

## Desarrollo metodológico para la optimización del coste eléctrico en fábricas de cemento, mediante inteligencia artificial, operando sobre coste eléctrico del mercado

Manuel Parejo Guzmán, Benito Navarrete Rubia, Pedro Mora Peris,  
Rafaela Alfalla-Luque

Recibido: 3 de Noviembre de 2020  
Aceptado: 4 de Junio de 2021

<https://doi.org/10.37610/dyo.v0i74.598>

### Resumen

Las fábricas de cemento presentan importantes consumos energéticos: el 70 % del coste variable se dedica a energía -33 % térmica y 37% eléctrica-. Este trabajo supone la segunda fase de una investigación para optimizar el coste eléctrico en cementeras mediante técnicas de inteligencia artificial. Tras una revisión sistemática de la literatura, encuestas y panel de expertos a un total de 42 profesionales del sector (primera fase), se ha desarrollado una metodología para optimizar la compra de electricidad. Para ello se propone el uso de Redes Neuronales Artificiales y del algoritmo Backpropagation, de cara a predecir el precio eléctrico spot.

### Palabras clave

Cemento, coste eléctrico, Inteligencia Artificial, (AI), redes neuronales artificiales y precio.

## 1. Introducción

El sector cementero español está sumido en una crisis muy profunda que se ha traducido en una drástica reducción del consumo. Entre 2006 y 2014 dicho consumo de cemento en España se redujo de 55,9 millones de toneladas (t.), lo cual supuso un decremento del 80,67%. La exportación de cemento se ha convertido en un mecanismo para compensar esta situación. En estos últimos años, las exportaciones se han visto muy afectadas por la pérdida de competitividad del sector. Durante 2018 las plantas españolas exportaron un total de 8.103.947 t. de cemento y clinker, cantidad que se vio reducida a 6.232.043t. en 2019 -reducción del 23,1%- (OFICEMEN, 2019)

El consumo energético de una planta cementera tiene un peso muy importante en la cuenta de resultados. Hasta el 70% del coste variable una planta cementera se destina a energía: un 33% a energía térmica del horno y un 37% a energía eléctrica (Swanepoel et al., 2013). Por lo tanto, el coste del consumo eléctrico en la fabricación de cemento resulta un factor de competitividad fundamental.

Según datos ofrecidos por Eurostat, los costes eléctricos de la industria electrointensiva española pueden llegar a ser hasta un 30% superiores a los de otros países europeos (Eurostat, 2019). Ello supone que el precio de la energía eléctrica de la industria española es superior al de la gran mayoría de sus competidores directos. Los datos comparados del coste eléctrico de la industria electrointensiva de los 28 países de la UE, con un consumo de entre 20.000 MWh y 150.000 MWh, que es el intervalo en el que se sitúan el 100% de las cementeras españolas, para el año 2018 -excluyendo impuestos y gravámenes-, dan como resultado que la industria española tiene uno de los costes eléctricos más altos, siendo solo superado por 3 países: Irlanda, Malta y Reino Unido.

En esta situación, el precio eléctrico de la industria electrointensiva en España que, como hemos mencionado, tuvo unos consumos entre 20.000 y 150.000 MWh en 2018, se situó en 78,8 €/MW, mientras que la media de la EU 28 fue de 61,3 €/MW. A modo de ejemplo, algunos de los precios de otros países fueron: Italia, 71,2 €/MW; Portugal, 63,95 €/MW; Alemania, 48,82 €/MW; Francia, 53,1 €/MW. En consecuencia, la industria en España se sitúa en clara desventaja competitiva. A pesar de la relevancia que presenta este tema para el sector, existen escasas investigaciones que hayan abordado la reducción del coste eléctrico en la industria cementera con objeto de desarrollar herramientas que permitan mejorar la competitividad.

Dada la situación planteada, el sector cementero español se enfrenta al problema de pérdida de competitividad y viabilidad, dados sus altos costes eléctricos. Tras una revisión sistemática de la literatura, encuestas y panel de expertos a un total de 42 profesionales del sector, el objetivo de este trabajo será intentar predecir el comportamiento del precio

---

✉  Manuel Parejo Guzmán (1), (2)  
ORCID: 000-0001-5701-9827

 Benito Navarrete Rubia (1)  
ORCID: 0000-0003-0742-7878

 Pedro Mora Peris (3)  
ORCID: 0000-0002-6913-2832

 Rafaela Alfalla-Luque (1)  
ORCID: 0000-0002-9110-8273

(1) Universidad de Sevilla, Spain

(2) Universidad Pablo de Olavide, Spain

(3) Universidad Politécnica de Madrid, Spain

spot de la electricidad, -el cual desconocemos-, es decir el precio del día D-1, para utilizarla el día “D”. De esta manera estaremos en disposición de optimizar el coste eléctrico. La investigación hará uso de la Inteligencia Artificial (AI), incidiendo en la compra de la electricidad, a través del empleo de Redes Neuronales Artificiales (ANN, Artificial Neural Network por sus siglas en inglés) y del algoritmo Backpropagation. El resultado contribuirá a mejorar la competitividad del sector y su viabilidad futura.

Este trabajo se organiza en adelante de la siguiente forma. El segundo apartado describe el marco conceptual, indicándose los resultados obtenidos de la revisión sistemática de la literatura y el panel de expertos, que sustentan el desarrollo de la metodología que se propone para optimizar la compra de electricidad mediante AI. A continuación, se realiza un análisis y discusión de los resultados. Finalmente, se exponen las principales conclusiones obtenidas.

## 2.Marco conceptual: revisión sistemática de la literatura y panel de expertos

Para establecer el marco conceptual de esta investigación y determinar el posible gap en el tema analizado, se ha desarrollado una revisión sistemática de la literatura (Cronin, P. et al., 2008; Hemingway, P., & Brereton, N., 2009). Una revisión sistemática es un proceso de “síntesis de la investigación de manera sistemática, transparente y reproducible, con el doble objetivo de mejorar la base de conocimientos y la formulación y práctica de políticas” (Tranfield, D. et al., 2003). Debido al enfoque estructurado que presenta, la revisión sistemática se ha utilizado en gran variedad de campos científicos, tales como las ciencias sociales, la educación o la gestión de la cadena de suministro (e.g. Oakley, A., 2003; Alfalla-Luque, R. et al., 2013; Fabbe-Costes, N., 2009; Andrés, C., Maheut, J., 2020; Curbelo et al., 2018; Pacheco, E.A. et al. , 2011).

Se realizaron búsquedas en las bases de datos de Scopus, Web of Science y ABI Inform Collection, relacionados con la materia objeto de estudio, haciendo uso de palabras clave (electricity, optimization, artificial intelligence y cement). Del total de artículos obtenidos de las búsquedas (207), tan sólo 12 artículos estaban centrados en aspectos relativos a nuestra investigación (Swanepoel, J.A. et al., 2013; Khotanzad, AI, 2018; Zhang, Jun y Cheng, Chuntian, 2008; Hurtado, L., 2014; Azadeh, A. et al, 2015; Ng and Tong Zhang, 2017; Pavlos S. Georgilakis, 2007; Castañón, S. et al., 2014; Swanepoel, J.A., 2013; Shaohog, Jing et al., 2012;. Andrew, Ng 2017; Wellesley, 2011). Ello muestra la escasa investigación existente en este tema. Tras su análisis detallado, pudimos obtener las siguientes conclusiones:

- Los modelos de ANN multicapa de perceptrón resultan de gran utilidad para predecir los precios futuros diarios de la electricidad.
- La meteorología juega un papel fundamental para predecir precios futuros (Khotanzad, AI, 2018; Zhang, Jun y Cheng, Chuntian, 2008).
- El portfolio de generación eléctrica supone otra importante variable que afecta al precio diario de la electricidad (Hurtado, L., 2014).
- Además de las ANN, pueden utilizarse otras herramientas, como algoritmos genéticos (Azadeh, A. et al., 2015) y lógica difusa (Hurtado, L., 2014), para predecir los precios futuros diarios de la electricidad.

