

Aplicación de redes neuronales para la predicción de la percepción, por parte de los usuarios, de la funcionalidad de un producto

Sabina Asensio-Cuesta

José Antonio Diego-Más

Jorge Alcaide-Marzal

M^a Carmen González-Cruz

Departamento de Proyectos de Ingeniería. Universidad Politécnica de Valencia.

Abstract

This work continues previous investigations to develop a logical framework for applying artificial intelligence to the modelization of product user's preferences. The framework was applied to modelizing general aspects of product user's preferences using neural networks. Afterwards, their capacity to predict specific aspects of the product perception, no related with their primary functionality, was validated. In this work, the framework is used to predict the perception of specific aspects of the product, directly related with their primary functionality. Results seems to point out the model robustness, being applicable to a diversity of products and levels of detail in the aspect of the perception to predict.

Keywords: *Neural Networks, perception, product design*

Resumen

Este trabajo es la continuación de investigaciones previas en las que se propuso un marco lógico para servir de base a la aplicación de la inteligencia artificial a la modelización de las preferencias del usuario de productos. Dicho marco lógico fue aplicado a la modelización de las preferencias de los usuarios de un determinado producto en cuanto a aspectos generales del mismo empleando redes neuronales. Posteriormente, se validó su capacidad para predecir aspectos muy concretos del producto no relacionados con su funcionalidad. En este trabajo se aplica dicho modelo para predecir la percepción del usuario en un aspecto concreto del producto directamente relacionado con sus funciones primarias. Los resultados parecen indicar la robustez del modelo, resultando aplicable a diversos tipos de productos y niveles de detalle en el aspecto de la percepción a predecir.

Palabras clave: *Redes Neuronales, percepción, diseño de producto.*

1. Introducción

Para un mismo producto de consumo el mercado actual ofrece al usuario gran variedad de alternativas. El comprador se enfrenta, en el momento de tomar la decisión final de compra, a productos similares con las mismas funcionalidades y capacidad para satisfacer las necesidades que motivaron su interés. Este mercado con sobreabundancia de oferta provoca que el usuario/comprador decante sus preferencias por un producto u otro en función de los atributos no funcionales de los mismos. Ante alternativas en las que en todos los casos la funcionalidad del producto queda asegurada, son los colores, las texturas, la aparición o situación de ciertos símbolos o la imagen de marca los que determinan el éxito o fracaso de un producto concreto (Holbrook, 1985, Crilly et al., 2004).

Los consumidores, antes de adquirir un determinado producto, llevan a cabo un proceso de decisión en el que analizan múltiples criterios relacionados con el mismo (funcionalidad, tamaño, facilidad de uso, etc.) o con el propio sujeto (necesidad real, precio, carga simbólica, etc.). Dado que parte de los criterios que guían la decisión final de compra de un producto se basan en la percepción que el sujeto tiene de éste, parece lógico presuponer una relación entre los atributos del producto y el juicio del consumidor. Sin embargo, no resulta una tarea sencilla determinar cuáles son las características del producto que hacen que el consumidor los perciba de determinada forma. La dificultad radica, fundamentalmente, en que dichas relaciones perceptuales son de elevada complejidad, de carácter eminentemente difuso y a que están afectadas por multitud de factores externos al sistema usuario-producto. En general no es posible encontrar relaciones biunívocas entre los atributos del producto y el modo en el que éste se percibe.

En trabajos anteriores de los autores se desarrolló un modelo, basado en redes neuronales, que permite establecer la forma en que un usuario percibirá un producto en base a los atributos formales del mismo. Este modelo general permite conocer la respuesta futura del mercado ante un determinado producto cuando se pide que emita un juicio concreto. El conocimiento a priori de la opinión del potencial consumidor sobre el producto en fase de diseño, permitirá al diseñador su adaptación progresiva hasta alcanzar soluciones que, en cierta medida, garanticen el éxito en el sector del mercado al que se dirige. En los trabajos previos realizados, el modelo fue validado empleándolo para predecir la respuesta de los usuarios ante juicios genéricos sobre un producto como ¿compraría el producto?, y ante juicios más específicos que trataban de predecir si un producto parecía cumplir una determinada función secundaria. En este segundo caso se trató de modelizar el proceso mental del consumidor cuando enjuicia el carácter ecológico de un objeto, con el objetivo de servir de herramienta de apoyo a los diseñadores de productos dirigidos a los usuarios que desean adquirir productos respetuosos con el medio ambiente. Aunque ésta no era una función principal del producto, el modelo fue capaz de predecir si el observador extraía, de su aspecto formal, la conclusión de que el objeto poseía carácter ecológico. Finalmente, en este trabajo se trata de validar que el modelo es capaz de predecir de la misma forma, si un producto parece cumplir con la función principal a la que está destinado. Es decir, si el producto, a través de sus atributos formales y estéticos, es capaz de transmitir al usuario la impresión de que cumple de manera adecuada su funcionalidad primordial.

La selección de las redes neuronales artificiales (RNA) (McCulloch and Pitts, 1943) como soporte técnico del modelo propuesto es debida a la analogía entre su funcionamiento y los mecanismos cerebrales. En el modelo presentado se complementa la capacidad de simulación de las RNA con la de los Algoritmos genéticos (AG) [2]. Es posible encontrar referencias de utilización de la Inteligencia Artificial (término con el que se designa un grupo de técnicas entre las que se incluye a las RNA y los AG) en el ámbito del diseño del producto: por ejemplo, en (Hsiao and Huang, 2002) se propone una herramienta de diseño de sillas basada en un algoritmo genético y, en [4], se utilizan algoritmos genéticos para obtener diseños de productos orientados al usuario.

