

# PREDICCIÓN DEL RIESGO DE LESIONES MÚSCULO-ESQUELÉTICAS EN EL LEVANTAMIENTO DE CARGAS MEDIANTE REDES NEURONALES

Sabina Asensio-Cuesta

José A. Diego-Mas,

Jorge Alcaide Marzal

*Universidad Politécnica de Valencia*

## Abstract

This paper describes a new neural network model applied to classifying the risk of low back disorders presented by certain lifting jobs. The neural network obtained can be used by the ergonomist as a diagnostics system, enabling jobs to be classified into two categories (low-risk and high-risk) according to the associated likelihood of causing low back disorders. This system provides a higher proportion of correct classifications (81.6%) than other previous models.

The development process of neural networks for classification problems and the influence of network architecture on its prediction and generalisation capabilities are analysed. So it is the phenomenon of overfitting and its relationship to the number of network connections and the size of the training data set. The new approach uses complex architecture networks and procedures for avoiding overfitting. It is compared with previous works and its results and advantages over them are discussed. The neural network obtained has been implemented in a software application focused on risk analysis and prevention of the injuries caused by tasks involving manual lifting in the industrial environment.

**Keywords:** *artificial neural networks; low-back disorders; ergonomic assessment*

## Resumen

Se presenta un modelo basado en redes neuronales para la predicción del riesgo de padecer trastornos músculo-esqueléticos asociado a puestos de trabajo con tareas de levantamiento de carga. El modelo resulta útil al ergónomo como sistema de diagnóstico, permitiendo clasificar los puestos de trabajo en dos categorías (alta y baja) en función del riesgo de provocar trastornos músculo-esqueléticos en la parte baja de la espalda. La proporción de clasificaciones correctas de este sistema es superior a los de otros modelos alcanzando el 81,6%.

Se analiza el proceso de desarrollo de redes neuronales para problemas de clasificación, las implicaciones de la arquitectura de la red en su capacidad de predicción y generalización, el fenómeno del sobre-entrenamiento y su relación con el número de conexiones de la red y el tamaño del set de datos de entrenamiento. El enfoque de este trabajo, basado en el uso de redes de arquitectura compleja y procedimientos para evitar el sobre-entrenamiento, es comparado con trabajos precedentes y sus resultados y ventajas respecto a estos son discutidos. La red neuronal obtenida ha sido implementada en un software útil en el análisis del riesgo y la prevención de las lesiones debidas al manejo de cargas en entornos industriales.

**Palabras clave:** *redes neuronales; trastornos músculo-esqueléticos; evaluación ergonómica*

## 1. Introducción

Los modelos matemáticos que permiten predecir la aparición de trastornos músculo-esqueléticos en la parte baja de la espalda (LBDs) a partir de datos obtenidos de estudios epidemiológicos son una herramienta de diagnóstico valiosa para los ergónomos. Sin embargo, el desarrollo de estos modelos no es una labor sencilla debido, por una parte, a la dificultad de la obtención de los datos, y por otra, a la dificultad de generar modelos suficientemente precisos. Por ejemplo; aunque existen múltiples estudios que tratan de determinar qué factores de riesgo están implicados en la aparición de LBDs (Eldersa y Burdorf, 2001; Magora, 1970; National Institute for Occupational Safety and Health, 1981; Neumann et al., 2001a, 2001b; Okunribido, 2006), no existe pleno consenso en la literatura respecto a cuáles son los factores relevantes ni sobre la forma en que éstos interactúan para provocar el riesgo (Battie et al., 1990; Bigos et al., 1986; Dempsey, 1998; Marras et al., 1993, 1995). Por otra parte, la capacidad predictiva de los modelos matemáticos está condicionada por la precisión y la cantidad de los datos obtenidos en el trabajo de campo. En general, es necesario tomar un gran número de muestras sobre el terreno y que las mediciones sean realizadas con suficiente fiabilidad para que el modelo obtenido resulte válido.

Los modelos más comúnmente empleados para desarrollar herramientas de diagnóstico que predigan la aparición de LBDs se basan en técnicas estadísticas (habitualmente regresiones logísticas y modelos aditivos generalizados) (Marras et al., 1993, 1995; Dempsey et al., 1995; Dempsey and Westfall, 1997) o en redes neuronales artificiales (ANNs) (Karwowski et al., 1994; Nussbaum y Chaffin, 1996; Zurada et al. 1997; Chen et al., 2000, 2004). En estos estudios la capacidad predictiva de los modelos basados en ANNs es mayor que la de los basados en métodos estadísticos para el problema de los LBDs. Sin embargo, esto no implica que las ANNs sean superiores a las técnicas estadísticas tradicionales (Sarle, 1997) y, en general, cada método estadístico es equivalente a algún tipo de ANN (Bishop, 1995). No obstante, el empleo de las ANNs se está generalizando, más que por su superioridad para la modelización, por su forma más cómoda y conveniente de abordar el problema y por su mayor simplicidad y rapidez en el cómputo de los valores predichos (Sarle, 1997). Independientemente de la forma de obtención de un modelo para predecir la aparición de LBDs, su validez dependerá de los factores de riesgo considerados y de la cantidad y precisión de los datos disponibles para relacionar esos factores con el nivel de riesgo realmente existente.

Para obtener una ANN adecuada para clasificar los puestos de acuerdo con su riesgo de provocar LBDs es necesario determinar cuáles de las variables experimentales recogidas en el trabajo de campo resultan significativas y, por tanto, deben ser empleadas como entradas al modelo. Además, es necesario establecer la arquitectura de la red más conveniente, es decir, el número de capas de neuronas que la conforman, el número de neuronas por capa, la función de activación de las neuronas, y establecer la regla de aprendizaje a emplear, los pesos iniciales de las conexiones sinápticas, y otros parámetros que condicionarán en gran medida la validez del modelo obtenido. Sin embargo, no existe un procedimiento sistemático que permita establecer las características de la red más adecuadas para el problema que se quiere resolver, y aunque se conocen ciertas reglas genéricas sobre cómo afectan las características de la red a su comportamiento, en general es difícil justificar la elección de una arquitectura determinada.

Zurada et al. (1997) desarrolló un modelo para predecir la aparición de LBDs a partir de cinco variables que representaban factores de riesgo, basándose en datos experimentales

recogidos en Marras et al. (1993). Posteriormente, en Chen et al. (2000), y empleando los mismos datos experimentales, se usa un procedimiento heurístico que trata de determinar cuáles de las 5 variables de los puestos de trabajo analizados en Marras et al. (1993) resultan realmente significativas en el modelo neuronal, y cuáles pueden ser eliminadas. Este procedimiento determina, además, el número adecuado de neuronas en la única capa oculta del modelo. Los mismos autores, en Chen et al. (2004) presentan un nuevo procedimiento que permite obtener resultados similares con un set de datos más reducido o incompleto.

