en puertos. Fuente: Elaboración propia

Resultados con redes neuronales artificiales

Para el caso de ejemplo los algoritmos de la red han sido:

- » *Training*: Gradiente Descent Backpropagation with Adaptive Learning Rate
- » *Performance*: Mean Squared Error

Para el entrenamiento de la red se realizan varias repeticiones variando el porcentaje de *training-test* (50-50, 70-30, 90-10, 100), con objeto de comprobar la variación del comportamiento de la red y su validación.

Los ajustes realizados mediante el error cuadrático medio MSE y las distintas comparaciones de correlación, muestran resultados de aproximación con una media por encima del 80% y nunca menor del 70%.

Para este estudio se han considerado dos etapas:

- » 1ª Etapa: la obtención de TEU en tiempos de crisis. Para el caso de la obtención de los TEU que se pueden mover en los puertos con los activos actuales, dando como entrada las variables *area*, *berth* y *crane* de los mismos, estimando los TEU que se pueden mover a corto plazo.

Con los resultados de esta primera etapa se pueden obtener los puertos que pueden aumentar los tráfico con base en los activos que disponen y los TEU que están moviendo y pueden mover en un corto plazo.

- » 2ª Etapa: a través del *input area*, *berth* y TEU, adquiriendo los TEU de las previsiones de organismos internacionales y obteniendo como output de la red las grúas necesarias para operar ese tráfico.

De este modo se comprueba con base en los activos (grúas) de que disponen los puertos que son capaces de mover los TEU previstos por estos organismos y los que no, valorando por tanto la previsible saturación de los mismos.

En la Figura 5 se pueden observar los puertos que pueden aumentar tráfico con los activos actuales sin realizar inversión alguna y en la Figura 6 aquellos que están próximos a la saturación con base en las previsiones de TEU de organismos internacionales.

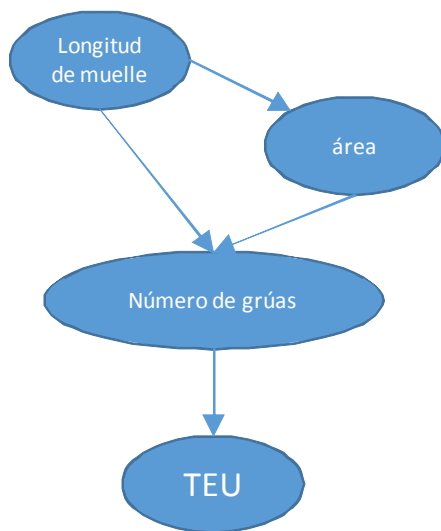


Figura 7. Relación causal de la red. Fuente: Elaboración propia

Por tanto, en los estudios realizados con *redes neuronales artificiales* se han estimado los TEU que se pueden manipular a corto plazo en los puertos objeto del estudio para el caso de no realizar ninguna inversión en activos como se comentó anteriormente. Con este estudio se comprueban los puertos que se encuentran saturados, los que están próximos a la saturación y que disponen de mayor capacidad con los medios de que disponen actualmente (Figura 5).

Por otro lado se analizan las necesidades de equipos, en este caso número de grúas, necesarias para poder gestionar los TEU estimados a corto plazo por organismos internacionales con objeto de poder determinar las posibilidades con los medios actuales, así como las necesidades a corto plazo.

Resultados con redes bayesianas

Para la realización de este estudio se ha realizado una discretización de los estratos para las variables seleccionadas en la investigación (longitud de muelle, área, número de grúas y TEU movidos) y que han servido para analizar los escenarios planteados. La discretización de los valores se ha realizado en intervalos determinados por los percentiles 25, 50 y 75, obteniendo los valores reflejados en el Cuadro 6.

Cuadro 6. Variables y percentiles utilizados en la red. Fuente: Elaboración propia

Variable	P ₂₅	P ₅₀	P ₇₅
Berth(m)	1.480	3.000	5.100
Área (ha)	31,8	80,6	208
Crane number	11	26,5	62
TEU number	524.791	1.892.231	6.709.818

Durante el proceso de generación de la red bayesiana, se ha obtenido la relación causal donde la variable longitud de muelle ha resultado ser la variable principal de planificación, al depender el resto de variables de ella (Figura 7).

