

Clasificación de consumidores eléctricos mediante el uso de varias técnicas de redes neuronales artificiales, e identificación de nuevos clientes con las redes entrenadas

S. Valero¹, M. Ortiz¹, C. Senabre¹, M. Peñarrubia¹, A. Gabaldón² y Fco. Garcia²

¹ Departamento de Ingeniería de Sistemas Industriales
Área de Ing. Eléctrica
Universidad Miguel Hernández
Avd. de la Universidad s/n, Edificio Torreblanca 03202, Elche (España)
Tel.:+34 966658969, fax:+34 966658979, e-mail: svalero@umh.es

² Departamento de Ingeniería Eléctrica, Universidad Politécnica de Cartagena, España
e-mail: antonio.gabaldon@upct.es

Resumen. El objetivo de esta comunicación es mostrar la capacidad de algunas técnicas de redes neuronales artificiales para la segmentación e identificación de la demanda eléctrica a partir de los perfiles de consumo eléctrico obtenidos de diferentes tipos de clientes, con el propósito de agruparlos de forma que sus curvas de demanda sean lo más parecidas posible dentro de los clusters realizados. Las técnicas analizadas fueron: Perceptrón Multicapa (MLP) [1], Redes Neuronales Probabilísticas (PNN), Cuantificación del Vector de Entrenamiento (LVQ), y Redes de Elman.

Lo primero es entrenar las diferentes técnicas utilizando el conjunto de datos de entrenamiento con el fin de obtener las mejores configuraciones de cada una de ellas, para después comprobar su capacidad de generalización presentándoles datos no utilizados en el entrenamiento previo, y así poder comparar las técnicas y seleccionar las más adecuadas.

Para la implementación de las distintas técnicas se utilizó el programa informático MATLAB, creando programas específicos para cada técnica a partir de las funciones existentes en la toolbox de redes neuronales artificiales de que dispone.

Tras realizar todas las simulaciones se observó que existen algunas técnicas más apropiadas para el propósito del presente trabajo, mediante las cuales se obtuvieron resultados muy satisfactorios.

Palabras llave

Redes Neuronales Artificiales, Segmentación de Clientes Eléctricos, Reconocimiento de Patrones, Mercados Eléctricos.

1. Introducción

En los nuevos mercados liberalizados, los clientes eléctricos tienen la oportunidad de elegir entre varios comercializadores, y por tanto, la posibilidad de acceder a nuevos productos y servicios por parte de los proveedores. Por esta razón, los comercializadores de energía están ahora más interesados en desarrollar nuevas estrategias y productos orientados hacia la demanda, es decir, hacia los clientes, con el fin de conseguir ofrecer el mejor servicio a cada usuario o de encontrar nuevas oportunidades de mercado.

De esta forma, los proveedores de los nuevos mercados liberalizados necesitan modelar y describir de forma precisa la demanda de los clientes para evaluar el potencial de un producto concreto o de una política en particular. Es bien sabido que los subgrupos de clientes presentan diferentes comportamientos eléctricos, características y requerimientos, y debido a ello cada política de demanda debería ser llevada a un segmento específico de clientes. La necesidad de ofrecer alternativas energéticas a los consumidores precisa de un conocimiento detallado de los segmentos de clientes y de la caracterización de estos clusters. Luego la evaluación de los segmentos de clientes en un área geográfica o eléctrica es percibida por parte de los proveedores y de los gobiernos como una herramienta muy útil.

El nuevo esquema regulado de los sistemas de energía eléctrica ha promovido la necesidad de monitorizar, adecuar y controlar las actividades de los clientes. Este hecho ha incrementado enormemente la cantidad de datos almacenados por parte de los proveedores, lo que supone un problema de utilización, pero también una indesechable oportunidad para la investigación. Estos datos altamente dimensionales no pueden ser modelados de forma sencilla, por lo que son necesarias nuevas herramientas para sintetizar estructuras de datos a partir de la información de que se dispone [2].

Hace ya bastante tiempo que vienen aplicándose técnicas estadísticas para el análisis y modelado de datos, pero los desarrollos más recientes de la Inteligencia Artificial han resaltado la importancia de los sistemas soporte de ayuda a la toma de decisiones y de la información cualitativa, sugiriendo modelos desarrollados para asistir al decisor en la resolución de problemas. En base a esto se pueden citar algunos trabajos y aplicaciones en los que se han usado redes neuronales artificiales, como puede ser el estudio del fracaso empresarial, la concesión de préstamos, telecomunicaciones, reconocimiento del habla, aplicaciones médicas, o aparatos de consumo.