En los estudios anteriores los autores trataron de emplear ANNs con pocas neuronas y con una única capa oculta para evitar el *overfitting*. El *overfitting* (también denominado *overtraining*) tiene lugar cuando el modelo captura el ruido estadístico de los datos en lugar de la señal subyacente (Sarle, 1997), es decir, el modelo comienza a memorizar las respuestas adecuadas a cada patrón de entradas en lugar de aprender las relaciones entre las entradas y las salidas. Cuando esto ocurre, el modelo produce resultados muy precisos con los datos empleados para entrenar a la red, pero es incapaz de generalizarlos a nuevos casos. En general, este fenómeno aparece cuando el número de conexiones internas de la red es excesivamente grande en comparación con el tamaño del set de datos de entrenamiento disponible. Reduciendo el número de neuronas se reduce el número de conexiones entre ellas, por lo que es menos probable el *overfitting*. Como contrapartida, disminuir el tamaño de la red disminuye su capacidad para establecer con precisión las relaciones entre las entradas y salidas del modelo. Por otra parte, una red con un gran número de elementos de proceso tiene una mayor tolerancia a fallos como la presencia de ruido en los datos de entrada, o la desconexión de alguno de los enlaces de la red.

Existen procedimientos para evitar el *overfitting* manteniendo un tamaño de red grande que permita un alto grado de generalización y una alta tolerancia a fallos. El objetivo del presente trabajo es doble: por un lado obtener un modelo basado en ANNs que permita clasificar los puestos de trabajo de acuerdo a su riesgo de provocar LBDs cuyos resultados mejoren los de trabajos previos, y por otro, comprobar que el empleo de ANNs con un número grande de elementos de proceso puede alcanzar un elevado ajuste y un mayor grado de generalización que una red de menor tamaño si se emplean los mecanismos adecuados para evitar el *overfitting*. La ANN obtenida como resultado de este trabajo es una red de topología compleja, con dos capas ocultas y un número elevado de enlaces entre las neuronas en relación al número de patrones de entrenamiento disponibles, que proporciona mejores resultados que la de trabajos precedentes.

En las secciones siguientes se exponen las bases de funcionamiento y desarrollo de las ANNs, se aborda el problema del *overfitting*, se muestra la aplicación de las ANNs al problema los LBDs en trabajos previos, se presenta el procedimiento seguido y el modelo desarrollado en este trabajo y, por último, se presentan y discuten los resultados.

## 2. Redes Neuronales Artificiales

Una ANN es un modelo matemático cuyo funcionamiento se inspira en el modo de operar de las redes neuronales naturales. Se trata de sistemas adaptativos distribuidos construidos mediante múltiples elementos de procesamiento interconectados. Las ANNs son empleadas en muchos campos de investigación (psicología, robótica, biología, informática...) (Marren et al., 1990; Principe et al., 2000) debido a su capacidad para adaptarse, aprender, generalizar o organizar y clasificar datos.


En las FeedForward Neural Networks (FNN) los elementos de proceso (neuronas) están distribuidos en diversas capas (Figura 1). La primera capa es denominada capa de entrada, la última, capa de salida, y las intermedias, capas ocultas. Generalmente, cada elemento de procesamiento recibe señales procedentes de las neuronas de la capa precedente a través

de las conexiones y las transmite a las neuronas de la capa siguiente tras procesarlas. El número de capas y la forma en que las neuronas están conectadas determinan la arquitectura de la red.

Las señales de entrada ( $i_1, i_2, \dots, i_n$ ) son los valores de las variables que representan un caso del fenómeno que se quiere modelizar. Las entradas son recogidas por la capa de entrada que las transmiten a las neuronas de la primera capa oculta a través de los enlaces. Las señales son escaladas en cada enlace en función de un parámetro ajustable denominado peso asociado a cada conexión entre neuronas. Habitualmente el peso inicial de cada enlace es establecido aleatoriamente. Cada neurona de la primera capa oculta recoge las señales de las conexiones, las suma, y produce una salida que es función del sumatorio de las señales recibidas. Las funciones más comúnmente empleadas son sigmoideas, tangentes hiperbólicas y versiones lineales de estas últimas. Las señales recorren la red desde la capa de entrada hasta la capa de salida, en la que se recoge la respuesta de la red a las entradas presentadas ( $o_1, o_2, \dots, o_m$ ).

Las redes de aprendizaje supervisado son capaces de aprender las relaciones entre las entradas y las salidas mediante la presentación reiterada de datos de entrada y los valores de las correspondientes salidas. Una vez entrenadas, pueden generalizar estas relaciones a nuevos casos no vistos anteriormente. El proceso de entrenamiento consiste en presentar a la red un número suficiente de casos en la entrada y los valores deseados en las salidas. La salida obtenida por la red en cada caso es comparada con la salida deseada, calculándose el error cometido por la red. Una vez calculado el error, los pesos de las conexiones entre las neuronas son modificados según el algoritmo de entrenamiento escogido. Este proceso se repite hasta que se alcanza un criterio previamente establecido, por ejemplo, que se alcance una cota superior en el error o que el error deje de decrecer. Los algoritmos de entrenamiento modifican los pesos de las conexiones entre las neuronas tratando de minimizar el error cometido por el modelo. Aunque existen diferentes algoritmos de entrenamiento aplicables a diversos tipos de redes, el tipo más comúnmente empleado para entrenar las FNN es el Back-Propagation (BP) (Rumelhart y McClelland, 1986). Básicamente, el algoritmo BP funciona de la siguiente forma: calculado el error cometido por la red ante una determinada entrada, los pesos de las conexiones entre las neuronas de la última capa oculta y la capa de salida son modificados en función del grado en que dicha conexión ha contribuido a la generación del error. Este procedimiento se lleva a cabo con cada capa hasta llegar a la capa de entrada.

**Figura 1: Ejemplo de la estructura de una red neuronal**



El BP es un procedimiento de gradiente descendiente que, idealmente, requeriría que las variaciones en los pesos de las conexiones fueran infinitesimales. De forma práctica se emplea un parámetro, la tasa de aprendizaje, que determina la magnitud de las variaciones

de los pesos. La tasa de aprendizaje debe ser escogida cuidadosamente, una tasa excesivamente pequeña prolongaría el tiempo necesario para lograr la convergencia y una tasa demasiado alta provocaría la oscilación del algoritmo. Para evitar las oscilaciones se emplea otro parámetro, el momentum, que proporciona al algoritmo cierta inercia. El momentum hace que los cambios de los pesos sean dependientes de las magnitudes de los cambios en iteraciones precedentes.