El modelo utilizado en el presente estudio se basa en el propuesto con anterioridad en (Diego-Mas et al., 2007; Diego-Mas et al., 2008; Diego-Mas et al., 2008b). A partir de dicho modelo genérico y en base al enfoque ya planteado, se ha desarrollado un nuevo modelo que relaciona los atributos del producto con el modo en que el consumidor percibe que cumple con su funcionalidad primaria. En el caso de estudio presentado se emplearon cascos de motocicleta, considerando la seguridad del usuario como su función primaria. El modelo permitirá determinar cuál será la respuesta del consumidor ante determinada combinación de atributos del producto al preguntarle si es o no seguro.

A continuación se realiza una breve aproximación a las RNA y a los AG. Posteriormente se expone el modelo teórico de transformación de la información que le llega al consumidor sobre el producto en su juicio sobre éste. Expuestos los fundamentos teóricos del modelo se describe el modelo basado en RNA y en AG. Finalmente se muestra la aplicación práctica del modelo en el caso de estudio ya citado.

2. Aproximación a las Redes Neuronales Artificiales y a los Algoritmos Genéticos.

Las redes neuronales artificiales son sistemas de procesamiento inspirados en el funcionamiento del cerebro humano, y son capaces de tratar e interpretar información de carácter difuso, lo cual las convierte en técnicas apropiadas para modelizar la percepción humana.

Una neurona artificial consiste en una abstracción matemática del funcionamiento de las neuronas naturales. Podría compararse con un amplificador operacional en el que se reciben las señales de entrada, se comprueba si se supera una función de activación, y si es pertinente, se produce la señal de salida. Las señales de entrada pueden representar información de lo que se quiere modelizar o bien pueden ser las señales de salida de otras neuronas. Los pesos representan la intensidad con que la sinapsis transmite la señal de la neurona presináptica a la postsináptica. Una función de activación en la neurona determina el umbral que deben sobrepasar las señales para que se produzca la salida.

Las RNA suelen estar formadas por varias neuronas interconectadas (salvo excepciones como la red Perceptron (Rosenblatt, 1958) formada por una única neurona). La disposición y forma de conexión varía de unos tipos de redes a otras, pero de forma general las neuronas se disponen en capas. La capa de entrada no es en sí una capa de neuronas sino que son los puntos donde se recogen las señales que se entregarán a la red. En esta capa no se procesa la información. Las capas internas (denominadas capas ocultas) recogen la información de la capa de entrada y la procesan. El número de capas ocultas, el número de neuronas por capa y la forma en que se conectan varían de unas redes a otras, y es lo que se denomina topología de la red. La capa de salida recibe la información de la última capa oculta y la transmite al medio.

Una vez configurada la topología de la red, y para que ésta pueda ofrecer salidas convenientes a las entradas que se le presenten debe ser sometida a un proceso denominado *entrenamiento*. En este proceso se le ofrece a la red el resultado esperado a una serie determinada de entradas. Las salidas proporcionadas por la red a estas entradas son comparadas con las salidas esperadas y se evalúa el error cometido. En función de ese error se modifican los pesos de los enlaces y los valores de las ganancias de las neuronas. Este proceso se repite hasta conseguir que el error alcance una cota superior determinada, punto en el cual se considera que la red está entrenada. Existen multitud de tipos y posibles clasificaciones de las RNA atendiendo a criterios como la forma de aprendizaje, el tipo de valores de entrada, el tipo de funciones de activación o la topología [9].

Los AG fueron desarrollados en (Holland, 1975). De forma general, estos algoritmos realizan una búsqueda estocástica guiada basándose en la evolución reiterada de un conjunto de estructuras y la selección de las más adecuadas en cada ciclo, estableciendo una analogía natural con la evolución de las especies. El punto de partida es un conjunto de soluciones al problema que se denominan *individuos*.

En el caso del presente trabajo, los individuos son diferentes combinaciones de pesos para cada uno de los atributos del producto que se está valorando generados de manera aleatoria. A este primer conjunto de individuos se le denomina *población inicial*. Cada uno de estos individuos está codificado mediante una cadena de longitud finita (*cromosoma*). La población es sometida a una serie de transformaciones que dan lugar a una nueva población de individuos (*nueva generación*). Estas transformaciones se llevan a cabo mediante la definición de una serie de operadores genéticos. Los más habituales son la *selección*, el *cruce*, y la *mutación*, que actúan combinando las cadenas que representan a los individuos. En cada generación se valora la bondad de las soluciones que conforman la población mediante una función de transformación (*función objetivo*). En este trabajo la calidad de los individuos (la bondad de los pesos asignados a cada atributo) se mide por la capacidad de la RNA para predecir las respuestas del usuario una vez entrenada con dichos pesos de los atributos. A partir de la valoración de los individuos de la población, e incluyendo cierto grado de aleatoriedad, se favorece a los individuos mejor dotados en un proceso de selección para conformar la siguiente generación. Este proceso es repetido cierto número de ciclos (*generaciones*) logrando que los individuos de la población evolucionen obteniendo buenas soluciones al problema que se trata de resolver, en este caso, determinar la importancia que el usuario otorga a cada atributo del producto.