Tras la revisión sistemática de la literatura, de la que se obtuvo menor información de la esperada, se llevó a cabo un estudio basado en encuestas y panel de expertos, en el que participaron un total de 42 expertos. El panel de expertos es un procedimiento efectivo para mejorar el comportamiento de la investigación y proporcionar información adicional sobre la calidad de la investigación (Barbosa, M., & Grayson, D., 2009; Lane, J., et al., 2011). El panel de expertos ha aportado información relevante para diseñar la metodología para optimizar el coste eléctrico haciendo uso de AI.

Para formar un panel de expertos resulta importante contar con revisores con experiencia interdisciplinar, además de con expertos en la materia concreta a estudiar (Quinlan et al. et al., 2008). Los expertos seleccionados para nuestra investigación cumplían estas características. Por una parte, todos los expertos eran profesionales con una experiencia de entre 22 y 41 años en distintos puestos directivos dentro del sector. Por otra parte, entre ellos, existía una formación diversa en la que predominaban economistas, ingenieros civiles, ingenieros industriales, ingenieros de minas y químicos. Las conclusiones más importantes obtenidas fueron:

- Los precios diarios de la electricidad son variables de entrada que resultan útiles para predecir los precios futuros. Para ello pueden emplearse modelos de redes neuronales artificiales.
- La meteorología y el mix energético afectan al precio de la electricidad.
- Es posible reducir los costes eléctricos optimizando la compra de la energía. Para ello se pueden utilizar técnicas de AI basadas en algoritmos genéticos y ANN. Se utilizarán como variables de entrada de estas técnicas, entre otras, los precios eléctricos, los datos meteorológicos y el mix energético.

Con toda la información recabada, a través de la revisión sistemática de la literatura y el panel de expertos, se pudieron determinar las herramientas de AI más idóneas para reducir el coste eléctrico de las fábricas cementeras, basándonos en la optimización de la compra de electricidad. Esto se aborda en el siguiente apartado, en el que se propone una metodología para conseguir tal objetivo.

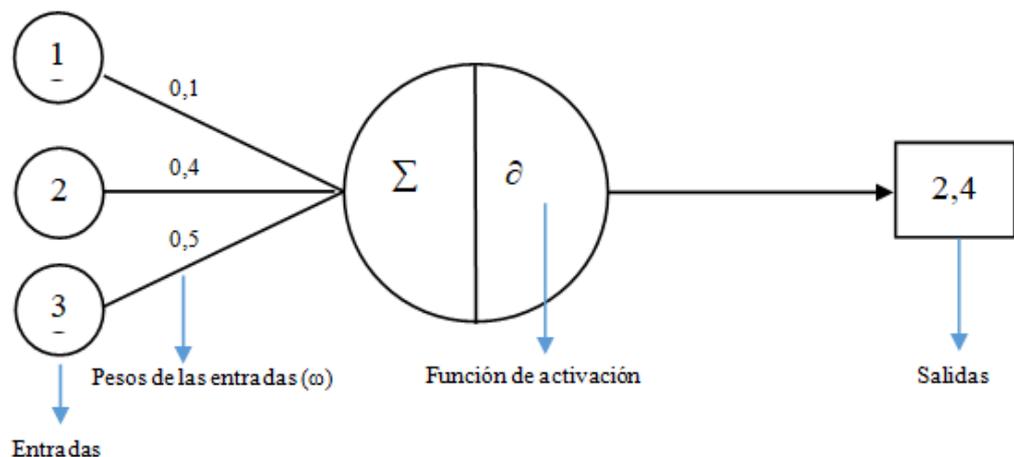
### 3. Propuesta metodológica para optimizar la compra de electricidad: aplicación de herramientas específicas de AI

#### 3.1. Redes Neuronales Artificiales. Aproximación teórica

En este apartado se abordará la metodología de AI que se empleará para reducir los costes eléctricos de una fábrica de cemento, optimizando la compra de la energía. Se utilizarán Redes Neuronales Artificiales (ANN) para predecir precios de compra (Bramer, M, 2007; Lara, J., 2014). Las ANN son modelos matemáticos que se basan en el comportamiento de las neuronas del cerebro humano (Pérez, C., 2007). Estas están conectadas de una forma concreta, organizadas en capas y su objetivo es aprender, de forma que puedan llegar a realizar tareas complejas que no podrían ser realizadas mediante programación clásica.

En la figura 1 aparece la representación gráfica de una neurona artificial. La suma de la entradas multiplicadas por sus pesos asociados, determina el impulso nervioso que recibe la neurona. Este valor se procesa dentro de la neurona mediante una función de activación que lo envía como valor de salida de la neurona

**Figura 1** Neurona artificial.  
 Fuente: elaboración propia.



A semejanza del cerebro humano, las redes reciben una serie de valores de entrada que llegan a un nodo llamado neurona. El primer paso a la hora de poner en funcionamiento una red neuronal, consiste en seleccionar adecuadamente los datos de entrada de manera que sean relevantes, es decir que afecten realmente al resultado final que intentamos predecir (Hernández, J. et al., 2004). Las neuronas de la red están a su vez agrupadas en capas.

Existen tres tipos de capas (Hernández, J., et al., 2004).

- Capa de entrada. Es la que recibe la información del exterior.
- Capas ocultas. Procesan la información internamente.
- Capa de salida. Es la que obtiene la respuesta de la red y la transfiere al exterior.

Cada neurona posee un peso (ω), con el que modifica la entrada recibida. Los nuevos valores obtenidos salen de las neuronas y continúan su camino por la red. El valor obtenido en cada neurona [1] sería un modelo de regresión lineal al que se le sumaría un sesgo -conocido como bias- "b".

$$Y = X_1 * \omega_1 + X_2 * \omega_2 + X_3 * \omega_3 + b \quad [1]$$

Lo normal es que el resultado obtenido por la red neuronal inicialmente (Y), no coincida con el resultado real; esto se debe a que la red debe recibir cierto entrenamiento y aprender a realizar su función correctamente. El entrenamiento se realiza modificando los pesos de las neuronas de manera que consiga acercarse lo más posible a los resultados deseados. Surge así una de las redes más extendidas, conocida como Perceptrón Multicapa -Multilayer Perceptron-MLP (Lara, J., 2014).

En este modelo se van introduciendo datos de entrenamiento a la red. Si el resultado que da la red con los pesos introducidos da un resultado erróneo, se modifican los pesos hasta que se minimice o elimine el error. Este método algorítmico de entrenamiento, que utilizaremos en nuestra investigación, se denomina Backpropagation o propagación hacia atrás. La red calculará los errores como la variación que tiene lugar entre el resultado obtenido y el resultado correcto para cada grupo de pesos, utilizando para ello derivadas. El objetivo del algoritmo Backpropagation, será minimizar este error (E) [2]. El error se expresará como diferencia entre el valor de la salida y el resultado correcto y se elevará al cuadrado, dado que no resulta relevante que el error tenga un valor positivo