A partir de la red construida mediante inferencia obtienen las probabilidades que pueden adoptar las discretizaciones de las diferentes variables, lo que permite obtener escenarios eficientes para las terminales de contenedores de manera que si la eficiencia, se entiende como la capacidad de alcanzar los objetivos programados con el mínimo de recursos disponible, logrando así su optimización, se obtienen diferentes escenarios para los diferentes *crane number*.

Los diferentes escenarios corresponden a las discretizaciones de la variable *crane number*; S1 corresponde a disponer de menos de 11 grúas; S2 a disponer de entre 11 a 26 grúas; S3 entre 26 y 62; y S4 disponer de más de 64 grúas. Para el caso de no realizar inversiones en la línea de atraque: *berth*. Los diferentes escenarios corresponden a las discretizaciones de la variable *berth*: S1 corresponde a disponer de menos de 1480 metros de línea de atraque; S2 a disponer de entre 1.480 y 3.000 metros de línea de atraque; S3 entre 3.000 y 5.100; y S4 disponer de más de 5.100 metros de línea de atraque. Para el caso de no realizar inversiones en el área: *area*. Los diferentes escenarios corresponden a las discretizaciones de la variable *area*: S1 corresponde a disponer de menos de 31,8 hectáreas; S2 a disponer de entre 31,8 y 80,6 hectáreas; S3 entre 80,6 y 208; y S4 disponer de más de 208 hectáreas.

Analizadas cada una de las variables y estratos para el caso de no inversión en activos, no invertir en grúas, no invertir en línea de atraque y no invertir en área, se ha comprobado que los estratos que presentan un mejor comportamiento o probabilidad, son los estratos comprendidos en los rangos que se indican a continuación (Cuadro 6).

Cuadro 6. Variables y estratos de discretización que presentan mejor comportamiento.

Fuente: Elaboración propia

VARIABLE	ESTRATOS DE DISCRETIZACIÓN	
	S ₁	S ₄
Berth(m)	< 1480	> 5.100
Área (ha)	< 31,8	> 208
Crane number	< 11	> 62
TEU	< 524.791	> 6.709.818

Conclusiones

Analizadas las necesidades generadas en el tiempo y concretamente en estos momentos de crisis, las nuevas situaciones que se pueden presentar a corto/medio plazo, la masiva generación de datos y la necesidad de procesamiento de dichos datos con objeto de planificar correctamente en los sistemas de transportes portuarios y en concreto en los puertos con terminales de contenedores donde el crecimiento y necesidades de actuación se presentan necesarias, podemos indicar las siguientes conclusiones:

- » Resulta necesario estimar los tráficos y activos, principalmente a corto/medio plazo, con objeto de optimizar recursos, minimizar costes e invertir de modo adecuado. Este hecho se ve acentuado en épocas de crisis donde las posibilidades de inversión se ven mermadas.
- » Existen técnicas de predicción basadas en la minería de datos, como son principalmente las *redes bayesianas* y las *redes neuronales artificiales* que siendo técnicas novedosas y adecuadas para la estimación de parámetros y estados o necesidades futuras en los puertos y los sistemas de transportes, presentan grandes y prometedoras posibilidades en este campo.
- » Con los modelos de RNA, se logra determinar cuáles son los puertos próximos a la saturación y conocer las necesidades de grúas según las previsiones de tráfico publicadas por organismos internacionales en el caso y por tanto se pueden indicar los puertos donde es o no es necesario realizar nuevas inversiones en grúas con la previsión de tráficos de los organismos internacionales.