3. Modelo perceptual

Para escoger el tipo de RNA más adecuado para generar un modelo que prediga la opinión de un usuario sobre un producto, es necesario conocer, aunque sea de manera aproximada, el proceso que se trata de modelizar. En (Diego-Mas et al., 2007) se presentó una propuesta de proceso de percepción que sirvió de base para un modelo similar al planteado en el presente trabajo.

De manera breve la propuesta de proceso plantea que el producto, dejando de lado su funcionalidad, posee una serie de atributos perceptibles por los sentidos del usuario que pueden clasificarse en diferentes niveles. La información correspondiente a dichos atributos y niveles de atributo llega al usuario a través de los sentidos. A partir de esta información el usuario valorará el producto cuando sea preguntado. Evidentemente, es necesario haber establecido qué se va a preguntar al usuario y la escala de valoración. El proceso propuesto consta de cuatro etapas (figura 2):

Etapa 1: Recepción de la información

Una vez que la información llega a los sentidos ésta es tratada de manera diferente en cada usuario. Parece lógico pensar que existen una serie de condicionantes particulares que afectan a la sensación que esa información produce en cada individuo. Por ejemplo, podría hablarse de condicionantes de tipo fisiológico: la capacidad de los sentidos para percibir los detalles o la educación de los mismos en la percepción de determinados atributos; de tipo psicológico: el estado de ánimo del observador; de tipo físico: el entorno y el medio de presentación del producto, o de tipo social: educación, acervo cultural o adscripción social.

Etapa 2: Filtrado de la información

La información llegada a través de los sentidos es filtrada antes de generar la sensación. No todos los atributos del producto tendrán la misma relevancia, e incluso alguna información

no influirá en absoluto. En esta etapa se elimina información superflua y se da preponderancia a la relevante.

Etapa 3: Preprocesado de la información

La información ya filtrada en la etapa anterior es preprocesada antes de generar la sensación. En esta etapa la información puede combinarse para dar lugar a atributos combinados que pueden ser determinantes en la sensación producida. Podemos hablar de una integración de los datos que añade, a la recibida por los sentidos, información global sobre el producto. Esta etapa finaliza con la generación de la sensación.

Etapa 4: Percepción y valoración

Una vez que se produce la sensación a partir de la información preprocesada comienza el proceso de percepción. Se plantea aquí la percepción como el proceso por el que, a partir de la sensación, se realiza una valoración del producto en aquel aspecto que se le pide al usuario que juzgue. Para realizar esta valoración global el usuario realiza una serie de valoraciones paralelas. Así, asignaría al producto un valor de uso: ¿cuánto cubre el producto mis necesidades?; un valor de posesión: ¿cuánto deseo poseer el producto?; o un valor estético: ¿en que medida los niveles de los diferentes atributos se ajustan a mis preferencias? Finalmente, mediante una ponderación de las diferentes valoraciones emitiría el juicio solicitado.