## 2.1 Proceso de desarrollo de redes neuronales

El desarrollo de un modelo basado en FNN para resolver un problema de clasificación comienza determinando las variables que, a priori, parecen influir en el fenómeno que se quiere modelizar. Los datos recogidos deben incluir los valores de las variables independientes y el resultado esperado para cada caso. El conjunto de datos es separado habitualmente en dos grupos, el set de entrenamiento y el set de test. El primer set será empleado para entrenar la red neuronal y el segundo para validar que la red ha sido entrenada convenientemente, y que es capaz de generalizar las relaciones entre las entradas y las salidas, proporcionando la respuesta deseada a nuevos casos no empleados durante el proceso de entrenamiento. Es necesario disponer de un número elevado de casos para el entrenamiento de la red, y en ellos deben estar representados todos los posibles patrones del problema. En caso contrario, la red neuronal no será capaz de determinar algunas de las relaciones entrada-salida, y aunque se obtuvieran buenos resultados con los datos de entrenamiento estos no serían generalizables a los datos de test.

Una vez establecidos los sets de entrenamiento y test es necesario determinar la arquitectura de la FNN. El tamaño de la red (número de capas ocultas y de neuronas por capa) influye en la capacidad de generalización del modelo. Establecer el número adecuado de neuronas es un gran problema para el que no existe un procedimiento sistemático, aunque existen algunas reglas simples como la de Masters (1993) que recomienda que el número mínimo de neuronas ocultas sea  $\text{Int}[(i + o)/2]$ , donde  $i$  es el número de entradas a la red y  $o$  es el número de salidas. En general se suele comenzar probando redes con pocas neuronas e ir aumentando el tamaño de la red hasta conseguir un resultado adecuado. El número de variables independientes y dependientes determina el número de neuronas de las capas de entrada y salida. En las capas ocultas el número adecuado dependerá del número de variables independientes y dependientes del problema, de la cantidad de datos disponibles para el entrenamiento y de la calidad de los mismos, de la complejidad de las relaciones entre los patrones de entrada y salida, del tipo de función de activación de las neuronas y del algoritmo de entrenamiento empleado (Sarle, 1997). Un número elevado de elementos de proceso incrementa la velocidad de convergencia y disminuye el error durante el entrenamiento, pero éste puede ser mucho mayor en la fase de test debido al overfitting. Por otra parte, un número excesivamente pequeño de elementos de proceso, sobre todo si la función que se pretende aproximar es compleja, puede provocar un mayor error en el entrenamiento y unos pobres resultados en el test (underfitting).

El número conveniente de capas ocultas de la red dependerá en gran medida de la función que se pretende aproximar y de las funciones de activación que se empleen en las neuronas. Para funciones objetivo complejas es útil emplear varias capas ocultas para lograr una mayor aproximación (Sarle, 1997). Una red con varias capas puede ajustar con más precisión una función que una red con una única capa oculta, pudiendo emplear un menor número de enlaces en función del número de neuronas en cada capa. Como contrapartida, una red con varias capas ocultas puede quedar atrapada más fácilmente en mínimos locales, pudiendo necesitar de algún procedimiento de optimización global o realizar varias inicializaciones aleatorias. En general, una FNN con dos capas ocultas es un aproximador

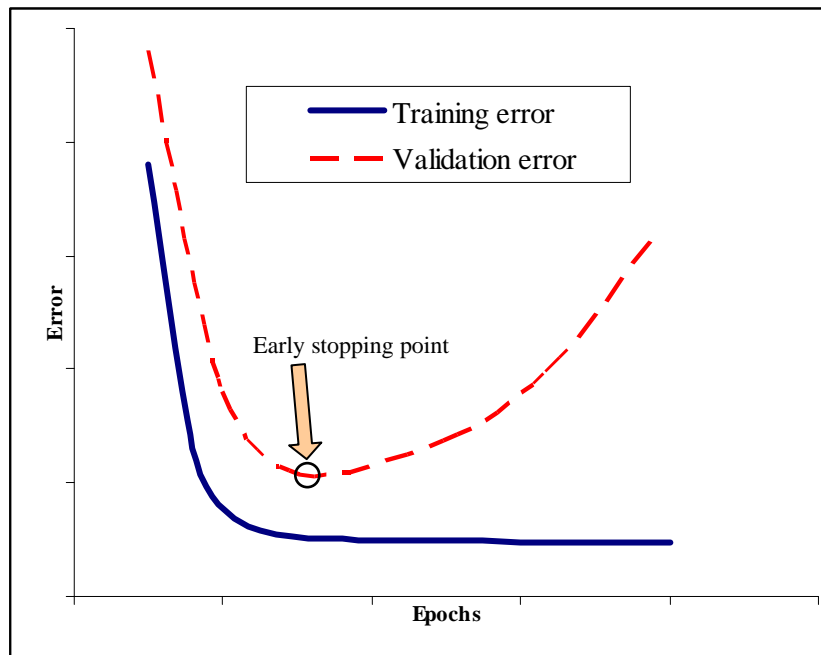
universal que puede generalizar cualquier relación entre las entradas y las salidas (Principe et al., 2000; Sontag, 1992).

## 2.2 Evitando el overfitting

El problema del overfitting no es particular de las ANNs y puede ocurrir también en los modelos de regresión. Obviamente el objetivo de la generación de un modelo neuronal o estadístico es lograr la generalización de los resultados, y un modelo que es capaz de ajustarse correctamente a los datos de entrenamiento, pero que no es capaz de generalizar el ajuste a nuevos casos no resulta de utilidad. La forma más común de evitar el overfitting es mantener el tamaño de la ANNs lo más pequeño posible, es decir, con un número pequeño de neuronas, lo que conlleva que el número de conexiones entre ellas sea pequeño. Algunos autores recomiendan establecer el número de neuronas ocultas como una función del número de entradas y salidas o de la cantidad de datos de entrenamiento disponibles (Berry y Linoff, 1997; Masters, 1993; Nelson y Illingworth, 1991), pero este tipo de reglas no consideran factores importantes como la complejidad de las relaciones entre las entradas y las salidas. En otros casos se recomienda que el número de conexiones entre neuronas no supere cierto valor dependiente del número de patrones de entrenamiento disponibles. Por ejemplo, Masters (1993) recomienda que el número de conexiones entre neuronas no exceda la mitad del de patrones de entrenamiento disponibles. Estas reglas genéricas pueden resultar útiles para evitar el overfitting, pero pueden limitar la capacidad del modelo para determinar con un buen grado de ajuste las relaciones entre las entradas y las salidas (underfitting). Para evitar el overfitting y obtener modelos con el mayor grado de ajuste posible pueden emplearse procedimientos de regularización como jitter (ruido añadido deliberadamente en las entradas durante el entrenamiento), weight decay (que añade un término de penalización en la función objetivo) o el early stopping.