El presente trabajo de investigación muestra el resultado de aplicar diferentes tipos de redes neuronales artificiales [3] para clasificar clientes eléctricos, extrayendo patrones de su comportamiento a partir de curvas de demanda y para identificar nuevos clientes en uno de los clusters realizados. El estudio está basado en datos reales de

veinte consumidores distintos, divididos a su vez en tres sectores españoles de clientes: Universidades, Zonas Residenciales e Industrias de Tamaño Medio. Las curvas de demanda están definidas por puntos de potencia activa tomados cada hora [4]. Por tanto, las curvas de demanda diarias fueron normalizadas y reducidas a 24 puntos. Estas curvas fueron tomadas de diferentes tests realizados desde 1995 hasta 2003. El número total de vectores (días) utilizados para el diseño o entrenamiento fue de 326. Para el testeo se utilizaron tres conjuntos de datos no usados en el diseño o entrenamiento, cada uno perteneciente a uno de los sectores ya citados. Se utilizaron 35 vectores de tipo residencial, 31 vectores de tipo industria y 21 vectores de tipo universidad.

TABLA I. – Clientes utilizados en el entrenamiento

Cliente	Etiqueta	Nº de vectores de entrada	Actividad del Cliente
U1	1	22	Universidad
U2	2	16	Universidad
I1	3	15	Industria
I2	4	15	Industria
R1	5	6	Residencial
R2	6	5	Residencial
R3	7	5	Residencial
R4	8	5	Residencial
U3	9	8	Universidad
U4	10	7	Universidad
U5	11	20	Universidad
U6	12	20	Universidad
U7	13	20	Universidad
U8	14	20	Universidad
U9	15	20	Universidad
U10	16	22	Universidad
I3	17	30	Industria
I4	18	22	Industria
R5	19	24	Residencial
R6	20	25	Residencial

En la Tabla I se puede observar: los clientes seleccionados para realizar el entrenamiento y las etiquetas asociadas con cada uno de ellos, el número de curvas de carga consideradas para cada cliente, y la clasificación del cliente de acuerdo con su actividad (universidad, residencial o industrial).

Los datos fueron reducidos a 24 puntos y normalizados entre 0 y 1. A continuación se muestra una gráfica de ejemplo de cada sector para ver la forma que toman las gráficas una vez tratados los datos:

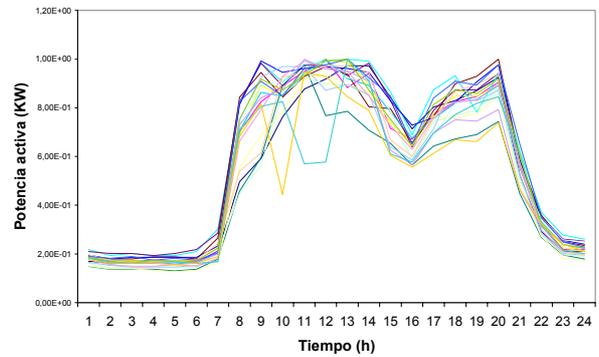


Fig. 1. Curva de carga cliente U6 (etiqueta 12)

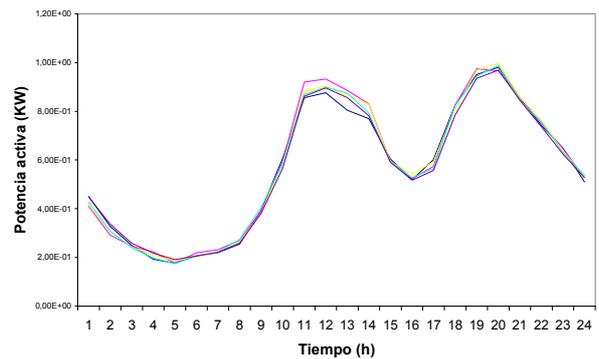


Fig. 2. Curva de carga cliente R2 (etiqueta 6)