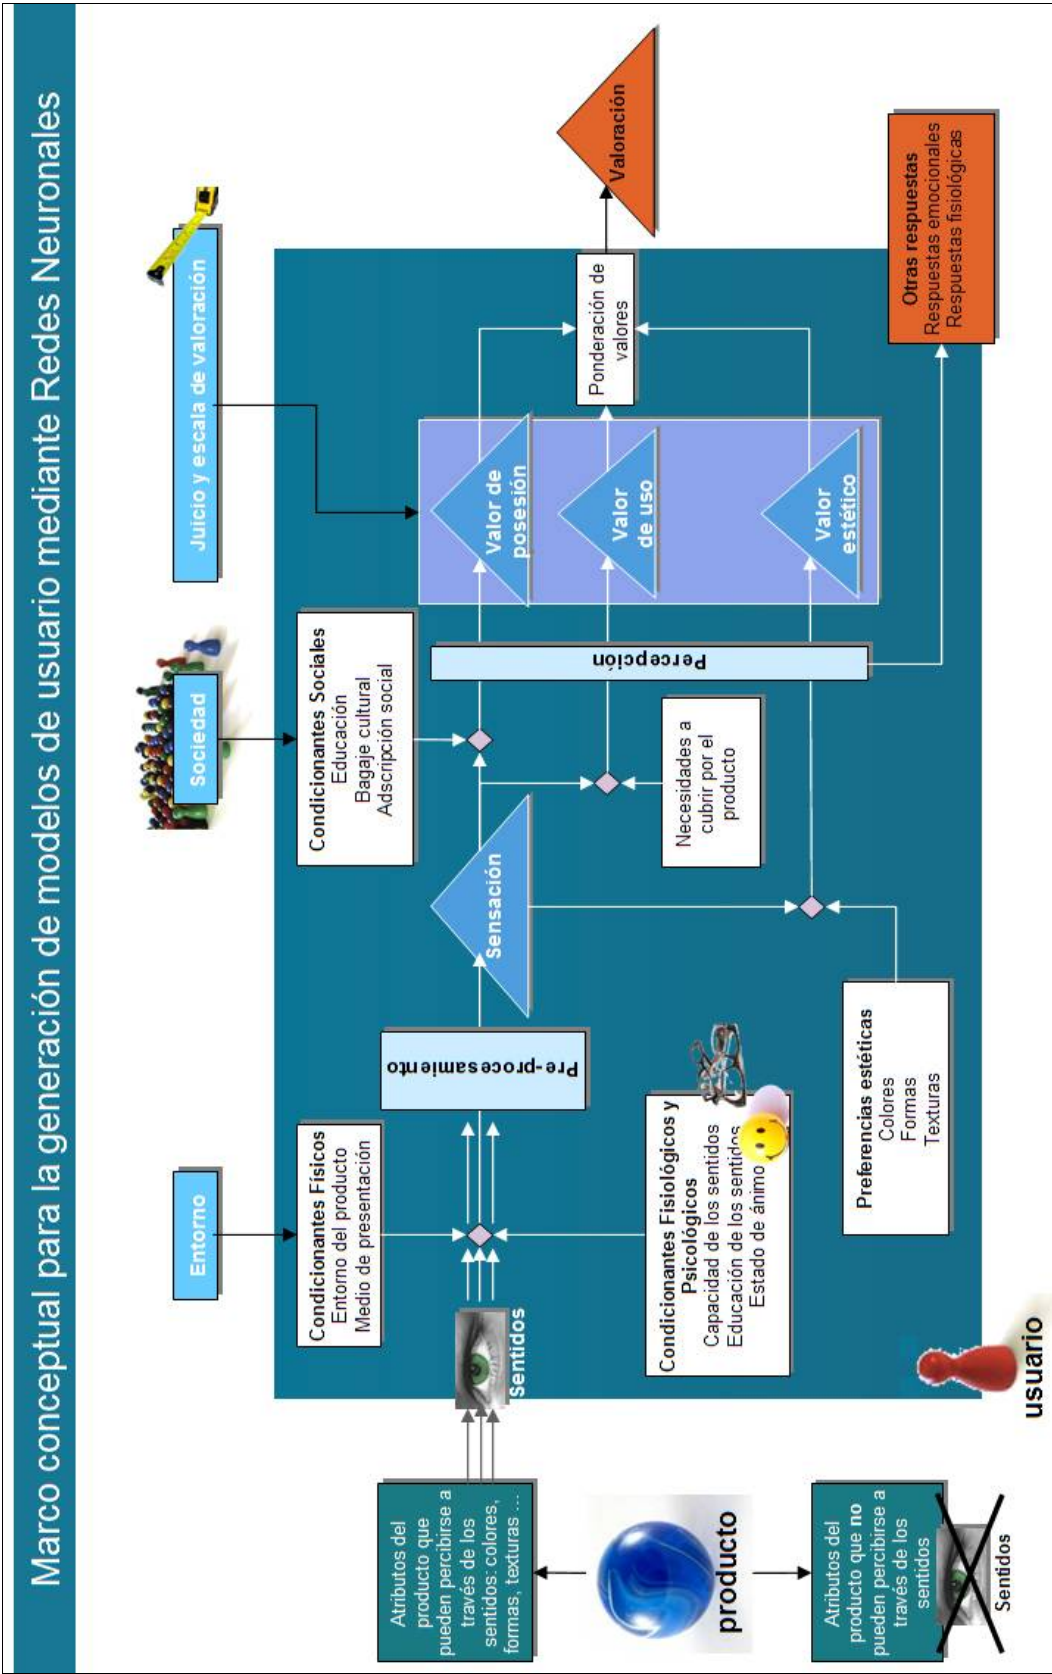


Figura 2. Esquema de la propuesta de proceso de percepción del usuario.

4. Modelo basado en redes neuronales

Tomando como base la propuesta de proceso de percepción expuesto en el apartado anterior se generó un modelo basado en RNA y en AG, para predecir la valoración de los usuarios respecto a un producto de consumo.

Como se ha indicado existen condicionantes particulares que provocan que la sensación producida a partir de la información llegada a través de los sentidos difiera de un usuario a otro. Por lo tanto, el modelo que se presenta será válido para un único usuario. Así, al entrenar las RNA con los datos recogidos de un usuario particular, la propia estructura de la red neuronal será capaz de modelizar las particularidades físicas, psicológicas y fisiológicas del mismo, dado que dicha información está implícita en las respuestas dadas por el usuario. Sería deseable que el modelo presentado en el apartado anterior fuera válido para representar la opinión del mercado en lugar de la de un único usuario. Salvo excepciones, el diseñador debe tratar de que la percepción asociada al producto sea satisfactoria para la mayor parte de los posibles usuarios. En general, los trabajos realizados hasta la fecha en la obtención de modelos de usuario mediante RNA han perseguido ese objetivo (Hsiao and Huang, 2002; Yang-Cheng and Hsin-Hsi, 2003). El procedimiento empleado habitualmente para conseguir modelos globales es emplear, para entrenar a las RNA, la media de las valoraciones que un grupo de usuarios representativos da de los productos que se evalúan (muestra del mercado). Al emplear estos procedimientos lo que se está modelizando es la respuesta media de los usuarios, lo que implica aventurar que existe un proceso perceptivo global del mercado que la red debe modelizar. Sin embargo, el trabajo aquí expuesto parte de la premisa de que existe una relación lógica entre los atributos del producto y la opinión del usuario. Esta relación es lógica porque tiene lugar en un proceso perceptivo llevado a cabo en el cerebro del usuario, y por lo tanto es particular para cada individuo.