Early stopping consiste en emplear un set reducido de datos (set de validación) para computar el error del modelo periódicamente durante el entrenamiento. Estos datos de validación no son empleados para entrenar a la red, si no que sirven para determinar el momento en el que el modelo deja de aprender y comienza a memorizar las relaciones entre los patrones de entrenamiento y sus salidas. Periódicamente durante el entrenamiento se fijan los pesos de las conexiones entre las neuronas y se introducen los datos del set de validación computando el error cometido. En una evolución típica del entrenamiento de una red el error de entrenamiento desciende de forma continua, mientras que el error de validación comienza descendiendo para, posteriormente, crecer cuando empieza a disminuir el grado de generalización del modelo (Figura 2). Dado que durante la validación los pesos de la red son fijos, la red no aprende de dichos casos, sólo de los casos del training set. Cuando las dos curvas de error son descendientes la red está aprendiendo relaciones entre las entradas y las salidas generalizables a casos que no pertenecen al set de entrenamiento. En el momento en el que la curva del error de validación comienza a crecer (early stopping point), la red está memorizando en los pesos de las conexiones entre las neuronas las respuestas adecuadas a los casos del training set, información que no es generalizable a los casos del set de validación. Así pues, aunque el error de entrenamiento podría seguir descendiendo, el proceso de entrenamiento es detenido en el punto en el que el error de validación comienza a crecer, evitando de esta forma el overfitting.

Figure 2: Evolución del error de una ANN durante el entrenamiento.



Este procedimiento permite entrenar ANNs con un elevado número de conexiones en relación al número de datos de entrenamiento disponibles sin que se produzca el overfitting. Es necesario remarcar que el error de validación no es un estimador adecuado del grado de generalización obtenido por la red, por ello, se emplea un tercer set de datos no empleado para el entrenamiento (set de test) para comprobar el grado de generalización. Así pues, el procedimiento comúnmente empleado es dividir los datos disponibles en tres sets: el set de entrenamiento, que se emplea para entrenar la red, el set de validación, que se emplea para determinar el early stopping point, y el set de test, usado para validar el grado de generalización del modelo ya entrenado. Existe cierta confusión en la literatura sobre el nombre adecuado para cada uno de estos sets de datos (Sarle, 1997), y en muchas ocasiones se emplea el término set de validación para referirse al set de test, por ejemplo en Chen et al., (2000) y en Chen et al. (2004).

### 3. Aplicaciones al problema de los LBDs

En Marras et al. (1993) se desarrolló un estudio que trataba de relacionar los movimientos del tronco y determinados aspectos del puesto de trabajo con el riesgo de padecer LBDs en tareas repetitivas. El estudio comprendió 403 puestos de trabajo industriales que fueron clasificados en tres grupos, bajo riesgo (124 casos), riesgo medio (168 casos) y alto riesgo (111 casos). Para realizar la clasificación de los puestos se analizó el riesgo asociado de padecer LBDs empleando los registros médicos de las compañías, registros de lesiones y tasas de rotación.

Zurada (Zurada et al. 1997) empleó los datos de este estudio de campo para desarrollar una FNN capaz de clasificar los puestos de trabajo en función del riesgo de padecer LBDs. En este trabajo se seleccionaron aleatoriamente 124 puestos del grupo de bajo riesgo y 111 del grupo de alto riesgo. El resto de los puestos fueron excluidos del estudio. 74 puestos de cada grupo fueron empleados para el entrenamiento del modelo, los demás, 50 puestos de

bajo riesgo y 37 alto riesgo fueron empleados para probar la FNN. Los datos contenían cinco variables independientes que representaban factores de riesgo para el desarrollo de LBDs: número de levantamientos por hora (LIFTR), velocidad de giro media (PTVAVG), momento máximo (PMOMENT), ángulo sagital máximo (PSUB), y velocidad lateral máxima (PLVMAX). La única variable dependiente (RISK of LBDs) podía tomar dos valores discretos: 'low risk' and 'high risk'. El procedimiento para determinar la arquitectura más adecuada de la red fue realizar un número indeterminado de pruebas con diferentes configuraciones topológicas con una única capa oculta, variando el número de neuronas entre 8 y 20. En todos los casos se mantuvieron constantes el número de variables de entrada y la función de activación de las neuronas (continua unipolar). Posteriormente, en Chen et al. (2000), y empleando los mismos datos experimentales, se usó un procedimiento heurístico que trataba de determinar cuáles de las 5 variables de los puestos analizados en Marras et al. (1993) resultaban realmente significativas para el modelo neuronal y cuáles podían ser eliminadas. Además el procedimiento establecía el número adecuado de neuronas en la única capa oculta del modelo. Los mismos autores, en Chen et al. (2004) presentaron un nuevo procedimiento que permite obtener resultados similares con un set de datos más reducido o incompleto.

Para medir el grado de generalización de los modelos obtenidos, los autores midieron la proporción de los puestos de trabajo del set de test que fueron correctamente clasificados (PCC). Denominando  $x_0$  al número de puestos de trabajo de bajo riesgo correctamente clasificados por el modelo,  $x_1$  al número de puestos de alto riesgo correctamente clasificados, y siendo  $n_0$  y  $n_1$  el número de puestos de bajo y alto riesgo respectivamente, el PCC se calcula como  $(x_0 + x_1)/(n_0 + n_1)$ . Denominando como 0 al grupo formado por los puestos de bajo riesgo y 1 al grupo formado por los puestos de alto riesgo, los autores presentan los resultados mediante una matriz de confusión (Tabla 1). En dicha tabla  $PCC_0$  y  $PCC_1$  se definen como  $x_0/n_0$  y  $x_1/n_1$ , representando, respectivamente, la proporción de casos de bajo y alto riesgo correctamente clasificados. Los mejores resultados obtenidos para los datos de test en Zurada et al. (1997), Chen et al. (2000) y Chen et al. (2004), están representados en la Tabla 2.