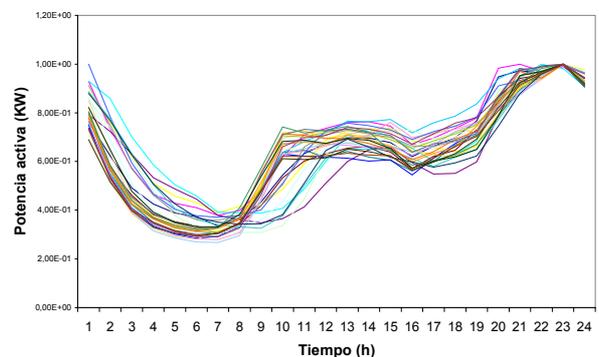


Fig. 3. Curva de carga cliente I3 (etiqueta 17)

En la siguiente gráfica se muestra una imagen de los datos de entrada a los que se les ha aplicado una técnica estadística denominada “escalado multidimensional”, para poder reducirlos de 24 a 2 dimensiones y así poder visualizarlos gráficamente.

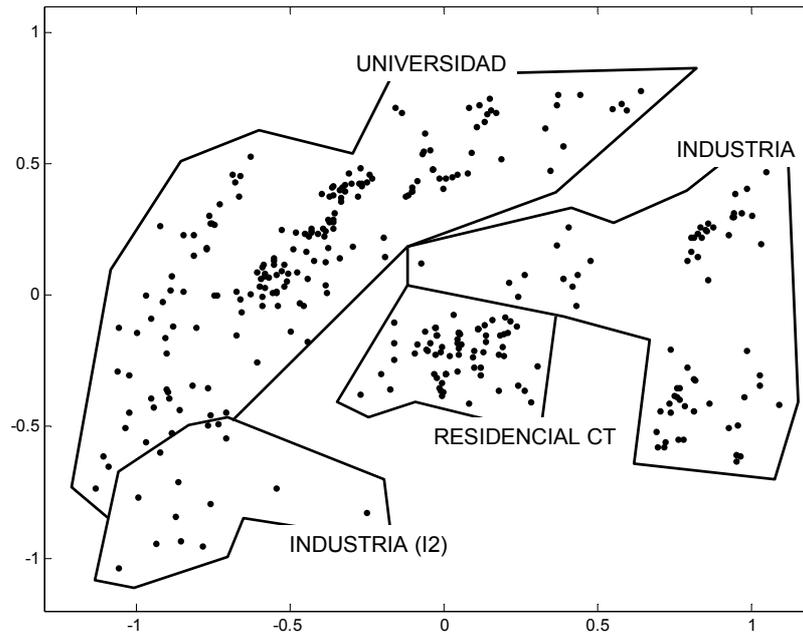


Fig. 4. Escalado Multidimensional

En la Fig. 4 puede comprobarse cómo el escalado multidimensional ha separado de forma bastante correcta los datos en sectores, a pesar de que al consumidor tipo Industria (I2) lo pone alejado de los de su sector.

2. Técnicas Analizadas

Las **redes neuronales artificiales**, mediante un estilo de computación paralelo, distribuido y adaptativo, son capaces de aprender a partir de ejemplos. Estos sistemas imitan esquemáticamente la estructura *hardware* (neuronal) del cerebro para tratar de reproducir algunas de sus capacidades. En la práctica, una red neuronal puede simularse mediante un programa de ordenador o bien realizarse en circuitos electrónicos específicos.

Los computadores fueron creados por el hombre específicamente para tareas que se pueden denominar de alto nivel, como el razonamiento o el cálculo, que pueden ser fácilmente resolubles mediante el procesamiento de símbolos; en este tipo de tareas el cerebro no es excesivamente diestro, y actúa en clara desventaja frente a la electrónica. Sin embargo, en tareas de procesamiento de bajo nivel, como las de reconocimiento de patrones, percepción, control, etc., los computadores se desenvuelven todavía torpemente, pues en origen no fueron ideados para ello. Para esta clase de problemas, esenciales para la supervivencia de un organismo vivo, la naturaleza encontró una excelente solución: el procesamiento autoorganizado que emerge de la interacción de numerosos procesadores elementales.

Por lo tanto, la idea de partida de las redes neuronales artificiales es que para ejecutar aquel tipo de tareas que más eficazmente resuelve el cerebro, puede resultar interesante copiar la estructura *hardware*, creando un sistema compuesto por múltiples neuronas ampliamente interconectadas, y estudiar si a partir de su autoorganización pueden reproducirse sus capacidades. Esta ruptura con el funcionalismo de la estructura de cómputo clásica aparece también en otros campos, que se suelen englobar dentro de la denominada computación emergente, inteligencia computacional o *soft computing*.