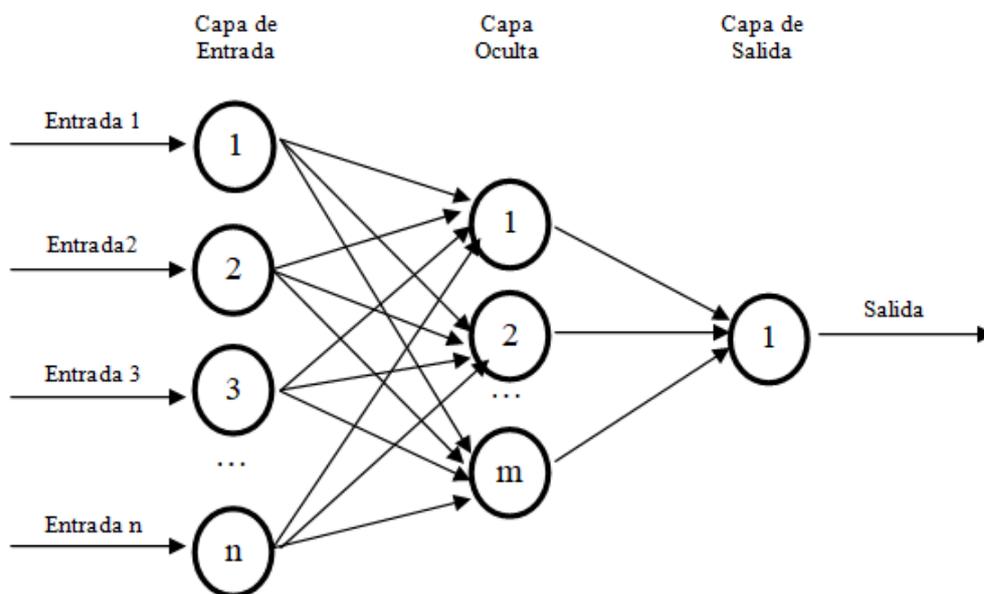
o negativo. Además se multiplicará por 1/2, para simplificar el cuadrado cuando calculemos la derivada. La derivada servirá para obtener la variación del error respecto a la variación de los pesos.

$$E = 1/2 (y-S)^2 \rightarrow \partial E / \partial \omega \tag{2}$$

*E: Error // y: Valor correcto // S: Salida de la red neuronal*

Una vez alcanzado el final de la red neuronal, con un error nulo o cercano a cero, se considera que la red está suficientemente entrenada (Figura 2).

**Figura 2** Funcionamiento de la Red Neuronal con el algoritmo Backpropagation.  
 Fuente: Elaboración propia



### 3.2. Metodología para optimizar la compra de electricidad en el mercado

El mercado de la electricidad en España se organiza en una secuencia de mercados en los que generación y demanda intercambian energía y reservas para distintos plazos

Días, semanas, meses e incluso años antes del momento en que la energía sea consumida, los agentes podrán intercambiar contratos de distinta duración en el mercado a plazo que gestiona el Operador del Mercado Ibérico de Energía - Polo Portugués (OMIP) o en el Mercado over the Counter (OTC).

Al llegar el día anterior al despacho, D-1, los agentes intercambian la energía para cada hora del día “D” en el mercado organizado por el Operador del Mercado Ibérico de la Energía (OMIE). Dentro de las 24 horas anteriores al momento de generación y consumo de la energía, los agentes podrían ajustar posiciones comprando y vendiendo energía en los mercados intradiarios, también gestionados por OMIE (<http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>) (Tabla 1).

**Tabla 1** Secuencia de mercados en el mercado ibérico de electricidad (MIBEL).

Fuente: *Elaboración propia*

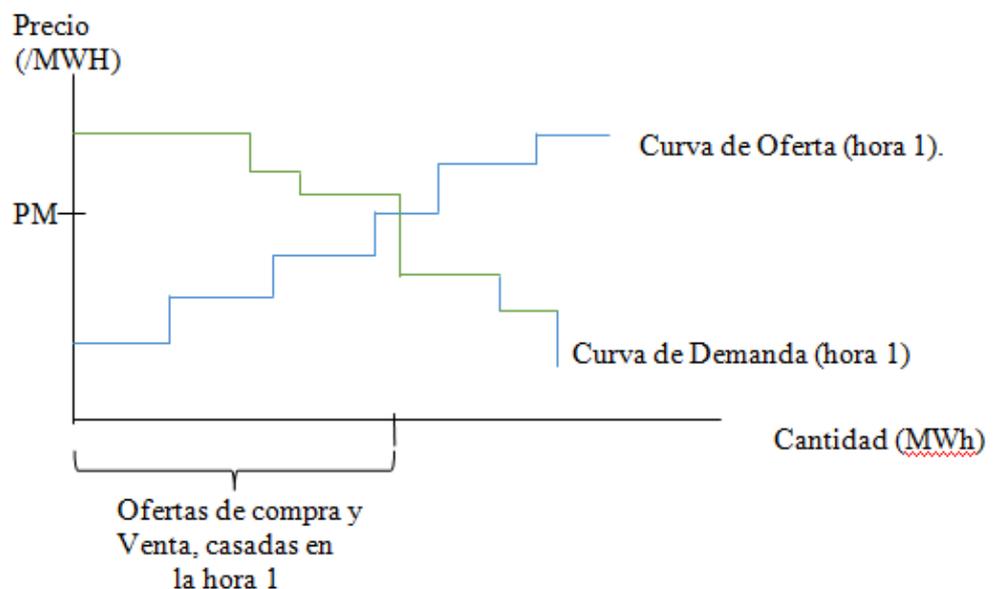
TIEMPO	MERCADO	GESTOR	
Antes del despacho (antes D-1)	Contratos bilaterales	OMIP /OTC	Mercado a plazo
Día anterior al despacho (D-1)	Mercados día anterior	OMIE	Mercado diario
Día del despacho (D)	Mercado intradiario	OMIE	Mercado a C/P

El mercado diario (precio spot) se celebra el día anterior al de la entrega de la energía y en él los compradores y vendedores, intercambian energía para cada una de las 24 horas del día siguiente. Los compradores presentan sus ofertas de compra para cada una de las 24 horas del día siguiente. Los vendedores hacen lo propio y llevan a cabo

sus ofertas de venta para cada una de estas 24 horas. Con estas ofertas OMIE construye las curvas de oferta y demanda de energía para cada hora del día siguiente. El cruce de estas curvas determina el precio eléctrico para cada hora del día siguiente (Figura 3).

**Figura 3** Curvas Oferta y Demanda de la electricidad del Mercado.

Fuente: *Elaboración propia*

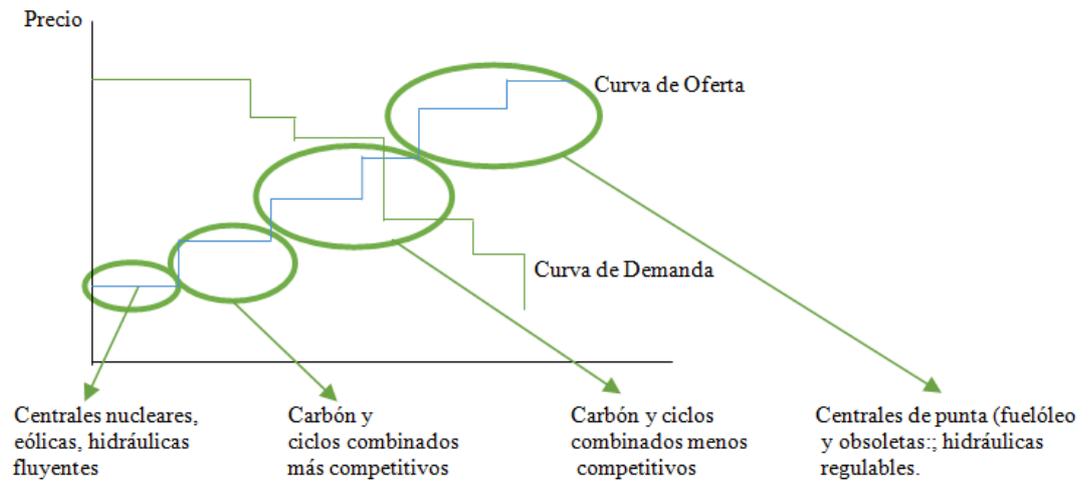


El mercado diario es un mercado marginalista, es decir, que todos los generadores reciben un mismo precio que se determina por el cruce de oferta y demanda. A continuación se verá como se van agregando las distintas ofertas de venta.