**Tabla 1. Matriz de confusión**

		Clasificación del modelo	
		0	1
Clasificación real	0	$x_0$	$n_0 - x_0$
	1	$n_1 - x_1$	$x_1$
		$PCC_0$	$PCC_1$
		PCC	



La red desarrollada en Zurada et al. (1997) consistía en una FNN entrenada mediante BP, con una única capa oculta con 10 neuronas y una capa de salida con 2 neuronas. En todas las neuronas se usó una función de activación unipolar continua. Los puestos se clasificaron en función de la neurona de la capa de salida que ofreciera una salida mayor. La red fue capaz de clasificar correctamente el 74,7% de los puestos de trabajo del set de test. En los casos de Chen et al. (2000) y Chen et al. (2004), la red con mayor capacidad de generalización fue una FNN con una capa oculta con cuatro neuronas que fue capaz de clasificar correctamente el 79.3% de los puestos del set de test. En este caso los autores determinaron que el modelo ofrecía mejores resultados eliminando la variable LIFTR, por lo que la red contaba con una entrada menos que la de Zurada et al. (1997).

**Tabla 2. Resultados de estudios previos**

		<b>Zurada et al. (1997)</b>		<b>Chen et al. (2000)</b>		<b>Chen et al. (2004)</b>	
		Clasificación del modelo		Clasificación del modelo		Clasificación del modelo	
		0	1	0	1	0	1
Clasificación real	0	36	14	38	12	38	12
	1	8	29	6	31	6	31
		0.720	0.784	0.760	0.838	0.760	0.838
		<b>PCC 0.747</b>		<b>PCC 0.793</b>		<b>PCC 0.793</b>	

En estos estudios el número de elementos de proceso de las ANNs se mantiene bajo de forma intencionada para evitar el overfitting. De acuerdo con la regla de Masters (1993), dado el número de casos de entrenamiento disponibles (148), el número de conexiones entre neuronas no debería ser mayor que 74. La mejor red obtenida por Zurada et al. (1997) tenía 80 conexiones entre neuronas, número algo superior al límite recomendado por Masters (1993). En el caso de Chen et al. (2000) y Chen et al. (2004), el número de conexiones de la mejor red localizada fue de 30, muy por debajo de dicho límite.

#### 4. Material y métodos

En este estudio se utilizó un enfoque distinto en la obtención de la arquitectura de la red. En lugar de limitar el tamaño de las redes y el número de neuronas para evitar el overfitting, se desarrollaron redes complejas, con un elevado número de conexiones, empleando early stopping como mecanismo para evitar el overfitting. El objetivo fue obtener una red con una mayor capacidad para establecer relaciones generalizadas entre las características de las tareas y el riesgo de provocar LBDs. La implementación de este procedimiento resulta menos laboriosa que el empleo de procedimientos heurísticos de búsqueda de arquitecturas adecuadas, y el entrenamiento de las redes más rápido debido a la parada temprana del proceso. Para comparar este enfoque con los de estudios precedentes se emplearon los datos del trabajo de campo de Marras et al. (1993) tal y como son descritos en Zurada et al. (1997). Este último trabajo presenta tablas con los datos de los 148 puestos (74 de bajo riesgo y 74 de alto riesgo) empleados para el entrenamiento del modelo, y los 87 empleados para el test (50 de bajo riesgo y 37 de alto riesgo).

Para poder aplicar el early stopping para evitar el overfitting fue necesario dividir el training set original en dos grupos, uno de los cuales se emplearía para el entrenamiento y el otro

para la validación. El test set se mantuvo sin modificación. No existe una regla fija para determinar el número de casos adecuado para formar el set de datos de validación, aunque en Sarle (1995) puede encontrarse un estudio al respecto. De los 148 puestos de entrenamiento se escogieron aleatoriamente 54 (27 de bajo riesgo y 27 de alto riesgo) para formar el set de validación. En total se empleó aproximadamente el 36.5% de los datos de entrenamiento disponibles para la validación. La Tabla 3 muestra la distribución de los casos en los diferentes sets. Los valores de las variables independientes fueron normalizados en el intervalo  $[-0.9, 0.9]$  y a la variable dependiente se le dio el valor  $-0.9$  en los casos de puestos de bajo riesgo y  $0.9$  en los de alto riesgo.

El tipo de red escogido para el estudio fue una Generalized Feedforward Network (GFN) con tres capas ocultas. Una GFN es una FNN en el que las neuronas de cada capa, además de estar conectadas con las de la siguiente capa, pueden saltar sobre ella y conectarse con las capas posteriores. Dado que poseen un mayor número de conexiones, este tipo de redes suelen entrenarse más rápidamente que las FNN no generalizadas empleando el mismo número de elementos de proceso.

**Tabla 3. Distribución de los casos en los diferentes sets**

	Set de entrenamiento	Set de validación	Set de Test	<b>Total</b>
Bajo Riesgo	47	27	50	<b>124</b>
Alto Riesgo	47	27	37	<b>111</b>
<b>Total</b>	<b>94</b>	<b>54</b>	<b>87</b>	<b>235</b>

Aunque en los problemas de clasificación suele emplearse como criterio de error el número de casos incorrectamente clasificados, algunas pruebas previas mostraron un mejor resultado empleando como criterio de error el error medio cuadrático, es decir, la media de los cuadrados de las diferencias entre las respuestas esperadas y las obtenidas.

Se decidió emplear como funciones de activación tangentes hiperbólicas en lugar de las logísticas usadas en trabajos previos (Zurada et al. 1997). Estas dos funciones tienen un comportamiento similar salvo por el rango de sus salidas, entre 0 y 1 en el caso de la logística, y entre  $-1$  y  $1$  en el de la tangente hiperbólica. El algoritmo de entrenamiento empleado fue de tipo BP con momentum. El momentum es un término que introduce cierta inercia en la actualización de los pesos de las conexiones, lo que acelera y estabiliza la evolución y evita la convergencia en un mínimo local. El momentum se fijó en 0.7. El tamaño de paso empleado fue 0.01 en la primera capa oculta, disminuyéndolo en un factor 5 en la segunda capa oculta, y de nuevo en la tercera (Principe et al. 2000). Los pesos iniciales fueron establecidos aleatoriamente con valores pequeños (con media 0 y rango entre  $-0.1$  y  $0.1$ ). Este procedimiento es recomendable cuando se emplean funciones de activación no lineales para evitar la saturación inicial de los elementos de proceso (Principe et al., 2000).

Dado que se pretendía generar un modelo basado en una red con un elevado número de conexiones, se fijó el número de elementos de proceso en un intervalo entre 16 y 20. Aunque en Zurada et al. (1997) se probaron redes con entre 8 y 20 neuronas, la distribución en tres capas ocultas de los elementos de proceso y el que las neuronas de una capa estén conectadas con todas las de las siguientes capas, provoca que el número de conexiones entre neuronas sea mayor que en dicho trabajo. En el caso de la red más grande probada

en Zurada et al. (1997) existían 160 conexiones, en el caso de este trabajo, la red más pequeña probada contenía 166, y la más grande 230. Por otra parte, el número de casos de entrenamiento disponible con el enfoque de este trabajo es inferior, debido a la necesidad de emplear algunos casos como set de validación.