Las redes neuronales o sistemas neuronales artificiales constituyen en la actualidad un activo campo multidisciplinar, en el que confluyen investigadores procedentes de muy diferentes áreas, como la electrónica, física, matemáticas, ingeniería, biología o psicología. No obstante, hay que tener muy presente que en las redes neuronales artificiales no se persigue ningún tipo de ambición *prometeica*, como las de la IA en sus inicios, sino que se utilizan en el control de procesos industriales, reconocimiento de vehículos en los peajes de las autopistas o la previsión del consumo eléctrico, objetivos mucho más modestos que la creación de un *cerebro artificial*, y extremadamente útiles desde un punto de vista tecnológico. Es en este tipo de problemas prácticos en los que los sistemas neuronales están alcanzando excelentes resultados.

A continuación se comentarán las distintas técnicas analizadas en el presente trabajo de investigación.

A. Perceptrón Multicapa (MLP)

Si se añaden capas intermedias (ocultas) a un perceptrón simple, se obtendrá un perceptrón multicapa. Esta arquitectura suele entrenarse mediante el algoritmo denominado retropropagación de errores o BP, o bien haciendo uso de alguna de sus variantes o derivados, motivo por el que en muchas ocasiones el conjunto arquitectura MLP + aprendizaje BP suele denominarse red de retropropagación, o simplemente BP.

Dentro de la arquitectura MLP existen numerosas variantes, como incluir neuronas no lineales en la capa de salida, solución que se adopta especialmente en problemas de clasificación, introducir más capas ocultas, emplear diferentes funciones de activación, limitar el número de conexiones entre una neurona y las de la capa siguiente, introducir arquitecturas recurrentes, etc.

Uno de los inconvenientes en este tipo de redes es seleccionar el número idóneo de neuronas ocultas para un problema concreto, ya que si se elige un número inferior al óptimo, la clasificación no será apropiada, mientras que si es superior, su aplicación puede ser inabordable en la práctica.

Una solución al problema de entrenar los nodos de las capas ocultas pertenecientes a arquitecturas multicapa proporciona el algoritmo de retropropagación de errores o BP (*backpropagation*). La deducción del BP aparece como una consecuencia de extender el algoritmo LMS a las redes multicapa. *Backpropagation* fue creado generalizando la regla de aprendizaje Widrow-Hoff a redes multicapa y funciones de transferencia diferenciables y no lineales. Los vectores de entrada y los correspondientes vectores de etiquetas son usados para entrenar una red hasta que puede asociar los vectores de entrada con vectores de salida específicos o clasificar los vectores de entrada de una forma apropiada tal y como lo defina el usuario.

El *backpropagation* estándar es un algoritmo de descenso por gradiente, tal y como es la regla de aprendizaje Widrow-Hoff, en la cual los pesos de la red se mueven a lo largo del gradiente negativo de la función en cuestión. El término *backpropagation* se refiere a la forma en la que el gradiente es calculado para redes multicapa no lineales.

Un inconveniente del BP es su lenta convergencia. Si el ratio de aprendizaje es demasiado grande, el algoritmo se hace inestable. Si es demasiado pequeño, el algoritmo tarda mucho tiempo en converger.

Hay muchas variaciones del algoritmo *backpropagation*. Se usarán varias de ellas:

- *Backpropagation* Levenberg-Marquardt.
- *Backpropagation* de Gradiente Descendiente
- *Backpropagation* de Gradiente Descendiente con Momento
- *Backpropagation* con ratio de aprendizaje variable.

- *Backpropagation* con ratio de aprendizaje adaptativo
- *Backpropagation* con ratio de aprendizaje adaptativo combinado con la técnica del momento.
- *Backpropagation* resistente.
- Algoritmos de gradiente conjugado.
 - Actualización Fletcher-Reeves.
 - Actualización Polak-Ribière.
 - Reinicialización Powell-Beale.
 - Gradiente conjugado escalado.
- Algoritmos Quasi-Newton.
 - Algoritmo BFGS.
 - Algoritmo secante de un paso.

B. Redes Neuronales Probabilísticas (PNN)

El modelo de redes de base radial, aunque de reciente introducción, cada vez cuenta con más aplicaciones prácticas gracias a su simplicidad, generalidad y rapidez de aprendizaje. Se trata de un modelo que a menudo se estudia junto al MLP por ser una red unidireccional para aproximación funcional, pero que puede considerarse de tipo híbrido por incorporar aprendizaje supervisado y no supervisado. Usa neuronas de la capa oculta con funciones de respuesta Gaussiana.