Como se muestra en la figura 4, una vez que los vendedores han presentado sus ofertas para cada hora del día siguiente, OMIE las agrega de manera ordenada por precio ascendente. En la curva quedan reflejados los escalones que corresponden

a ofertas de centros de generación de la misma tecnología. La oferta de los vendedores reflejan sus costes de oportunidad -no los costes totales ni variables-. Así, en el primer escalón aparecen las centrales nucleares y las hidráulicas fluyentes, que tienen costes de oportunidad muy bajos. En la parte alta aparecen las centrales hidráulicas regulables, que tienen costes de oportunidad altos, pues pueden reservar el agua para producir en otro momento el que el precio de mercado sea más alto.

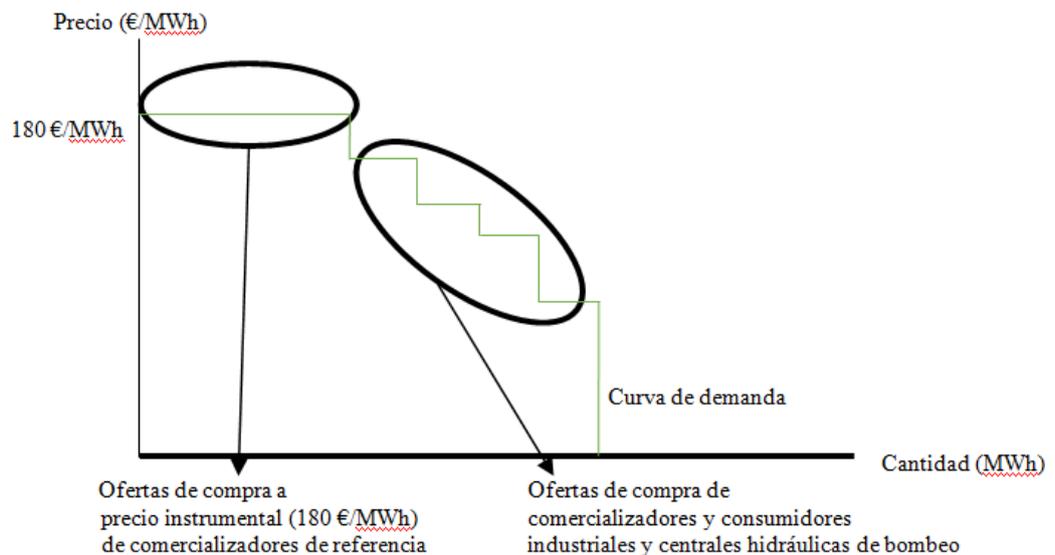
**Figura 4** Curva de Oferta de la electricidad del Mercado.  
 Fuente: *Elaboración propia*



El funcionamiento de la demanda de electricidad es similar al de la oferta. Los consumidores finales se clasifican en tres grupos: grandes consumidores industriales, como grandes industrias, transporte ferroviario, etc.; consumidores medios y pequeños. La demanda de electricidad, determinante para

establecer el precio marginal, dependerá de varios factores, como la laboralidad y las condiciones meteorológicas y ambientales, entre otros. La curva de demanda tendrá varios tramos (Figura 5).

**Figura 5** Curva de demanda de electricidad del mercado.  
 Fuente: *Elaboración propia*



Los comercializadores de referencia suelen ofertar al precio instrumental -máximo permitido- (180 €/Mwh), de manera que se aseguran que los consumidores -sus clientes-, dispondrán de la energía que demanden. Esto no quiere decir que finalmente se pague este precio, pues como se ha indicado el mercado eléctrico es un mercado de precio marginalista.

Una parte de los consumidores eléctricos solo está dispuesta a adquirir la electricidad si esta presenta un precio menor o igual a cierto valor, dado que pueden adaptar su consumo a los precios de cada momento.

La intersección de las curvas de oferta y demanda para la hora  $h$  del día  $D$ , determinará el precio de la misma para ese momento. Así, en cada una de las horas del día las distintas ofertas de venta y compra que resulten casadas recibirán/pagarán el precio establecido (<http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>).

En el mercado a plazos se intercambia la energía para distintos plazos de tiempo (años, meses, semanas, etc.). En el largo y medio plazo rigen distintos tipos de contratos:

- Contratos bilaterales, que se adaptan a las necesidades de los agentes, compradores y vendedores que operan en el mercado. Destaca el mercado Over The Counter (OTC), en el que los agentes intercambian contratos diseñados en función de sus preferencias.
- Productos estandarizados a través de mercados organizados, gestionado por OMIP.

En ausencia de mercados a plazo (futuros), los agentes deberán de comprar la electricidad en el mercado diario, cuyo precio resulta desconocido en el momento de ofertar. Con los mercados a plazo es posible contratar la energía por adelantado, a un precio cerrado en el momento de compra. De esta manera el comprador de electricidad elimina el riesgo de incurrir en pérdidas debidas a errores en la estimación del precio de mercado. Se trata de fijar un precio con el que tanto comprador como vendedor se sientan cómodos de cara al futuro.

El precio Call, -al que se puede adquirir hoy la energía a futuro, para utilizarla el día “D”-, es conocido en el momento inicial. El objetivo de esta investigación será intentar predecir, mediante el uso de redes neuronales, el comportamiento del precio spot de la electricidad -el cual desconocemos-, es decir el precio del día D-1 para utilizarla el día “D”. De esta manera estaremos en disposición de decidir, en función de los precios obtenidos, a qué precio adquirir la energía.

Veamos el planteamiento con un ejemplo. Si hoy fuera 1 de octubre de 2020 y necesitara comprar electricidad para usarla el 1 de octubre de 2021 (“D”), dispondría de dos opciones:

Opción 1: Comprar electricidad a precio Spot (desconocido en el día de hoy) el 30 de septiembre de 2021 (Día “D-1”).

Opción 2: Comprar electricidad a precio Call 2021. Este sería el precio al que puedo adquirir la electricidad hoy -1 de octubre de 2020-, para consumirla el 1 de octubre de 2021. Se trata de un precio a futuro conocido a fecha de hoy.

Se analizará como se forma el precio spot del mercado diario de la electricidad (<http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>). De acuerdo con la teoría económica, el precio esperado del mercado diario constituye el coste de oportunidad del mercado a plazo; es decir, este último refleja el precio esperado del mercado diario. Para facilitar la comprensión de este concepto, se presenta el proceso paso a paso:

- A cualquier agente se le presentan dos opciones a la hora de adquirir la electricidad.
  1. Comprarla a plazo, con un precio conocido a fecha actual.
  2. Comprarla en el mercado diario, al precio que tenga en el día D-1.
- Dado que el mercado a plazo precede al diario, el agente que opera en el mismo está renunciando a operar en el mercado diario, de cara a obtener un precio de compra seguro que le satisfaga.
- Por lo tanto los agentes valoran los contratos a plazo en función de los precios esperados en el mercado diario. Por lo tanto, en términos puramente económicos, el precio esperado en el mercado diario (Spot) constituye el coste de oportunidad del mercado a plazo (call).
- Así, dado el coste de oportunidad del mercado Call a plazo, será el precio esperado en el mercado diario (Spot).

En la formación del precio de la electricidad, se han identificado distintos factores que pasaremos a analizar (Khotanzad, AI, 2018; Zhang, J. y Cheng, C., 2008; Hurtado, L., 2014; Pezzutto, S. et al., 2018.; <http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>):

1. Generadores de oferta. Existe un volumen de ofertas de venta con precios muy bajos, correspondientes a generadores con dificultad para parar de producir energía (centrales nucleares) o bien que tienen que generar electricidad obligatoriamente (centrales hidroeléctricas que estén descargando), o bien son generadores con costes variables muy bajos o primados (centrales fotovoltaicas, eólicas, etc.). El volumen de oferta de energía a precios bajos condicionará el precio marginal final.