Se entrenaron redes con 7, 8 y 9 neuronas en la primera capa oculta, 5, 6 y 7 en la segunda, 3 en la tercera y una única neurona en la capa de salida empleando el early stopping como criterio de parada. Cada una de las redes fue entrenada 5 veces. Una vez alcanzado el early stopping point en cada red se detuvo el entrenamiento y se midió el PCC sobre los casos del test set, registrando el mayor PCC de los cinco entrenamientos realizados (Tabla 4). Las redes que obtuvieron un PCC más alto estaban compuestas por capas de 8, 6 y 3 neuronas y por 9, 6 y 3 neuronas respectivamente. Se consideró la mejor red a la compuesta por capas de 8, 6 y 3 neuronas debido a su mayor simplicidad. El número medio de ciclos de entrenamiento necesarios para alcanzar el early stopping point fue de 2213, y el tiempo medio de entrenamiento en un PC con un procesador de 1.83 GHz y 1GB de RAM fue de 28 segundos.

Tabla 4. PCCs de las diferentes redes sobre los datos de test.

Neuronas en la primera capa oculta	Neuronas en la segunda capa oculta	Neuronas en la tercera capa oculta	Neuronas en la capa de salida	PCC <sub>1</sub>	PCC <sub>2</sub>	PCC
7	5	3	1	0.760	0.838	<b>0.793</b>
8	5	3	1	0.760	0.865	<b>0.805</b>
9	5	3	1	0.760	0.811	<b>0.782</b>
7	6	3	1	0.760	0.838	<b>0.793</b>
<b>8</b>	<b>6</b>	<b>3</b>	<b>1</b>	<b>0.780</b>	<b>0.865</b>	<b>0.816</b>
<b>9</b>	<b>6</b>	<b>3</b>	<b>1</b>	<b>0.780</b>	<b>0.865</b>	<b>0.816</b>
7	7	3	1	0.760	0.865	<b>0.805</b>
8	7	3	1	0.780	0.838	<b>0.805</b>
9	7	3	1	0.760	0.865	<b>0.805</b>

#### 4. Resultados y discusión

La mejor red obtenida por el procedimiento descrito en el presente trabajo contenía 197 conexiones neuronales. Según Masters (1993) el número de casos de entrenamiento mínimos necesarios para dicha red es de 394. Sin embargo, a pesar de que el training set empleado contenía únicamente 94 casos, la red fue capaz de alcanzar un grado de generalización mayor que los de trabajos similares precedentes. El PCC sobre los datos de test fue aproximadamente un 6% mejor para los trabajos de bajo riesgo y un 8% para los de alto riesgo que los obtenidos por Zurada et al. (1997). En el caso de Chen et al (2000) y Chen et al (2004), la mejora fue de un 2% y un 3% aproximadamente (Table 5). Como

indican los autores de estos trabajos es difícil obtener una mayor generalización a partir de los datos de Marras et al. (1993), debido a la naturaleza compleja de la etiología de los LBDs, existiendo factores no contemplados en el estudio de Marras et al. (1993) y posibles clasificaciones incorrectas en el trabajo de campo. La tabla 4 muestra también el PCC obtenido por Marras et al. (1992) empleando regresión logística. La capacidad predictiva de los modelos basados en ANNs es mayor en todos los casos estudiados que los basados en regresión. El modelo de Marras clasifica correctamente el 88% de los trabajos de bajo riesgo, pero sólo el 51% de los de alto riesgo. Este último tipo de clasificación incorrecta puede resultar peligroso para la salud de los trabajadores.

**Tabla 5. Comparación de los resultados de trabajos previos y el nuevo enfoque.**

		<b>Marras et al. (1992)</b>		<b>Zurada et al. (1997)</b>		<b>Chen et al. (2000) Chen et al. (2004)</b>		<b>Modelo Actual</b>	
		Clasificación del modelo		Clasificación del modelo		Clasificación del modelo		Clasificación del modelo	
		0	1	0	1	0	1	0	1
Clasificación real	0	44	6	36	14	38	12	39	11
	1	18	19	8	29	6	31	5	32
		0.880	0.514	0.720	0.784	0.760	0.838	0.780	0.865
		<b>PCC 0.724</b>		<b>PCC 0.747</b>		<b>PCC 0.793</b>		<b>PCC 0.816</b>	

El enfoque presentado en este estudio para obtener una ANN para la predicción del riesgo de padecer LBDs en puestos de trabajo con manejo manual de carga, proporciona beneficios significativos tanto en el campo de la ergonomía como en otros ámbitos. El fundamental es la predicción más precisa de la clasificación de los puestos industriales en función del riesgo de producir LBDs. Este aumento de la precisión resulta fundamental para que resulte una herramienta útil al ergónomo. El procedimiento presentado en este trabajo, frente al empleo de métodos metaheurísticos de búsqueda, supone un menor esfuerzo de desarrollo y obtención del modelo, obteniendo niveles de generalización superiores. Los algoritmos genéticos o el recocido simulado son procedimientos globales de búsqueda que pueden evitar los mínimos locales, pero son complejos de implementar, lentos, y requieren de una cuidadosa parametrización. Por otra parte, el tiempo de entrenamiento de las redes es menor debido a que el proceso es detenido cuando el error cometido por la red sobre el set de validación comienza a crecer. Como consecuencia, los errores en el set de entrenamiento suelen ser mayores que en otros procedimientos, pero se consigue un mejor PCC en la fase de producción del modelo. En este sentido, se realizó una prueba continuando el entrenamiento de la mejor red localizada durante 1500 ciclos una vez superado el early stopping point. Como resultado se alcanzó un PCC de entrenamiento cercano a 0.94, sin embargo el PCC de test disminuyó hasta 0.62. En la Tabla 6 se muestran los PCCs de la mejor red encontrada en este trabajo para cada uno de los sets de datos. Estos resultados pueden compararse con los de Chen et al. (2000) y Chen et al. (2004), en los que el PCC del training set de la mejor red fue superior (0.85), y en los que, sin embargo, el PCC del test set fue inferior (0.79).

Tabla 6. PCCs de la mejor red sobre los diferentes sets de datos.