Las redes de base radial pueden requerir más neuronas que las redes *backpropagation*, pero a menudo pueden diseñarse en menos tiempo. Estos modelos de redes neuronales utilizan como base de partida técnicas estadísticas conocidas y utilizadas en problemas de clasificación y reconocimiento de patrones o aproximación. En algún caso, el modelo es una representación de una técnica estadística conocida en forma de red neuronal, y también en algún caso, el aprendizaje es directo y no hay ajuste iterativo de los pesos involucrados, lo que aumenta considerablemente la velocidad de entrenamiento. En este trabajo se usarán las Redes Neuronales Probabilísticas o PNN (*Probabilistic Neural Networks*), que representan como red neuronal el conocido clasificador bayesiano. Las redes PNN consisten en dos capas: una capa de base radial oculta y una capa con neuronas de tipo competitivo en la salida, y son el tipo de red de base radial más apropiado para los problemas de clasificación.

Cuando se presenta una entrada, la primera capa computa las distancias desde el vector de entrada a los vectores de entrada del entrenamiento y produce un vector cuyos elementos indican lo próxima que está la entrada respecto a la entrada de entrenamiento. La segunda capa suma estas contribuciones para cada clase de entradas para producir como salida de la red un vector de probabilidades. Finalmente, una función de transferencia competitiva en la salida de la segunda capa recoge el máximo de estas probabilidades y produce un 1 para esa clase y un 0 para las demás. Por tanto, la red clasifica un vector de entrada en una de las clases porque esa clase tiene la máxima probabilidad de ser correcta. Estas redes poseen un parámetro característico denominado “*spread*”. Si el valor del parámetro *spread* es cercano a

cero, la red actuará como un clasificador cercano de vecindad. Conforme *spread* se hace más grande, la red diseñada tendrá en consideración varios vectores cercanos y no será tan exacta.

Las redes probabilísticas compiten con el algoritmo *Backpropagation* (MLP), el cual ha sido aplicado con éxito a una gama amplia de aplicaciones. Las redes PNN no tienen entrenamiento, son robustas en la presencia de ruido, y aproximan la optimalidad bayesiana si el conjunto de entrenamiento es suficientemente grande. En el cerebro biológico no hay nada parecido, pero como modelo de representación de un método estadístico muy usado, puede tener gran interés.

C. Cuantificación del vector de entrenamiento (LVQ)

Existen tres tipos de redes competitivas: Capas competitivas, Mapas autoorganizados o SOM (*Self-organizing maps*) y LVQ (*Learning vector quantization*). En el aprendizaje competitivo, las neuronas de la salida compiten por activarse y sólo una de ellas permanece activa ante una determinada información de entrada a la red. Esta neurona se denomina *prevalente* o *vencedora*, y en función de ella se ajustan los pesos de las conexiones. Las neuronas de las redes competitivas aprenden a reconocer grupos de vectores de entradas similares. Los mapas autoorganizados aprenden a reconocer grupos de vectores de entrada similares de forma que las neuronas que responden a vectores de entrada similares están físicamente cerca unas de otras en la capa. El método LVQ se usa para entrenar capas competitivas de forma supervisada. Una capa competitiva aprende automáticamente a clasificar vectores de entrada, sin embargo, las clases que encuentra la capa competitiva dependen únicamente de la distancia entre los vectores de entrada. Si dos vectores de entrada son muy similares, la capa competitiva los pondrá probablemente en la misma clase al no proporcionarle etiquetas. Por otra parte, LVQ aprende a clasificar los vectores de entrada en etiquetas elegidas por el usuario. Por tanto, a una capa competitiva se le puede pedir que divida los vectores de entrada en un número determinado de clases, pero no se le puede pedir que clasifique un vector cualquiera en una clase determinada.

Una red LVQ posee una primera capa competitiva y una segunda capa lineal. La capa competitiva aprende a clasificar vectores de entrada de la forma que se ha explicado anteriormente. La capa lineal transforma las clases de la capa competitiva en etiquetas de clasificación definidas por el usuario. Ambas capas poseen una neurona por clase. El número de clases de la primera capa debe ser siempre mayor que el de la segunda.