2. Generadores de demanda. Existen consumidores con demanda inelástica, los cuales van a consumir la misma cantidad de electricidad con independencia del precio. Estos consumidores ofrecen como precio el máximo permitido (180 €/MWh), si bien saben que acabarán pagando no ese precio, sino el marginal. Hay otros consumidores que sólo están dispuestos a tomar energía si su precio es menor o igual a un cierto valor (el cual reflejan en sus ofertas al mercado). Son consumidores que tienen posibilidad de adaptar su consumo a los precios del mercado.
3. Tecnologías de generación / precio materias primas. Abordaremos las tecnologías de generación eléctrica más importantes que más influyen en la generación del precio:
  - 3.1. Energía nuclear. Se basa en la fisión de núcleos de uranio para generar vapor, el cual genera electricidad a través de una turbina. No se emiten gases contaminantes a la atmósfera, pero se producen residuos nucleares de alta, media y baja actividad que deben ser depositados en vertederos especiales de manera controlada durante muy largos periodos de tiempo. Presenta costes fijos bastante altos, pero sus costes variables son muy bajos, lo cual la hace muy competitiva.
  - 3.2. Energía eólica. Se produce electricidad transformando la energía cinética del viento. Además de no emitir contaminantes, no necesita de un recurso primario que sea necesario transformar. Uno de los mayores inconvenientes que presenta es que al depender del viento, ofrece una producción intermitente. El precio depende, entre otros factores, de la meteorología.
  - 3.3. Energía solar. Existen dos formas de aprovechar la energía solar para producir electricidad: tecnología fotovoltaica y tecnología termoeléctrica. Depende también, entre otros factores, de la meteorología.
  - 3.4. Cogeneración. Se trata de instalaciones que producen de manera simultánea energía eléctrica y térmica útil. Tiene la ventaja de que, debido a su alto nivel de rendimiento, genera pocas emisiones contaminantes. Se trata de una tecnología con costes bajos.
  - 3.5. Hidráulica fluyente. No dispone de grandes reservas de agua, por lo que depende del aporte de agua en cada momento. Su coste variable es muy bajo, sin bien tiene costes fijos considerables. El precio depende, entre otros factores, de la meteorología.
  - 3.6. Hidráulica con reservas anuales (regulable). Almacena agua en un embalse con gran capacidad y produce electricidad en función de dos variables: expectativas de lluvias y precio futuro de la electricidad. Su coste variable es bajo, pero presenta costes fijos importantes. Presenta además gran flexibilidad en la producción. El precio depende, entre otros factores, de la meteorología.
  - 3.7. Hidráulica por bombeo. Obtiene un margen económico bombeando agua a un nivel superior al que se encuentran las turbinas, en momentos en los que la electricidad es barata. A continuación, cuando el precio es superior, producen y comercializan la electricidad haciendo fluir el agua embalsada hacia las turbinas. Cuenta con gran flexibilidad. Sus costes variables son moderados, pero tienen costes fijos considerables. El precio depende, entre otros factores, de la meteorología.
  - 3.8. Centrales térmicas convencionales. Es una tecnología que genera electricidad quemando un combustible fósil: carbón, gas o fuelóleo. El vapor generado mueve una turbina produciendo energía eléctrica. Presentan impacto ambiental, pues emiten gases contaminantes y partículas a la atmósfera. Las centrales de fuelóleo y de gas son bastante flexibles, no siendo así las de carbón. Estas últimas pueden tener, en función de combustible utilizado, costes variables altos o bajos. Cuando se usa carbón importado -con mayor poder calorífico que el autóctono y mejor precio-, los costes son inferiores que cuando se usa carbón nacional. El precio de las centrales de carbón depende del precio de los futuros del carbón (API 2), paridad entre el € y el \$ y precio del CO<sub>2</sub> (este último puede afectar en torno a un 30%). El precio del gas natural y el fuelóleo, obedecerían a patrones similares.
  - 3.9. Ciclo combinado. La energía térmica del gas natural, mediante dos ciclos termodinámicos diferentes -primero una turbina de gas y después una de vapor-, es transformada en electricidad. Su precio depende, entre otros del precio de los futuros de gas (TTF) y del CO<sub>2</sub> (hasta un 16% aproximadamente).
  - 3.10. Interconexiones Internacionales. Se utilizan cuando el precio en España es superior al internacional.
  - 3.11. Otras: Centrales de generación a partir de biomasa, energías del mar, geotermia, etc.

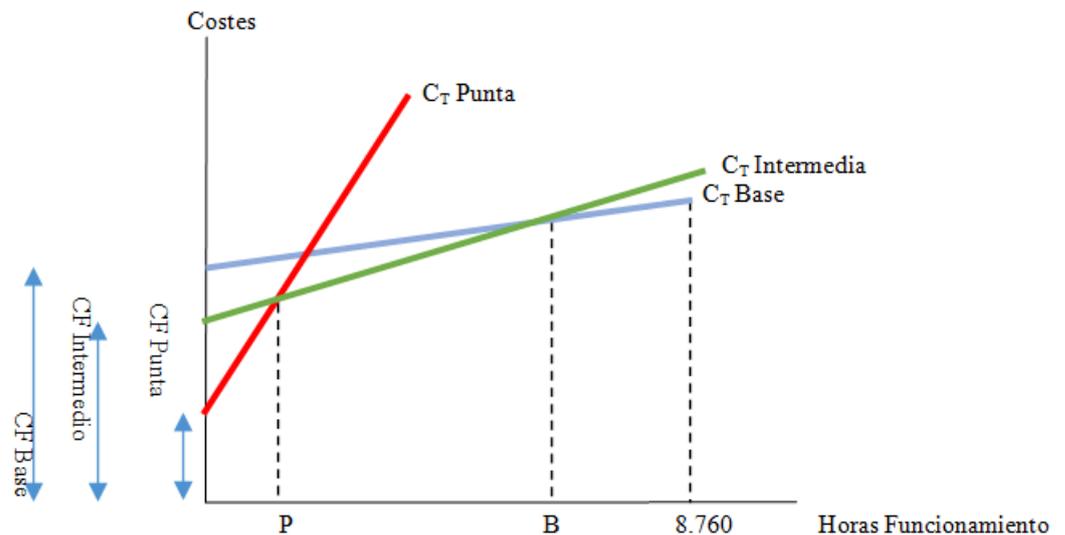
Como se ha visto, cada tecnología tiene distintas estructuras de costes fijos y variables; además, la flexibilidad para adaptarse a las variaciones de la demanda no es igual en todos los casos. En función de estos condicionantes, en un mismo instante se podría estar generando electricidad proveniente de distintas tecnologías. Podrían establecerse tres bloques atendiendo a las estructuras de coste de cada una de las tecnologías:

- Tecnologías de base. Conformadas por aquellas con costes fijos altos y variables relativamente bajos: nucleares, algunas centrales de carbón -sobre todo las de carbón importado-, cogeneración y ciclos combinados.
- Tecnologías intermedias. Presentan costes fijos y variables intermedios. Algunas centrales de carbón y ciclos combinados y centrales hidráulicas regulables.

- Tecnologías punta. Tiene costes fijos bajos y variables altos. Encontramos las centrales de fuelóleo y turbinas de gas.

En la figura 6 se puede observar como cada grupo de tecnologías es óptima (coste total mínimo) para un determinado número de horas de funcionamiento al año. Así, durante una serie de horas -entre 0 y P-, la tecnología punta es la óptima. Para unas horas de funcionamiento esperadas al año -entre P y B-, la tecnología intermedia sería la óptima. Por último, para unas horas de funcionamiento esperadas al año mayores que B, la tecnología óptima es la de la base.

**Figura 6** Uso óptimo de dada grupo de tecnologías en la generación eléctrica.  
 Fuente: Elaboración propia



Cada una de las tecnologías eléctricas presenta una volatilidad diferente. Las centrales hidráulicas tienden a depender de las aportaciones hidráulicas del año, sobre todo en el caso de las fluyentes. Las que tienen embalses presentan una dependencia menor, que es totalmente inexistente en el caso de las centrales de bombeo.

Las utilización de las centrales nucleares resulta bastante estable. Al tener costes variables muy bajos, producen casi de manera ininterrumpida, con independencia del precio de mercado.