		Set de entrenamiento		Set de validación		Set de test	
		Clasificación del modelo		Clasificación del modelo		Clasificación del modelo	
		0	1	0	1	0	1
Clasificación real	0	37	10	19	8	39	11
	1	8	39	4	23	5	32
		0.787	0.830	0.704	0.852	0.780	0.865
		<b>PCC 0.809</b>		<b>PCC 0.777</b>		<b>PCC 0.816</b>	

En Chen et al. (2000) se empleó un método para eliminar del modelo variables independientes que influyeran poco en la clasificación de los puestos (backward elimination). De forma similar, en Chen et al. (2004) se utilizó un procedimiento similar (forward selection of input variables). En los dos casos, los mejores resultados se obtuvieron al eliminar del estudio la variable LIFTR (tasa de levantamientos). En este estudio se realizaron pruebas utilizando early stopping eliminando dicha variable, sin embargo, los resultados obtenidos fueron peores que considerando las cinco variables originales. Se llevó a cabo un análisis de sensibilidad con la mejor red obtenida empleando las cinco variables para conocer el efecto que cada variable producía en la salida. Para ello se calculó el valor medio de cada variable en los casos del set de entrenamiento, se fijaron los pesos de los enlaces de la red entrenada, y se emplearon dichos valores medios como entradas. Se perturbó aleatoriamente el valor de una entrada alrededor de su valor medio manteniendo constante el resto y midiendo la variación de la salida. Este procedimiento se repitió para cada variable de entrada. El resultado del análisis, expresado en porcentaje de influencia de cada entrada respecto a la clasificación del riesgo de los puestos, fue: LIFTR 14.00%, PTVAVG 3.04%, PMOMENT 53.42%, PSUB 8.33%, and PLVMAX 21.21%. A partir de estos resultados puede concluirse que el momento máximo es la variable que más influye en la clasificación del riesgo de LBDs en el modelo obtenido, y que la tasa de levantamiento y la velocidad lateral máxima tienen una influencia importante. Al contrario que lo propuesto en los estudios anteriores, la influencia de la tasa de levantamiento es lo suficientemente significativa como para no ser eliminada del modelo. La variable PTVAVG parece tener una influencia muy pequeña en la clasificación del riesgo y podría plantearse su eliminación. No obstante, la pequeña influencia de esta variable en las salidas del modelo no implica que PTVAVG no sea un factor influyente en la aparición de LBDs.

Aunque se ha conseguido un alto grado de generalización de las relaciones entre las variables de entrada y la correspondiente clasificación del riesgo, el modelo no es capaz de clasificar correctamente el 18.4% de los casos (porcentaje medido sobre el test set). Los motivos de las clasificaciones incorrectas pueden ser varios y probablemente relacionados con los datos empleados para el entrenamiento de la red. Zurada et al. (1997) achaca los errores de la red en la clasificación de los puestos de trabajo a errores cometidos durante el estudio de campo realizado por Marras et al. (1993). Fundamentalmente que los registros de LBDs de las compañías fueran incompletos o erróneos, o que no se contemplaran factores psicológicos que pueden provocar un incorrecto registro del origen de algunas lesiones. Chen et al. (2000) afirma que, dejando de lado los posibles errores del trabajo de campo, el

empleo de algoritmos BP para el entrenamiento de las redes puede ser la causa de errores en la clasificación.

La mejor ANNs encontrada fue implementada en una aplicación web (Figura 3) accesible libremente a los lectores interesados en la dirección <http://www.ergonautas.com/herramientas/rnergo/rnergo.php>. El usuario de la aplicación debe introducir los valores de las cinco variables del modelo correspondientes al puesto que se quiera clasificar, obteniendo como salida la clasificación del riesgo asociado al puesto. Es necesario remarcar que en el trabajo de campo del que se han obtenido los datos para la generación del modelo se recogieron datos de puestos con unas características concretas, puestos estables con repetitividad elevada y levantamiento manual de cargas. Por este motivo, el modelo sólo debe ser empleado para clasificar puestos de las mismas características.

En este trabajo se ha probado que el empleo de redes de arquitectura compleja combinada con procedimientos para evitar el overfitting como el early stopping, puede proporcionar resultados superiores al empleo de procedimientos heurísticos para determinar la arquitectura de la red en el caso de la predicción del riesgo de LBDs. El enfoque planteado en este trabajo proporciona una mayor capacidad predictiva, un mayor grado de generalización y un menor coste de implantación en cuanto a complejidad y tiempo de desarrollo. No obstante, ambos enfoques no son excluyentes, e investigaciones futuras pueden plantear la combinación de técnicas metaheurísticas con procedimientos para evitar el overfitting como el early stopping.

**Figura 3: Aplicación web que implementa el modelo neuronal**

**Riesgo de lumbalgias por levantamiento de carga**  
Herramienta de diagnóstico basada en el estudio de Marras 1993


Esta herramienta emplea una Red Neuronal Artificial para predecir el riesgo de aparición de trastornos músculo esqueléticos a partir de ciertos datos del levantamiento. Su desarrollo se ha basado en el estudio de Marras et al.1993 que analizó 403 puestos de trabajo con levantamiento de carga y la incidencia de trastornos en los mismos.

MARRAS, W.S., LAVENDER, S.A., LEURGANS, S.E., RAJULU, S.L., ALLREAD, W.G., FATHALLAH, F.A. AND FERGUSON, S.A., 1993. THE ROLE OF DYNAMIC THREE DIMENSIONAL TRUNK MOTION IN OCCUPATIONALLY RELATED LOW BACK DISORDERS. SPINE 18, 617-628.

[Más información >>>](#)

**Carga-RN**

VARIABLES		UNITS - UNIDADES
Tasa de levantamiento/ lift rate	<input style="width: 80%;" type="text" value="90,9"/>	lifts/h - levantamientos/hora
Velocidad media de giro del tronco máxima / peak twist velocity average	<input style="width: 80%;" type="text" value="7,7"/>	°/s
Momento máximo / peak moment	<input style="width: 80%;" type="text" value="12,6"/>	Nm
Desviación sagital máxima / peak sagittal angle	<input style="width: 80%;" type="text" value="35,0"/>	°
Velocidad de lateralización máxima / peak lateral velocity maximum	<input style="width: 80%;" type="text" value="32,5"/>	°/s



Risk Level / Nivel de Riesgo: **Low / Bajo**  
Probability of Risk / Probabilidad del Riesgo: **23,09%**

## Agradecimientos

Agradecemos a la Universidad Politécnica de Valencia su apoyo a esta investigación a través de su Programa de Apoyo a la Investigación y Desarrollo 2009 y su financiación a través de los proyectos PAID-06-09/2902 y PAID-05-09/4215.