D. Redes de Elman

Las redes realimentadas o recurrentes es un tema de considerable interés. Se estudiará un tipo de redes recurrentes: Redes de Elman. Las redes de Elman son redes *backpropagation* de dos capas, la primera sigmoidea y la segunda lineal, con realimentación desde la salida de la primera capa hasta la entrada de la misma.

Esta conexión recurrente permite a la red de Elman detectar y generar patrones variables en el tiempo. El único requerimiento de este tipo de redes es que la capa oculta posea suficientes neuronas.

3. Entrenamiento

Una vez analizadas las técnicas presentadas en el apartado anterior, se procedió a realizar los entrenamientos con cada una de ellas utilizando los datos de la Tabla I con el fin de encontrar las arquitecturas que mejor reconocieran el *mapping* subyacente de los datos de entrada, clasificando correctamente los vectores en sus etiquetas correspondientes.

En el caso de la red MLP, tras realizar multitud de pruebas y simulaciones, se llegó a la conclusión de que el algoritmo que mejores resultados proporcionaba con los datos utilizados era el *Backpropagation Resistente* con tres capas y 18 neuronas en la capa oculta, ratio de aprendizaje 0.01, 300 iteraciones y meta de la función de actuación $1e-005$. El hecho de que la mayoría de las redes multicapa usen funciones de transferencia sigmoideas presenta muchos inconvenientes, los cuales pueden ser parcialmente eliminados con el algoritmo de entrenamiento *backpropagation* resistente. En este algoritmo el valor actualizado para cada peso y bias se incrementa por un factor cuando la derivada de la función de activación con respecto a ese peso tiene el mismo signo en dos iteraciones consecutivas. El valor actualizado se decrementa por un factor cuando la derivada respecto a ese peso cambia de signo respecto a la iteración anterior. Si la derivada es cero, el valor actualizado se queda igual. Además de ser mucho más rápido de lo normal, este algoritmo requiere muy poca memoria para ser ejecutado.

En la red PNN, el único parámetro necesario es el *spread*. En este caso se eligió un valor de 0.15 para este parámetro, ya que se obtenían resultados muy satisfactorios. La gran ventaja de estas redes es que al no necesitar entrenamiento, su diseño es muy rápido.

La mejor arquitectura encontrada con los datos del presente trabajo para la red LVQ fue con 75 neuronas ocultas, ratio de aprendizaje 0.01, meta de la función de actuación 0 y 250 iteraciones.

La mejor arquitectura encontrada para esta la red de Elman fue con 100 neuronas ocultas, ratio de aprendizaje 0.01, meta de la función de actuación 0 y 3000 iteraciones.

Por tanto, primero se entrenaron las redes utilizando los 326 vectores pertenecientes a uno de los sectores antes mencionados, probando con diferentes arquitecturas y valores de los parámetros para cada técnica hasta encontrar un sistema que ajuste adecuadamente los datos en las etiquetas conocidas. Después, se simuló en las redes entrenadas, que son datos no utilizados en el diseño o entrenamiento de las redes, pero que pertenecen a consumidores similares. Este testeo servirá para comprobar si las redes son también buenas a la hora de generalizar, esto es, de clasificar datos no

entrenados en sus etiquetas correctas, así se podrá ver qué tipos de redes son las mejores para el propósito del presente trabajo.

4. Testeo

Una vez escogida la mejor configuración para cada tipo de red, y habiéndolas diseñado, se procede a realizar el testeo con datos de nuevos consumidores no utilizados en el entrenamiento, cuyos resultados se muestran en este apartado.

Debajo se pueden ver las tablas que muestran los mejores resultados para cada técnica, aplicadas a identificar a cada consumidor en su sector correspondiente. Las tablas indican la cantidad y tipo de las etiquetas identificadas, los consumidores a los que pertenecen dichas etiquetas y el porcentaje que suponen, y el índice de acierto, que es un parámetro que varía entre 0 y 1, correspondiendo 1 a una identificación perfecta, y 0 todo lo contrario.

A. Test Residencial

El número de curvas utilizadas fue 35.