- » En los modelos realizados con RB, se pueden obtener las relaciones causales entre las variables del estudio, donde se puede obtener la variable principal, todas serán *efecto* de ella, esta es la variable principal de planificación. Así mismo, se pueden obtener para los distintos escenarios planteados cuáles son los estratos de discretización que presentan un mejor comportamiento y por tanto poder estimar posibles necesidades o actuaciones a desarrollar para una mejor planificación.
- » Los resultados obtenidos en estudios recientes invitan a seguir experimentando estas técnicas para que en un futuro se consoliden estas herramientas y sirvan a los agentes encargados de la planificación y logística en estos sistemas de transportes para desarrollarlas como complemento de las técnicas tradicionales. Al día de hoy este hecho ya se está produciendo en algunos puertos internacionales como sucede en los puertos de la región de Valparaíso.

Bibliografía

- » AL-DEEK, Haitham M. (2001) Comparison between neural networks and multiple regression approaches for developing freight planning models with specific applications to sea-ports. *80th annual meeting of the transportation research board*. Washington, DC.
- » ALFA, Attahiru Sule (1986) A review of models for the temporal distribution of peak traffic demand. *Transportation Research Part B: Methodological* vol. 20 n° 6, pp. 491-499.
- » BAR-GERA, Hillel and BOYCE, David (2003) Origin-based algorithms for combined travel forecasting models. *Transportation Research Part B: Methodological* vol. 37, n° 5, pp. 405-422.
- » BÖSE, Jürgen W. (2011) *Handbook of terminal planning*. Hamburg, Germany, Vol. 49. Springer Science & Business Media.
- » BOX, George Edward Pelham and JENKINS, Gwilym Meirion (1973) Some comments on a paper by Chatfield and Prothero and on a review by Kendall. *Journal of the Royal Statistical Society. Series A (General)*, vol. 136 n° 3, pp. 337-352.
- » CAIN, Jeremy (2001) *Planning improvements in natural resource management. Guidelines for using bayesian networks to support the planning and management of development programmes in the water sector and beyond*. Wallingford, Oxon: CEH Wallingford
- » CAMARERO, Alberto y GONZÁLEZ, M^a Nicoletta (2007) *Logística y transporte de contenedores*. Madrid, España: Fundación Agustín de Betancourt. Ministerio de Fomento.
- » GARBOLINO, Paolo and TARONI, Franco (2002) Evaluation of scientific evidence using bayesian networks. *Forensic Science International*, vol. 125 n° 2, pp. 149-155.
- » GARCÍA-BAEZ, Patricio (2006). Introducción a las redes neuronales y su aplicación a la investigación astrofísica. *Instituto de Astrofísica de Canarias*. Santa Cruz de Tenerife, España
- » GESTAL POSE, Marcos DORADO, Julián, FERNÁNDEZ-BLANCO Enrique (2007). Redes de neuronas artificiales y computación evolutiva. Publicado En: *Tecnologías de la Información y las Comunicaciones en Ingeniería Civil*. ISBN 84-934497-7-6, pp. 41-64. Fundación Alfredo Brañas. Santiago de Compostela, A Coruña (España).
- » GOLIAS, John (2002) Analysis of traffic corridor impacts from the introduction of the new Athens Metro system. *Journal of Transport Geography*, vol. 10, n° 2, pp. 91-97.
- » GONZÁLEZ, M^a Nicoletta (2007) *Metodología para la determinación de parámetros de diseño de terminales portuarias de contenedores a partir de datos de tráfico marítimo*, Tesis en Universidad Politécnica de Madrid.
- » GONZÁLEZ, M^a Nicoletta y CAMARERO, Alberto (2009) Caracterización de parámetros físicos de las terminales de contenedores del sistema portuario español. *Ingeniería y Ciencia*, vol. 10 n° 49, pp. 54-67.
- » HENSHER, David Alan and TON, Tu That (2000) A comparison of the predictive

potential of artificial neural networks and nested logit models for commuter mode choice. *Transportation Research Part E: Logistics and Transportation Review*, vol. 36 nº 3, pp. 155-172.