El problema de la individualidad del modelo presentado puede salvarse mediante un muestreo adecuado del mercado. Aunque los procesos perceptivos varían de usuario a usuario, es posible realizar agrupaciones de usuarios en función de sus valoraciones del producto mediante procedimientos de *clustering*. Para ello se escoge una muestra de usuarios representativa del mercado y se agrupan en función de las respuestas a un conjunto reducido de productos. Una vez agrupados se escoge a un usuario representativo de cada grupo, obteniendo un modelo de RNA individual para cada uno de ellos. La salida de cada uno de estos modelos individuales será la opinión del grupo al que representa el usuario. Ponderando la salida de cada modelo individual por el tamaño del grupo al que representa cada usuario, será posible obtener un modelo global del mercado. Como en cualquier otro ámbito el tamaño de la muestra de usuarios y el número de grupos formados influirá en la exactitud del modelo.

El modelo desarrollado está compuesto por un algoritmo genético que realiza las funciones de filtrado de la información correspondiente a la etapa 2 del proceso de percepción antes descrito, una RNA de aprendizaje *no supervisado* para el preprocesado de la información de la etapa 3, y una RNA de procesamiento paralelo para modelizar la percepción y emitir la valoración en la última etapa (ver figura 3). El algoritmo genético, en sus sucesivas iteraciones, permite determinar qué atributos resultan relevantes para el usuario a la hora de emitir el juicio solicitado, eliminando aquellos que no aportan variabilidad en la salida del sistema. La RNA de aprendizaje *no supervisado* realiza el equivalente a un análisis de Componentes Principales, combinando la información ya filtrada por el algoritmo genético para dar lugar a las entradas a la red supervisada.

Este modelo, como cualquiera basado en RNA, requiere de un proceso de entrenamiento. Durante este proceso al modelo se le proporciona información sobre qué ha respondido el usuario al preguntársele por un número suficientemente elevado de productos. Una vez entrenado, el modelo será capaz de predecir la opinión del usuario ante nuevos productos.

La primera tarea a realizar es, por tanto, determinar los atributos más destacables del producto que se trata de analizar y los niveles que pueden tomar dichos atributos. Para ello es posible emplear técnicas como el Análisis Conjunto (Green and Rao, 1971; Luce and Tukey, 1964). A continuación se escogerá un número suficiente de productos (del mismo tipo) y se parametrizarán, es decir, se establecerá qué nivel poseen en cada atributo. Se entrevistará al usuario que se quiere modelizar mostrándole cada producto y solicitándole que emita un determinado juicio sobre ellos. Parte de estos datos se emplearán para el proceso de entrenamiento (datos de entrenamiento) y otra parte para, una vez entrenado el modelo, validar que los resultados son correctos (datos de test).

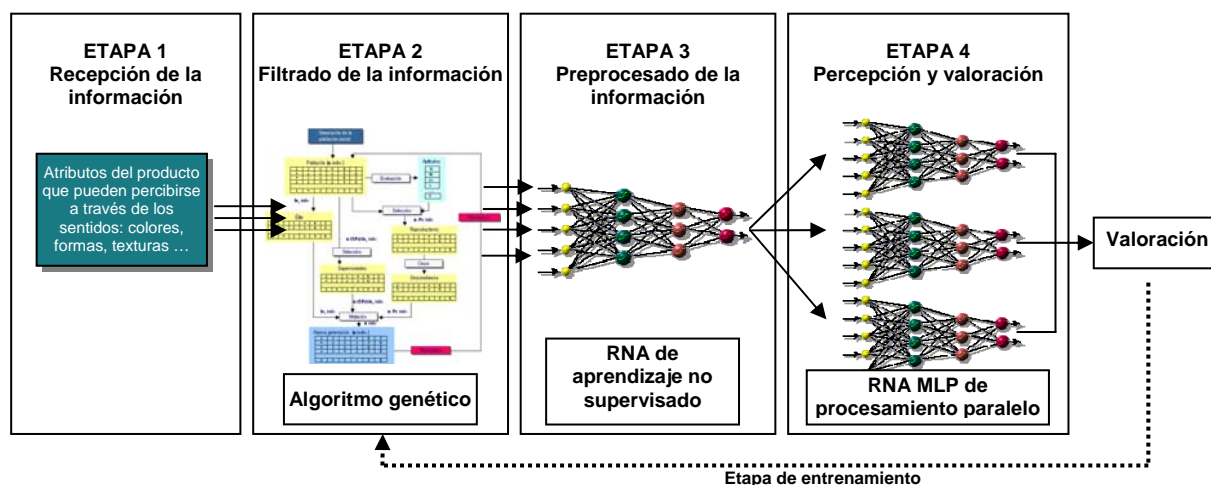


Figura 3. Modelo basado en RNA.

Durante la fase de entrenamiento, se introducirá en el modelo la información referente a los atributos del producto y se comparará la salida del modelo con la opinión del usuario. En esta fase la información de los atributos del producto pasará al AG de la etapa 2 que creará una población de soluciones (ver apartado 2) que representan diferentes combinaciones de pesos de cada atributo del producto. A la RNA de la etapa 3 llegará la información de los atributos ponderada por los pesos asignados por el AG. El AG empleará para evaluar la bondad de cada combinación de pesos el error cometido por las RNA de las siguientes etapas al predecir la opinión del usuario (reflejado en la figura 3 mediante una línea discontinua). Tras cierto número de iteraciones el AG será capaz de ponderar adecuadamente la información de entrada.