TABLA II. – Resultados Test Residencial

	Etiquetas identificadas	Tipo de consumidor identificado (%)	Índice de acierto
MLP	20 vectores con Etiqueta 5 12 vectores con Etiqueta 19 3 vectores con Etiqueta 20	R1 57.14 R5 34.89 R6 8.57	1
PNN	20 vectores con Etiqueta 5 10 vectores con Etiqueta 19 5 vectores con Etiqueta 20	R1 57.14 R2 28.57 R6 14.29	1
LVQ	7 vectores con Etiqueta 17 1 vector con Etiqueta 18 12 vectores con Etiqueta 19 15 vectores con Etiqueta 20	I3 20 I4 2.86 R5 34.29 R6 42.86	0.77
ELMAN	11 vectores con Etiqueta 5 4 vectores con Etiqueta 17 2 vectores con Etiqueta 18 9 vectores con Etiqueta 19 9 vectores con Etiqueta 20	R1 31.43 I3 11.43 I4 5.71 R5 25.71 R6 25.71	0.83

B. Test Industria

El número de curvas utilizadas fue 31.

TABLA III. – Resultados Test Industria

	Etiquetas identificadas	Tipo de consumidor identificado (%)	Índice de acierto
MLP	16 vectores con Etiqueta 3 14 vectores con Etiqueta 17 1 vector con Etiqueta 18	I1 51.61 I3 45.16 I4 3.23	1
PNN	31 vectores con Etiqueta 17	I3 100	1
LVQ	30 vectores con Etiqueta 17 1 vector con Etiqueta 18	I3 96.77 I4 3.23	1
ELMAN	30 vectores con Etiqueta 17 1 vector con Etiqueta 18	I3 96.77 I4 3.23	1

C. Test Universidad

El número de curvas utilizadas fue 21.

TABLA IV. – Resultados Test Universidad

	Etiquetas identificadas	Tipo de consumidor identificado (%)	Índice de acierto
MLP	4 vectores con Etiqueta 1 7 vectores con Etiqueta 15 10 vectores con Etiqueta 16	U1 19.04 U9 33.33 U10 47.62	1
PNN	2 vectores con Etiqueta 1 4 vectores con Etiqueta 15 15 vectores con Etiqueta 16	U1 9.52 U9 19.04 U10 71.43	1
LVQ	3 vectores con Etiqueta 1 1 vector con Etiqueta 11 17 vectores con Etiqueta 16	U1 14.29 U5 4.76 U10 80.95	1
ELMAN	1 vector con Etiqueta 1 2 vectores con Etiqueta 15 18 vectores con Etiqueta 16	U9 47.62 U10 47.62 U1 4.76	1

Una vez realizados los tres tests, se puede llegar a una serie de conclusiones. De las técnicas empleadas, todas han proporcionado resultados aceptables, pero las que mejor respuesta han dado son la red MLP con algoritmo Resistente y la red PNN, que han acertado en el 100% de los casos. Las red LVQ y la red de Elman han dado peores resultados, y además su entrenamiento es bastante largo (alrededor de 20 minutos) con los datos utilizados (Tabla I). Entre las dos mejores técnicas mencionadas, cabe destacar la red PNN, que además de haber proporcionado excelentes resultados, son de muy fácil aplicación y muy rápidas (unos pocos segundos con los datos utilizados) y robustas, mientras que la red MLP necesita de unos 20 minutos de entrenamiento.

En las siguientes gráficas se muestra un escalado multidimensional de los resultados obtenidos mediante las redes MLP y PNN para ver cómo han identificado a los consumidores pertenecientes a los datos de los distintos tests realizados. En las figuras aparecen los mismos datos de la Fig. 4 a los que se han añadido los correspondientes a los tres tests realizados en este apartado, indicando con un número junto a ellos la etiqueta a la que han sido asociados por la red.