- » JOVICIC, Goran and HANSEN, Christian Overgaard (2003) A passenger travel demand model for Copenhagen. *Transportation Research Part A: Policy and Practice*, vol. 37 nº4, pp.333-349.
- » KULSRESHTHA, Mudit, and NAG, Barnali (2000) Structure and dynamics of non-suburban passenger travel demand in Indian railways. *Transportation*, vol. 27 nº2, pp. 221-241.
- » MARTÍN ALCALDE, Enrique (2008) *Optimización de la operativa del subsistema de recepción y entrega en terminales portuarias de contenedores*. Tesis Doctoral en la Universidad Politécnica de Cataluña. Barcelona. <http://hdl.handle.net/2099.1/5906>.
- » MARTÍNEZ LÓPEZ, Ignacio y RODRÍGUEZ TORREBLANCA, Carmelo (2003) Modelos gráficos. En Y. del Águila et al. (Eds.), *Técnicas estadísticas aplicadas al análisis de datos*. Almería: Servicio de Publicaciones de la Universidad de Almería, pp. 217-257.
- » MATICH, Jorge (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Tecnológica Nacional.
- » NADKARNI, Sucheta and SHENOY, Prakash P. (2001) A bayesian network approach to making inferences in causal maps. *European Journal of Operational Research*, vol.128 nº 3, pp. 479-498.
- » NADKARNI, Sucheta and SHENOY, Prakash P. (2004) A causal mapping approach to constructing bayesian networks. *Decision Support Systems*, 38, 259-281.
- » PÉRTIGA DÍAZ, Sonia y PITA FERNÁNDEZ, Salvador (2000) *Técnicas de regresión: Regresión Lineal Múltiple*. Cad. Aten Primaria, 7.
- » RODRÍGUEZ GARCÍA, Tomás, GONZÁLEZ CANCELAS, Nicoletta and SOLER FLORES, Francisco (2013) Setting the port planning parameters in container terminals through artificial neural networks, *Global Virtual Conference*. <http://www.gv-conference.com/archive/?vid=1&aid=2&kid=30101-9>
- » RODRÍGUEZ GARCÍA, Tomás, GONZÁLEZ CANCELAS, Nicoletta and SOLER FLORES, Francisco (2013) The Artificial Neural Networks to obtain port planning parameters, *Procedia-Social and Behavioral Sciences*. DOI: 10.1016/j.sbspro.2014.12.197
- » RODRÍGUEZ GARCÍA, Tomás, GONZÁLEZ CANCELAS, Nicoletta and SOLER FLORES, Francisco (2013) Forecasting models in ports transport systems: Are ANNs Applications the solution? *Proceedings in EIIIC - The 2nd Electronic International Interdisciplinary Conference*, EDIS - Publishing Institution of the University of Zilina, Eslovaquia.
- » ROJO, José Manuel (2007) *Regresión lineal múltiple*. Instituto de Economía y Geografía. Consultado el, 10.
- » STEENKEN, Dirk, VOß, Stefan and STAHLBOCK, Robert (2004) Container terminal operation and operations research-a classification and literature review. *OR spectrum*, 26(1), 3-49.
- » TSEKERIS, Theodore and STATHOPOULOS, Antony (2006) Gravity models for dynamic transport planning: Development and implementation in urban networks. *Journal of Transport Geography*, 14(2), 152-160.

- » VARAGOULI, Giannis, SIMOS, Theodore and XEIDAKIS, Georgios (2005) Fitting a multiple regression line to travel demand forecasting: The case of the prefecture of Xanthi, Northern Greece. *Mathematical and Computer Modelling*, vol. 42, no. 7, pp. 817-836
- » WARDMAN, Mark (2006) Demand for rail travel and the effects of external factors. *Transportation Research Part E: Logistics and Transportation Review*, 42(3), 129-148.

Tomás Rodríguez García

Doctor Ingeniero de Caminos, Canales y Puertos por la Escuela Técnica Superior de Ingenieros de Caminos, Canales y Puertos de la Universidad Politécnica de Madrid. Profesor Asociado en el Departamento de Ingeniería Civil- Infraestructuras del transporte, en la Escuela Técnica Superior de Ingeniería Civil de la Universidad Politécnica de Madrid.