Ya se ha dicho que la RNA de la etapa 3 recibe la información de los atributos del producto en cuestión filtrada por el AG de la etapa 2. La RNA de la etapa 3 debe preprocesar esta información combinándola para dar lugar a nueva información significativa. El tipo de red escogido es una red de aprendizaje no supervisado. Este tipo de aprendizaje no emplea información sobre la salida que debe ofrecer la red, va adecuando los pesos de las conexiones entre las neuronas en función de la información interna que va recogiendo de las entradas. Este tipo de entrenamiento se utiliza principalmente para clasificar y diferenciar rasgos significativos de un conjunto de datos no clasificado a priori, dado que la red internamente intenta encontrar redundancias y rasgos significativos para agrupar la información. La salida de esta red es un conjunto de datos sobre el producto más reducido pero de mayor significación. Esta información de *calidad* pasa, en la etapa 4, a una RNA Multilayer Perceptron que, a través de esta información preprocesada llevará a cabo la valoración global del producto.

Así pues, durante la etapa de entrenamiento, el modelo ajustará los pesos de las conexiones entre las neuronas de las RNA, y el AG determinará los pesos de los atributos

del producto comparando las salidas del modelo con las opiniones reales del usuario. Una vez concluida la fase de entrenamiento se valida el buen funcionamiento del modelo empleando los datos de test. Como se ha dicho anteriormente los datos de tests son respuestas que el usuario ha dado a cierto número de productos y que no han sido empleados en la fase de entrenamiento. Si el modelo es capaz de ofrecer una valoración similar a la del usuario para estos datos podrá considerarse que es válido.

5. Aplicación práctica del modelo al caso de estudio

En trabajos anteriores (Diego-Mas et al., 2007; Diego-Mas et al., 2008; Diego-Mas et al., 2008b) se probó la capacidad del modelo planteado para predecir las preferencias genéricas de los usuarios respecto a un determinado producto. Dichos modelos respondían, bien a cuestiones como “¿Compraría usted este producto?” que establecen el grado en que un producto satisface de forma genérica los gustos y necesidades del usuario, o bien a cuestiones más específicas y alejadas de la función primaria del producto. Sin embargo cabe plantearse la duda de si el modelo será capaz de predecir juicios menos genéricos y centrados en el modo en el que el aspecto externo del objeto transmite su capacidad para cumplir con su funcionalidad básica.

El caso de estudio presentado a continuación pretendía validar dicha capacidad. Se seleccionó como producto para el caso los cascos para motocicleta, y como juicio a emitir si el casco parecer cumplir su función de dar seguridad y proteger al usuario. Se trató, pues, de entrenar al modelo para predecir, a partir de los atributos no funcionales del producto, en qué grado éste sería percibido por el usuario como seguro. La selección del producto se llevó a cabo considerando ciertas premisas: debía tratarse de un producto de consumo, no excesivamente complejo, en el que el peso de los atributos no funcionales fuese significativo ‘a priori’ en la valoración del usuario y que fuese fácilmente parametrizable.

El proceso dio comienzo con la selección de un total de 133 modelos de cascos para motocicleta con características diversas. Se determinaron los parámetros o atributos a priori fundamentales en la definición del producto (Transparencia de la pantalla, Presencia de doble pantalla, Tipo de visera, Forma de la calota, Motivos del estampado, Color primario de la calota...). En total fueron definidos 29 atributos con diferente número de niveles por atributo. El número total de niveles de atributo fue 111. Los atributos que planteaban dudas sobre su significación fueron introducidos en el modelo, confiando en el algoritmo genético de la etapa 2 la determinación de su importancia.

Se parametrizó cada una de los cascos determinando qué nivel de atributo poseían para cada característica. Los cascos se distribuyeron en dos grupos: el grupo de entrenamiento compuesto de 98 cascos que se emplearon para entrenar las RNA, y el grupo de test compuesto por 14 cascos que se emplearon para validar el ajuste del modelo una vez entrenadas las redes. Los 98 cascos del grupo de entrenamiento se clasificaron mediante un procedimiento de *clustering* de conglomerados jerárquicos de *k* medias. Se obtuvieron 7 conglomerados con 18, 15, 26, 26, 13, 14 y 21 cascos con características similares, y se escogieron los dos más cercanos al centro de cada conglomerado como representantes de cada grupo. Se obtuvo así un conjunto de 14 cascos de características heterogéneas y representativas del conjunto de todos los cascos.

Se escogieron 104 usuarios potenciales a los que se encuestó respecto a su opinión sobre las 14 cascos representativos. Las opiniones recogidas respecto a estos productos permitieron agrupar a los usuarios en *clusters* en función de la similitud de sus apreciaciones mediante un procedimiento de conglomerados jerárquicos. Se obtuvieron 4 clusters con 15, 38, 36 y 15 usuarios de los que se escogieron a los 4 encuestados más cercanos al centro de sus conglomerados. A estos 4 usuarios representativos del mercado se les mostró el total de 98 cascos del grupo de entrenamiento y los 14 del grupo de test para que emitieran su

valoración respecto al siguiente juicio: “*El casco que está viendo le parece seguro*”. Los usuarios respondieron sobre una escala Likert con 6 niveles en la que -3 indicaba “Completamente en desacuerdo” y 3 indicaba “Completamente de acuerdo”. De esta forma se obtuvo para cada casco la valoración de cada usuario. El nivel 0 de la escala de Likert fue eliminado porque experimentos previos permitieron establecer que, si el usuario no se decanta por alguno de los lados de la escala (positivo o negativo), el modelo no es capaz de extraer información válida del juicio emitido. Para llevar a cabo el proceso de obtención de las encuestas se empleó un software desarrollado al efecto que permitía mostrar al encuestado los productos en un navegador de Internet, aleatorizando el orden en que las mesas eran mostradas y automatizando la recogida de los datos. El software permitió la realización de la encuesta en varias sesiones, de forma que el encuestado pudiera dejar de evaluar productos cuando se sintiera cansado y continuar más adelante en el mismo punto en que abandonó la sesión anterior