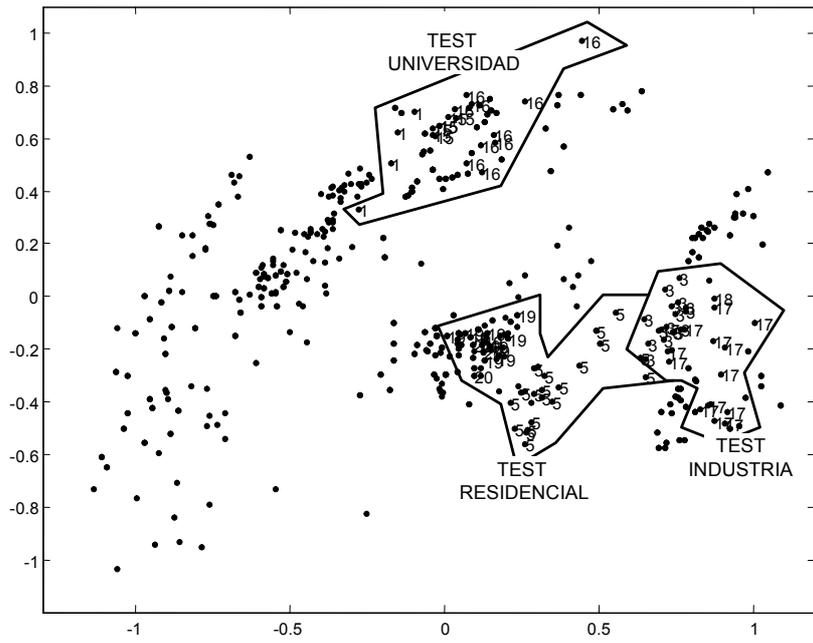


Fig. 5. Testeo MLP, Escalado Multidimensional

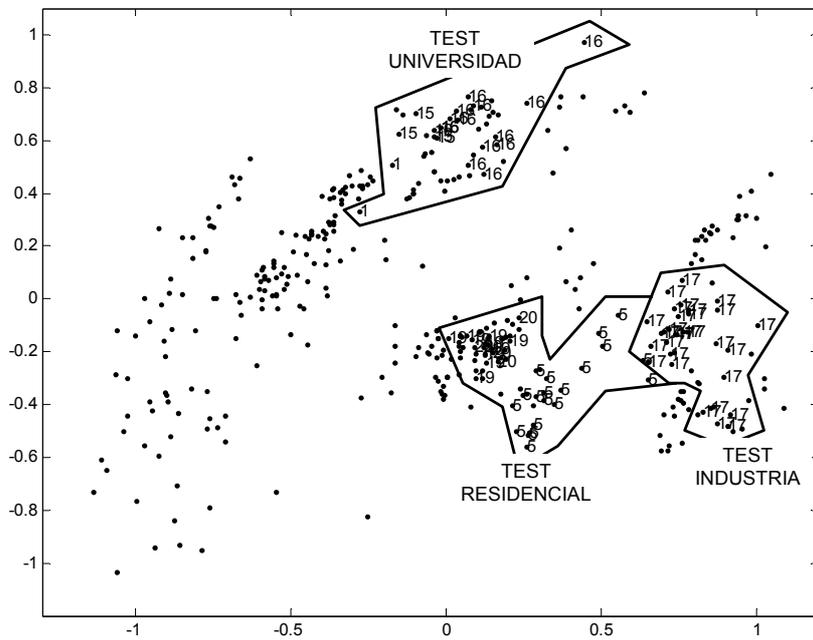


Fig. 6. Testeo PNN, Escalado Multidimensional

5. Conclusiones

Después de entrenar y testear los datos con todas las técnicas, comprobamos que era posible encontrar una arquitectura aceptable con cada una, aunque hay muchas diferencias entre ellas, como la velocidad de entrenamiento o la robustez de la red creada. Por tanto las mejores redes resultantes en cuanto a mejores resultados proporcionados fueron las redes MLP y PNN, siendo ésta última la mejor para el propósito del trabajo, debido a su rápido diseño, al no necesitar entrenamiento, y a la robustez o fiabilidad de los resultados que proporciona.

Las redes neuronales se muestran como unas herramientas muy interesantes para la segmentación de clientes eléctricos, presentando un amplio campo de aplicación.

Referencias

- [1] García Villares, J. L., Blasco, J., Martín del Brío, B., Domínguez, J.A., Barquillas, J., Ramírez, I., Medrano, N. *Short-term electric load-forecasting using ANN. Part II: Multilayer Perceptron for hourly electric-demand forecasting*. 14th IASTED Int. Conf. on Modeling, Identification and Control, IgsI, Austria, February 1995.
- [2] G. Chicco, R. Napoli, F. Piglione, P. Postolache, M.Scutariu, C.Toader. *A Review of Concepts and Techniques for Emergent Customer Categorization*. Available:http://www.telmark.org/2002Sep/2-4_Chicco.pdf.
- [3] Fogelman-Soulié, F. *Applications of neural networks*. In [Arbib 98], 1998.
- [4] S. Valero, M. Ortiz, Fco J. García, N. Encinas, A. Gabaldón, A.Molina, E. Gómez. *Characterization and Identification of Electrical Customers Through the Use of Self-Organizing Maps and Daily Load Parameters*. IEEE Power Energy Systems Conference & Exposition. New York City.10-13. October 2004.