## Referencias

- Battie, M.C., Bigos, S.J., Fisher, L.D., Spengler, D.M., Hansson, T. H., Nachemson, A.L. & Wortley, M.D. (1990). The role of spinal flexibility in back pain complaints within industry: A prospective study. *Spine*, 15, 768-773.
- Beach, T.A.V., Coke, K.S. & Callaghan J.P. (2006). Upper body kinematic and low-back kinetic responses to precision placement challenges and cognitive distractions during repetitive lifting. *International Journal of Industrial Ergonomics*, 36, 637-650.
- Berry, M.J.A. & Linoff, G.(1997). *Data Mining Techniques*. John Wiley & Sons. New York.
- Bigos, S.J., Spengler, D.M., Martin, N.A., Zeh, J., Fisher, L., Nachemson, A.L., & Wang, M.H. (1986). Back injuries in industry: A prospective study. II. Injury factors. *Spine*, 11, 246-251.
- Bishop, C.M., (1995). *Neural Networks for Pattern Recognition*. Oxford University Press, Oxford.
- Chen, C.L., Kaber, D.B. & Dempsey, P.G. (2000). A new approach to applying feedforward neural networks to the prediction of musculoskeletal disorder risk. *Applied Ergonomics*, 31, 269-282.
- Chen, C.L., Kaber, D.B. & Dempsey, P.G. (2004). Using feedforward neural networks and forward selection of input variables for an ergonomics data classification problem. *Human Factors in Ergonomics & Manufacturing*, 14, 31 – 49.
- Dempsey, P.G., (1998). A critical review of biomechanical, epidemiological, physiological and psychophysical criteria for designing manual materials handling tasks. *Ergonomics*, 41, 73-88.
- Dempsey, P.G., Ayoub, M.M. & Westfall, P.H. (1995). The NIOSH lifting equations: a closer look. In: Bitner, A.C., Champney, P.C. (Eds.), *Advance in Industrial Ergonomics and Safety VII*. Taylor and Francis, Bristol, PA, 705-712.
- Dempsey, P.G. & Westfall, P.H. (1997). Developing explicit risk models for predicting low-back disability: a statistical perspective. *International Journal of Industrial Ergonomics*, 19, 483-497.
- Eldersa, L.A.M. & Burdorf, A. (2001). Interrelations of risk factors and low back pain in scaffolders. *Occupational and Environmental Medicine*, 58, 597-603.
- Karwowski, W, Zurada, J., Marras, W. S. and Gaddie, P. (1994). A prototype of the artificial neural network-based system for classification of industrial jobs with respect to risk of

- low back disorders. Aghazadeh, F. (ed) *Proceedings of the Industrial Ergonomics & Safety Conference*, Taylor & Francis, London, 19-22.
- Magora, A. (1970). Investigation of the relation between low back pain and occupation. *Industrial Medicine*, 39, 465-471.
- Marras, W.S., Lavender, S.A., Leurgans, S.E., Rajulu, S.L., Allread, W.G., Fathallah, F.A. & Ferguson, S.A. (1993). The role of dynamic three dimensional trunk motion in occupationally related low back disorders. *Spine*, 18, 617-628.
- Marras, W.S., Lavender, S.A., Leurgans, S.E., Fathallah, F.A., Ferguson, S.A., Allread, W.G. & Rajulu, S.L. (1995). Biomechanical risk factors for occupationally related low back disorder risk. *Ergonomics*, 38, 377-410.
- Marren, A., Harston, C. & Pap, R. (1990). Handbook of neural computing applications. Academic Press Inc, San Diego.
- Masters, T. (1993). Practical Neural Network Recipes in C++. Academic Press Inc., San Diego, CA.
- National Institute for Occupational Safety and Health (1981). Work practices guide for manual lifting. NIOSH Technical Report No. 81-122. Cincinnati: National Institute for Occupational Safety and Health.
- Nelson, M. and Illingworth, W.T. (1991). A practical guide to neural nets. Addison-Wesley, New York.
- Nelson, N.A. and Hughes, R.E. (2009). Quantifying relationships between selected work-related risk factors and back pain: A systematic review of objective biomechanical measures and cost-related health outcomes. *International Journal of Industrial Ergonomics*, 39, 202-210.
- Neumann, W.P., Wells, R.P., Norman, R.W., Frank, J., Shannon, H, Kerr, M.S & the OUBPS Working Group. (2001a). A posture and load sampling approach to determining low-back pain risk in occupational settings. *International Journal of Industrial Ergonomics*, 27, 65-77.
- Neumann, W.P., Wells, R.P., Norman, R.W., Kerr, M.S., Frank, J., Shannon, H. & OUBPS Working Group (2001b). Trunk posture: reliability, accuracy, and risk estimates for low back pain from a video based assessment method. *International Journal of Industrial Ergonomics*, 28, 355-365.
- Nussbaum, M. & Chaffin, D.B. (1996). Evaluation of artificial neural network modelling to predict torso muscle activity. *Ergonomics*, 39, 1430-1444.
- Okunribido, O.O., Magnusson, M. & Pope, M.M. (2006). Delivery drivers and low-back pain: A study of the exposures to posture demands, manual materials handling and whole-body vibration. *International Journal of Industrial Ergonomics*, 36, 265-273.
- Principe, J.C., Euliano, N.R. & Lefebvre, W.C. (2000), Neural and adaptive systems, fundamentals through simulations. John Wiley & Sons, Inc, New York.



Sarle, W.S. (1995). Stopped Training and Other Remedies for Overfitting. Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics, 352-360.

Sarle, W.S., ed. (1997). Neural Network FAQ, part 1 of 7: Introduction, periodic posting to the Usenet newsgroup comp.ai.neural-nets, URL: <ftp://ftp.sas.com/pub/neural/FAQ.html>

Sontag, E.D. (1992). Feedback stabilization using two-hidden-layer nets. *IEEE Transactions on Neural Networks*, 3, 981-990.

Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986). Learning internal representations by error propagation, in Rumelhart, D.E. and McClelland, J. L., eds. (1986), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Volume 1, 318-362. The MIT Press. Cambridge.

Zurada, J., Karwowski, W. & Marras, W.S. (1997). A neural network-based system for classification of industrial jobs with respect to risk of low back disorders due to workplace design. *Applied Ergonomics*, 28, 49-58.

**Correspondencia** (Para más información contacte con):

José A. Diego Más

Phone: +34 96 387 7000 Ext (5683)

Fax:

E-mail : [jodiemas@dpi.upv.es](mailto:jodiemas@dpi.upv.es)

URL : [www.ergonautas.com](http://www.ergonautas.com)