Obtenidos los atributos de los productos y las opiniones de los usuarios se empleó el software NeuroSolutions 5 para generar las redes neuronales, entrenar los modelos de cada usuario y validar su ajuste. La tabla 1 muestra la topología de la red obtenida para cada modelo. La validación del ajuste se realizó comparando las opiniones de los usuarios respecto a los 14 cascos de test con las ofrecidas por los modelos entrenados. La Figura 4 muestra, para cada usuario, la valoración que realizó de los 14 cascos de test (indicado como *valor deseado* en la figura) y la valoración predicha por el modelo correspondiente a ese usuario (*valor predicho*). Los errores cuadráticos medios para cada modelo fueron, respectivamente: 0.1819, 0.1392, 0.1190 y 0,1710. Considerando como válidos los casos en los que la respuesta del modelo y del usuario coinciden en el signo de la respuesta, el porcentaje de aciertos de cada modelo fue, respectivamente: 78.6, 92.8, 78.6 y 78.6%.

Modelo	Aprendizaje no supervisado	Aprendizaje supervisado	
	Nº neuronas	Nº neuronas en capa 1	Nº neuronas en capa 2
1	8	8	4
2	8	7	3
3	8	7	3
4	8	7	3

Tabla 1. Topología de los modelos neuronales.

6. Conclusiones

El desarrollo del modelo basado en RNA propuesto se basa en una serie de hipótesis sobre el proceso mental que el usuario lleva a cabo cuando juzga un producto de consumo. La primera aplicación práctica del modelo, expuesto en (Diego-Mas et al., 2007), refrendó que las hipótesis de partida habían sido adecuadas para un producto concreto y para un juicio genérico. Otro trabajo posterior (Diego-Mas et al., 2008) trató de comprobar la robustez del modelo respecto a su capacidad para adaptarse a diversos tipos de productos, validez refrendada por los resultados del presente trabajo. En (Diego-Mas et al., 2007) el modelo sirvió para predecir las preferencias de los usuarios respecto a raquetas de padel. En (Diego-Mas et al., 2008) el modelo demostró su capacidad para hacer lo mismo con un producto muy distinto en cuanto a características, uso y público objetivo. La robustez del modelo puede considerarse muy elevada tras este trabajo. Por otra parte, se logró validar la capacidad del modelo para predecir la opinión del usuario respecto a juicios sobre la funcionalidad primordial del producto. Si en (Diego-Mas et al., 2007) se planteaba al usuario una pregunta que pretendía establecer en qué medida un producto satisfacía sus

preferencias globales, en este trabajo y en el desarrollado en (Diego-Mas et al., 2008) se le planteó una pregunta muy concreta sobre una característica específica del producto: bien sobre funcionalidades primarias, bien sobre funcionalidades accesorias. De nuevo el modelo parece robusto respecto al juicio que se pretende modelizar.

El modelo es válido para todos los usuarios con los que se ha experimentado sin necesidad de introducir ningún cambio, debiendo únicamente entrenar a las redes con los datos correspondientes a cada uno. De la misma forma que ocurrió en (Diego-Mas et al., 2007) y en (Diego-Mas et al., 2008) hay que remarcar una excepción. Aunque la topología de la red Perceptron en paralelo que modeliza la percepción de los usuarios ha sido común para todos ellos, no ha ocurrido lo mismo con la red de aprendizaje no supervisado que modeliza la sensación. En este caso se debió variar la topología en función del usuario modelizado. El número de salidas de dicha red debe adaptarse al usuario, pudiéndose especular con que cada usuario posee una dimensionalidad distinta en la sensación que le produce el objeto. Es decir, la información de calidad producida tras el preprocesamiento de la información proveniente de los sentidos posee diferentes niveles de complejidad. En unos casos esta información sin redundancias puede expresarse con un número pequeño de salidas en la red de aprendizaje no supervisado, en otros es necesario un nivel de complejidad mayor.