La utilización de tecnologías de producción a partir de fuentes de energía renovables, cogeneración y residuos, depende de la disponibilidad de energía primaria (viento, sol, biomasa, etc.). Al estar gran parte de estas tecnologías subvencionadas y tener costes variables muy bajos, se producen con independencia del precio del mercado.

Las centrales térmicas convencionales (carbón y fuelóleo) y ciclos combinados, dependen de la producción de tecnologías fluyentes e hidráulicas con embalses y de bombeo. La parte que no se cubre con estas últimas tecnologías ha de ser cubierta mediante térmicas y ciclos combinados y recibe el nombre de “huevo térmico”; estas cierran los últimos precios. El coste de la electricidad generada por estas tecnologías, depende del precio de las fuentes energéticas primarias (carbón, gas, etc.).

4. Climatología. Existen diversos factores climáticos que afectan al precio de la energía: temperaturas, viento y lluvia. Los días de mucho frío o calor, el consumo eléctrico se dispara, pues crece el volumen de demanda inelástica. Los días de mucho viento y lluvia los precios, sobre todo a últimas horas del día, suelen bajar.

5. Laboralidad. Los días festivos, al reducirse la demanda inelástica, se reducen los precios.
6. Estacionalidad. En los meses de mucho calor -julio y sobre todo agosto-, la electricidad suele ser más cara.
7. Hay otros dos aspectos que incorporaremos al modelo y que afectan a la predicción del precio spot que se dará en el día D. Se trata de la relación entre el precio diario de hoy ( $Pr_i$ ) y del precio call de la electricidad (precio al que puedo adquirir hoy la electricidad para utilizarla el día D+1).

En nuestro modelo utilizaremos una función [3], para tener en cuenta el efecto que en el precio spot tienen el precio diario ( $Pr_i$ ) de cada hora del año, combinado con el precio Call a futuro y con el resto de variables analizadas anteriormente: mix energético, meteorología, laboralidad y estacionalidad. Para considerar la influencia del precio diario de hoy en la formación del precio spot, debemos tener en cuenta que para la industria electrointensiva existen 6 precios diferentes ( $Pr_1, Pr_2, Pr_3, Pr_4, Pr_5$  y  $Pr_6$ ) que van teniendo valores decrecientes desde  $Pr_1$   $Pr_6$ . Para nuestro modelo consideraremos el cociente entre el precio más alto ( $Pr_1$ ) y el más bajo ( $Pr_6$ ) en cada momento, es decir  $Pr_1/Pr_6$  como referencia de la situación de los precios en cada momento.

A tal efecto se preparará una tabla (tabla 2) para recogida de datos con los  $Pr_1$  y  $Pr_6$  de cada una de las 8.760 horas del año. Incluiremos una columna más que relacionará el  $Pr_1$  (precio más alto del día), con el  $Pr_6$  (precio más bajo del día), obteniendo así  $Pr_1/Pr_6$

**Tabla 2** Precios diarios para el mes de enero del año “N” y cociente  $Pr_1/Pr_6$ .  
 Fuente: Elaboración propia

ENERO	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
$Pr_1$	52	53	53	54	55	54	54	53	52	52	56	54	53	54	56	52	54	53	53	56	57	52	52	53	52	56	57	58	56	56	57
$Pr_6$	51	51	50	49	47	48	48	51	49	47	48	48	51	52	53	51	50	51	51	50	49	47	48	48	49	51	52	51	50	50	50
$Pr_1/Pr_6$	1,02	1,04	1,06	1,10	1,17	1,13	1,13	1,04	1,06	1,11	1,17	1,13	1,04	1,04	1,06	1,02	1,08	1,04	1,04	1,12	1,16	1,11	1,08	1,10	1,06	1,10	1,10	1,14	1,12	1,12	1,14

A continuación estableceremos la siguiente función de base para la red neuronal, con objeto de evaluar el precio spot horario [3]:

$$\text{Precio Spot} = F(\text{Pr}_1/\text{Pr}_6, \text{Precio Call } X, \text{ mix energético, meteorología, laboralidad, estacionalidad}) * \omega_{iF} \quad [3]$$

Para cada una de las 8.760 horas del año obtendremos a partir de los precios diarios de hoy ( $\text{Pr}_i$ ) un P1/P6 y un mix energético concreto.

En la figura 7 se plantea la Red Neuronal Artificial que servirá para analizar la formación del precio spot. La metodología que se propone para la aplicación de la Red Neuronal cuenta con los siguientes pasos:

a. Entrenar a la red neuronal con el algoritmo de aprendizaje supervisado Back Propagation para determinar cómo afecta cada variable de entrada (neuronas color blanco), a la composición del mix eléctrico (color verde). En la capa oculta, el sistema determinará los pesos correctos de los distintos  $\omega_{ij}$ , teniendo presente que debe cumplirse que  $\sum \omega_{i8} = 1 / i = 1, 2, 3$ . //  $\sum \omega_{i9} = 1 / i = 1, 2$ .

b. Determinar como afecta el mix energético (neuronas color verde), el cociente P1/P6 (neurona azul), la laboralidad (neurona roja), la estacionalidad (neurona amarilla) y el precio call futuro (neurona rosa), al precio spot. Al igual que en el apartado anterior se entrenará la red neuronal con datos históricos de manera que la misma sea capaz de determinar los valores más exactos de los  $\sum \omega_{i5}$  que afectan a estas variables. Hemos de tener en cuenta en esta ocasión que  $\sum \omega_{i5} = 1$ . //  $i = 1, \dots, 14$ .

El objetivo consiste en facilitar a la ANN datos suficientes para que mediante aprendizaje -deep learning-, pueda predecir el valor del precio spot. Una vez que el sistema conozca como afectan cada una de las 21 variables (7 neuronas blancas, 10 verdes, 1 azul, 1 roja, 1 amarilla y 1 rosa) al Precio Spot, dado que conocemos el valor del precio call a futuro al que podemos adquirir la electricidad en el día de hoy, estaríamos en disposición de decidir a que precio compramos la electricidad: hoy a precio Call o bien el día "D-1" a precio spot; en ambos casos para utilizarlo en el día D.

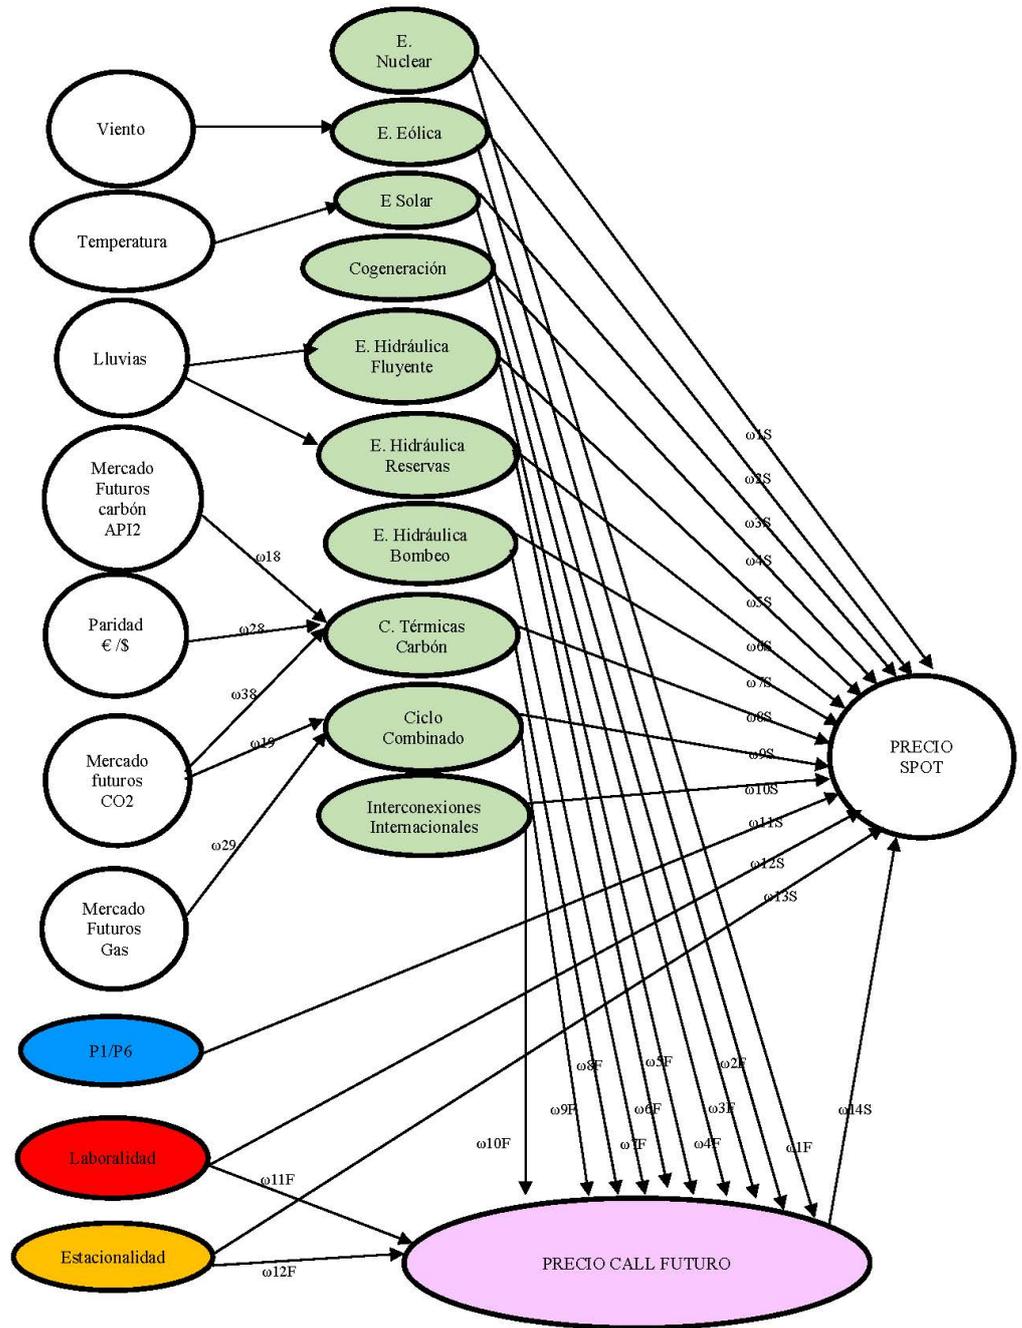
Si la red neuronal predijera que el precio Spot del día "D-1" será mayor que el Precio Call que se da hoy, se adquiriría hoy la electricidad en el mercado de futuros al precio call. Si predijera un menor precio, se compraría la electricidad en el mercado diario spot el día "D".

Para seleccionar como herramientas de AI más idóneas la ANN y el algoritmo Backpropagation, así como las distintas variables que se han utilizado para alimentar la red, tal y como aparece en la figura 7, se ha tenido en cuenta la información recabada en el análisis sistemático de la literatura llevado a cabo. Los artículos consultados y que se mencionan en el apartado 2 de este artículo, hacen referencia expresa a variables tales como la meteorología, la laboralidad y el mix energético, entre otros. Los expertos en materia energética consultados en el panel han aportado otra batería de variables, a la vez que matizado las seleccionadas mediante el análisis bibliográfico. El hecho de basar la selección de las variables en estas dos fuentes -bibliografía y expertos- nos hace llegar a la conclusión de que las mismas son representativas para explicar el precio spot que pretendemos predecir.

Llegados a este punto, resulta fundamental determinar como afectan cada una de las 21 variables seleccionadas a la formación del precio spot, de qué manera y con qué peso. Para ello, tanto la bibliografía como los expertos del sector consultados, han coincidido en la idoneidad de usar las ANN -Multilayer Perceptron- y el algoritmo de entrenamiento Backpropagation. La gran ventaja de estas herramientas, es que determinan el peso  $\omega_{ij}$ , de cada una de las variables en la formación del precio spot. Se trata del funcionamiento normal de las ANN entrenadas con el algoritmo Backpropagation: partiendo de unos pesos iniciales  $\omega_{ij}$ , van aprendiendo con cada época - cada ciclo de corrección de propagación hacia atrás y hacia adelante para reducir la pérdida- hasta llegar a determinar el peso correcto de cada una de las variables que influyen en la formación del precio spot. Por lo tanto, estas fuentes y los planteamientos que se han expuesto, justifican la elección de la ANN y el algoritmo Backpropagation como herramientas y de las variables de partida para nuestro modelo.

Tras el entrenamiento de la red obtendremos un modelo fiable de predicción de precios. Este modelo habrá de ser testado empíricamente en un proyecto piloto para ajustarlo lo más posible a la realidad, antes de darlo como definitivo y proceder a su implementación en la planta cementera.

**Figura 7** Red Neuronal para determinar el precio eléctrico spot y futuro.  
 Fuente: Elaboración propia



### 4. Discusión de los resultados y conclusiones

Tras la revisión sistemática de la literatura, solo se han encontrado artículos que abordan la optimización del coste eléctrico en fábricas de cemento, que se basan de manera exclusiva solo en uno de los tres aspectos que integran nuestra investigación: optimización de variables de proceso (e.g. Swanepoel et al.(2013); Swanepoel (2013)), precios eléctricos regulados y precios de mercado (e.g.. Pavlos S. Georgilakis (2007); Khotanzad, AI (2018). Zhang, Jun y Cheng, Chuntian (2008)). Además, en muchos casos se hacía uso de modelos estadísticos y no de herramientas de AI (e.g. Castañón, A.M.,(2014)). Nuestra investigación integra los 3 procedimientos de manera simultánea y complementaria; uno de ellos, la optimización de la compra de energía, se analiza en profundidad en este trabajo. De esta manera se da la posibilidad de alcanzar un grado de optimización del coste eléctrico mucho mayor que el analizado en otros procesos de investigación, haciendo uso, además, de herramientas de AI. Esta cuestión se representa un aspecto completamente innovador respecto a la literatura previa.

Ante la escasez de bibliografía sobre esta temática, se ha empleado un panel de expertos, del que se han obtenido datos que han permitido desarrollar un estudio cuantitativo sobre la composición del coste eléctrico regulado de la industria cementera española totalmente novedoso, que ha resultado de utilidad a la hora de abordar en nuestra investigación los costes eléctricos regulados. Además, servirá de base para futuras investigaciones sobre los aspectos eléctricos del sector cementero español.

El resultado final obtenido tras el proceso de investigación, es un modelo de optimización del coste eléctrico que resulta aplicable a cualquier fábrica de cemento del mundo. Además, introduciendo ciertas modificaciones, se podría aplicar a otras industrias de transformación electrointensivas. Como se ha explicado anteriormente, se trata además de un modelo novedoso que ofrece la posibilidad de alcanzar mayores reducciones de coste, aportando de esta manera mayor competitividad al sector cementero, inmerso actualmente en una situación crítica. Esto constituye la implicación más importante desde el punto de vista de los directivos de las empresas cementeras.

Como principales conclusiones de este trabajo podemos indicar:

1 Este artículo forma parte de un proceso de investigación que integra tres procedimientos diferentes para optimizar el coste eléctrico en fábricas de cemento. El primer procedimiento incide sobre determinadas variables del proceso productivo de fabricación de cemento. El segundo optimiza los precios eléctricos regulados. El tercero, objeto de este artículo, incide sobre los precios de compra de electricidad en los mercados spot y futuro.