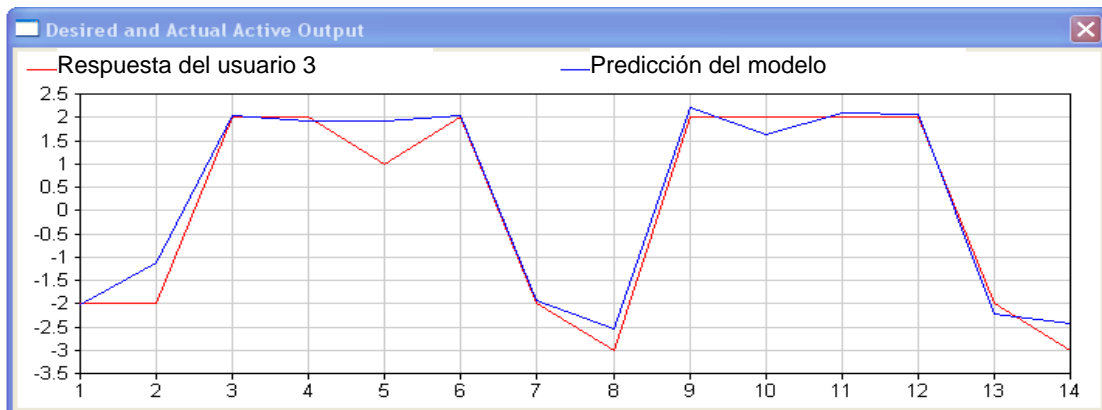
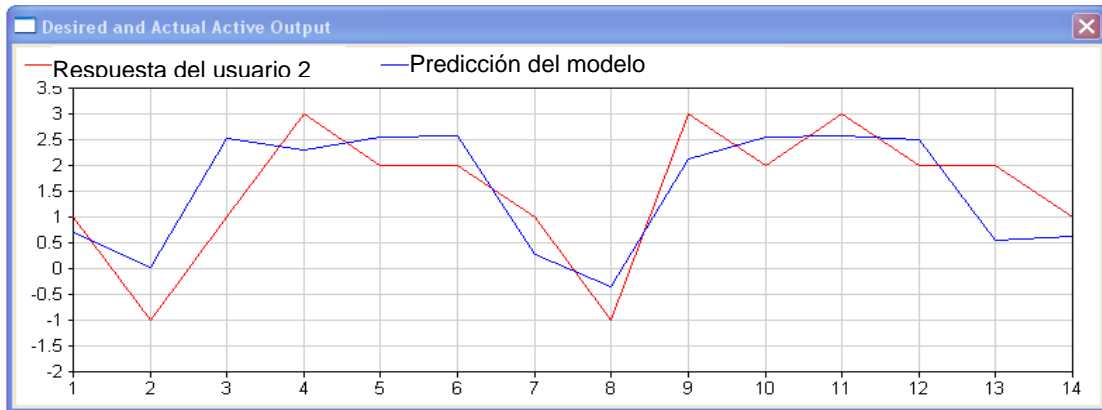


Figura 4. Grado de ajuste de los modelos de los cuatro usuarios

En este trabajo se ha validado el modelo desarrollado y se ha comprobado su utilidad como herramienta para ingenieros y diseñadores de productos. Una vez entrenado el modelo, éste es capaz de predecir la opinión de los usuarios respecto a productos que pueden encontrarse en fase de desarrollo temprano. Esto permite llevar a cabo modificaciones que permitan que el producto final cumpla los requerimientos estético formales adecuados, suponiendo esto una importante ventaja competitiva en mercados con sobre oferta de productos de similar funcionalidad.

Referencias

- Acosta-Buitrago M.A. and Zuluaga-Muñoz, C. A., "Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web", documento electrónico disponible en: <http://ohm.utp.edu.co/neuronales/>, fecha de último acceso: Febrero/2008.
- Diego-Mas, J.A., Alcaide-Marzal, J., Artacho-Ramírez, M.A., Debón-Alonso, J. and Asensio-Cuesta, S. "Modelización de las preferencias del usuario de productos industriales mediante redes neuronales: marco lógico y aplicación práctica". *XI Congreso Internacional de Ingeniería de Proyectos*. Lugo, 26-28 Septiembre, 2007.
- Diego-Mas, J.A., Asensio-Cuesta, S. and Alcaide-Marzal, J. "Aplicación de redes neuronales a la modelización de las preferencias del usuario de productos de consumo". *Dyna*, 2008, vol. 83, 3, pp 148-156.
- Diego-Más, J. A., Asensio-Cuesta S., Alcaide-Marzal J., Bastante-Ceca M.J., González-Cruz M.C., Martínez-Piqueras, M, "Aplicación de redes neuronales para la predicción del grado en que un producto será percibido como respetuoso con el medio ambiente". *XII Congreso Internacional de Ingeniería de Proyectos*. Zaragoza, 9-11 Julio, 2008b.
- Green, P.E. and Rao V.R., "Conjoint Measurement for Quantifying Judgmental Data," *Journal of Marketing Research*, 1971, vol 3, pp 355-363.
- Holland, J. H. "Adaptation in natural and artificial systems". *University of Michigan Press*, Ann Arbor. 1975.
- Hsiao, S.W. and Huang, H.C. "A neural network based approach for product form design". *Design Studies*, 2002, vol 23, pp 67-84.
- Luce, D. and Tukey, J., "Simultaneous Conjoint Measurement: A New Type of Fundamental Measurement", *Journal of Mathematical Psychology*, 1964, vol.1, pp 1-27.
- McCulloch W.S. and Pitts, W. "A logical calculus of idea's immanent in nervous activity". *Bulletin of Mathematical Biophysics*. 1943, vol 5, pp: 115-133.
- Rosenblatt F., "The Perceptron: a probabilistic model for information storage and organization in the brain", *Psychological Review*, 1958, vol. 65, pp: 386-408.
- Yang-Cheng, L. and Hsin-Hsi, L., "Design Optimization of Product Forms using Neural Networks: a case study of cellular phones", *Proceedings of the ADC 2003, 6th Asian Design International Conference*. October 14-17, 2003, Tsukuba, Japan.

Correspondencia (Para más información contacte con):

José Antonio Diego Más
Departamento de Proyectos de Ingeniería
Universidad Politécnica de Valencia
Camino de Vera s/n, 40071, Valencia, Spain.
Phone: +34 963 877000 ext 85683
E-mail : jodiemas@dpi.upv.es
URL: www.ergonautas.com