- 2 Es posible optimizar el coste eléctrico en las fábricas de cemento optimizando la compra de electricidad en los mercados spot y a plazo, utilizando para ello herramientas de AI tales como las ANN.
- 3 El modelo que resulta de este proceso de investigación es aplicable a cualquier fábrica de cemento del mundo. Introduciendo diversas modificaciones incluso podría aplicarse a otras muchas industrias de transformación electrointensivas. Se trata por lo tanto de un modelo que cuenta con gran versatilidad.
- 4 Este modelo mejora el desarrollo de productos -cemento y otros productos industriales-. La metodología desarrollada contribuye a influenciar y transformar nuestra manera de vivir y trabajar, dado que hace que las industrias sean más competitivas. La competitividad ayuda a las empresas a generar más actividad, valor añadido y empleo.

### Referencias Bibliográficas:

- Alfalla-Luque, R., Medina-Lopez, C & Prasanta Kumar Dey (2013) Supply chain integration framework using literature review, *Production Planning & Control: The Management of Operations*, 24:8-9, 800-817, DOI: 10.1080/09537287.2012.666870.
- Andrés, C., Maheut, J., 2020. Secuenciación con almacenes limitados. Una revisión de la literatura]. *Dirección y Organización* (64), pp. 5-35.
- Andrew Ng (2017) Artificial Intelligence is the New Electricity. *Newstex Global Business Blogs*.
- Andrew Ng and Tong Zhang (2017). The Optimistic Promise of Artificial Intelligence; how AI is going to be like electricity, transforming every industry. *Wall Street Journal on line* (ISSN: 2574 9579).
- Azadeh, A., Sohrabi P. y Saberi ,M. (2015). A unique meta-heuristic algorithm for optimization of electricity consumption in energy-intensive industries with stochastic inputs. *International Journal of Advanced Manufacturing Technology* (ISSN: 1443-3015).
- Barbosa, M., & Grayson, D. (2009). Site visits: Assessing and improving the climate for women in physics. In Harline, B. K., Horton, K. R., & Kaicher, C. M. (Eds.), *AIP conference proceedings* (Vol. 1119, pp. 14–15). American Institute of Physics doi:10.1063/1.3137748.
- Bramer, M. *Principles of Data Mining*, London: Springer, Marc, 2007.

- Chaoqun Ma. M. y Jianhong. Wu. G. Gan, *Data Clustering Theory, Algorithms and Applications*, United States of America, 2007.
- Castañón, S., A.M. García-Granda, A. Guerrero, M.P. Lorenzo y S. Angulo. Energy and environmental savings via optimisation of the production process at a Spanish cement Factory, (2014). *Journal of Cleaner Production Elsevier* (ISSN: 0959-6526).
- Curbelo, A. D., Municio, Á.M.G., Delgado, F.M., 2020. Herramientas para la gestión de riesgos en cadenas de suministro: Una revisión de la literatura. *Dirección y Organización*. (64), pp. 5-35.
- Cronin, P., Ryan, F., & Coughlan, M. (2008). Undertaking a literature review: A step-by-step approach. *British Journal of Nursing*, 17(1), 38–43.
- Eurostat Estadísticas de precios eléctricos. Recuperada de: <https://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do>, 2019.
- Fabbe-Costes, N., Jahre, M., and Roussat, C., 2009. Supply chain integration: the role of logistics service providers. *International Journal of Productivity and Performance Management*, 58 (1), 71-91.
- Gilvonio Alegría, Leoncio Rubén & Inche Mitma, Jorge Luis. (2005). *El Ahorro de Energía en la Industria Cementera como Estrategia de la Excelencia Operativa* (Tesis doctoral). Universidad Mayor de San Marcos, Lima, Perú.
- Hemingway, P., & Brereton, N. (2009). *What is a systematic review? Series* (2nd Ed.). Newmarket, UK: Hayward Medical Communications.
- Hernández, J. Ma. Ramírez, y C. Ferri, *Introducción a la minería de datos*, Madrid: Pearson Educación, 2004.
- <http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>
- Hurtado Moreno, Laura; Quintero Montoya, Olga Lucía y García Rendón, John Jairo (2014). Estimación del precio de oferta de la energía eléctrica en Colombia mediante inteligencia artificial. *Revista de Métodos Cuantitativos para la Economía y la Empresa* (ISSN: 1886-516X).
- Khotanzad, AI (2018). Using artificial intelligence to develop electricity load forecasts. *Power Magazine*, Jun.2018, Vol162, Issue 6, pag 1-1. (ISSN 032-5929).
- Lara, J. *Minería de datos*, Madrid: Centro de Estudios Financieros, 2014.
- Nagi, J. An intelligent system for detection of non-technical losses in Tenaga Nasional Berhad (TNB) Malaysia low voltage distribution network, *Malasia: Universiti Tenaga Nasional*, 2009.
- Oakley, A. (2003). *Research evidence: Knowledge management and educational practice: early lessons from a systematic approach*. London *Review of Education*, 1(1), 21–33.
- OFICEMEN (2019). “*Informes Estadísticos Avance Nacional Diciembre 2019*”. Recuperada de: <https://www.oficemen.com/shop/>
- Pacheco, E.A., Rodríguez, M.V., Rodríguez, 2011. Assessment of the readiness of the strategic human capital through a model to prioritize the strategic competences: A literature review. *Dirección y Organización*. 43, pp. 78-89.
- Pavlos S. Georgilakis (2007). Artificial intelligence solution to electricity price forecasting problema *Applied Artificial Intelligence* (ISSN 0883-9514).
- Pereira, L. y otros, “*Multilayer Perceptron Neural Networks Training Through Charged System Search and its Application for Non-Technical Losses Detection*,” *IEEE PES, ISGT Latin America*, 2013.
- Pérez, C. *Minería de datos técnicas y herramientas*, Madrid: Thomson, 2007.
- Pezzutto, S., Grilli, G., Zambotti, S. Dunjic, S. (2018). Forecasting Electricity Market Price for End Users in EU28 until 2020—Main Factors of Influence. *Energies* 11(6),1460; 2018 by the authors. (ISSN: 19961073).
- Provost, F., and Fawcett, T. *Data Science for Business*. United States of America. O’Reilly Median Inc.. 2013.
- Quinlan, K. M., Kane, M., & Trochim, W. M. K. (2008). Evaluation of large research initiatives: Outcomes, challenges, and methodological considerations. In (Series Ed.) & C. L. S. Coryn, & M. Scriven (Vol. Eds.), *New directions for evaluation*, No. 118: Reforming the evaluation of research (pp. 61–72).
- Ramos, C. y otros, “*A New Approach for Nontechnical Losses Based on Optimum-Path Forest*,” *IEEE Transactions on Power Systems*, vol. 26, nº 1, pp. 181-189, 2011.
- Shaohog Jing, Wemeng Xu y Xiaohong Wang (2012). *Research on the Key Technology of Energy Management and Optimization in Cement Enterprises*. *Advanced Materials Research* (ISSN 1662-8985).

- Swanepoel, Jan Adriaan, Mathews, Edward Henry, Vosloo, Jan, Liebenberg, Leon. Integrated energy optimisation for the cement industry: A case study perspective. *Energy Conversion and Management* (ISSN: 0196-8904), 2013.
- Swanepoel, J.A., (2013). Modeling for Integrated Energy Optimization In Cement Production. *Energy Conversion and Management* (ISSN: 0196-8904).
- Szkuta, BR; Sanabria, LA; Dillon, TS Previsión de precios de electricidad a corto plazo utilizando redes neuronales artificiales. *IEEE Trans. Power Syst.* 1999 , 14 , 851–857.
- Torghaban, SS; Motamedi, A .; Zareipour, H .; Tuan, LA Previsión de precios de electricidad a mediano plazo. En *Actas del Simposio de Energía de América del Norte 2012 (NAPS 2012)*, Champaign, IL, EE. UU., 9-11 de septiembre de 2012; pp. 1-8.
- Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British Journal of Management*, 14(3), 207–222.
- Wellesley, Mass (2011) EnvaPower's New Artificial Intelligence Software Makes Managing Electricity a No-Brainer. PR Newswire, NY.
- Zhang, Jun y Cheng, Chuntian (2008). Day-ahead electricity price forecasting using artificial intelligence. *IEEE Electrical Power & Energy Conference*.