



TESIS DOCTORAL

Programa de Doctorado de Ciencias Económicas, Empresariales y Sociales.

Universidad de Sevilla

DESARROLLO METODOLÓGICO PARA LA OPTIMIZACIÓN
DEL COSTE ELÉCTRICO EN FÁBRICAS DE CEMENTO MEDIANTE
EL USO DE INTELIGENCIA ARTIFICIAL

METHODOLOGICAL DEVELOPMENT FOR ELECTRICAL COST
OPTIMIZATION IN CEMENT FACTORIES BY USING ARTIFICIAL
INTELLIGENCE

MANUEL PAREJO GUZMÁN

DIRECTORES:

Dra. D^a. Rafaela Alfalla-Luque. Departamento de Economía Financiera y Dirección de Operaciones. Universidad de Sevilla.

Dr. D. Pedro Mora Peris. Departamento de Ingeniería Geológica y Minera ETS Ingenieros de Minas y Energía. Universidad Politécnica de Madrid.

Dr. D. Benito Navarrete Rubia. Departamento de Ingeniería Química y Ambiental. ETS de Ingeniería. Universidad de Sevilla.

Sevilla, noviembre de 2021

DESARROLLO METODOLÓGICO PARA LA OPTIMIZACIÓN
DEL COSTE ELÉCTRICO EN FÁBRICAS DE CEMENTO MEDIANTE
EL USO DE INTELIGENCIA ARTIFICIAL

Disertación que se presenta para la Mención Industrial en el Título de
Doctor en Ciencias Económicas, Empresariales y Sociales

ÍNDICE

- I. Agradecimientos.
- II. Resumen. Palabras Clave.
- III. Abstract. Keywords.
- IV. Contenido.

Capítulo 1. INTRODUCCIÓN.

- 1.1. Introducción.
- 1.2. Justificación del tema: la pérdida de competitividad en el sector.
- 1.3. Planteamiento del problema.
- 1.4. Objetivos y subobjetivos.
- 1.5. Metodología.
- 1.6. Estructura de la tesis doctoral.

Capítulo 2. METODOLOGÍA.

- 2.1. Introducción.
- 2.2. Revisión sistemática de la literatura.
- 2.3. Encuestas a expertos y estudio cuantitativo.
- 2.4. Panel de expertos y estudio cualitativo.
- 2.5. Herramientas disponibles para la optimización.
- 2.6. Algoritmos y técnicas de aprendizaje automático.

Capítulo 3. ANÁLISIS COMPARATIVO DE LOS PRECIOS ELÉCTRICOS EN ESPAÑA Y EN LA UE-28.

3.1. Introducción.

3.2. Análisis comparativo de los precios eléctricos en España y en la UE-28.

3.3. Factores que influyen en el sobreprecio de la electricidad en España.

Capítulo 4. OPTIMIZACIÓN DEL COSTE ELÉCTRICO OPERANDO SOBRE VARIABLES DEL PROCESO.

4.1. Introducción.

4.2. Revisión de la literatura.

4.3. Consultas a expertos. Análisis del precio eléctrico de la industria cementera española.

4.4. Metodología para la optimización eléctrica operacional.

4.5. Metodología para la optimización de costes eléctricos regulados.

4.5.1. Traslación del consumo eléctrico de las distintas fases a los periodos P(Y) de menor coste.

4.5.2. Limitaciones de potencia para las tarifas de acceso.

4.5.3. Restricciones de Operación y Ventas.

Capítulo 5. OPTIMIZACIÓN DEL COSTE ELÉCTRICO OPERANDO SOBRE PRECIO ELÉCTRICO DEL MERCADO.

5.1. Introducción.

5.2. Revisión de la literatura.

5.3. Consultas a expertos.

5.4. Metodología para la optimización eléctrica operando sobre el precio eléctrico del mercado.

Capítulo 6. CONCLUSIONES, DISCUSIÓN DE RESULTADOS Y LÍNEAS FUTURAS DE INVESTIGACIÓN.

6.1. Introducción.

6.2. Conclusiones.

6.3. Implicaciones de la investigación para la práctica empresarial.

6.4. Implicaciones de la investigación para el ámbito académico.

6.5. Innovación introducida y líneas futuras de investigación.

6.6. Consideraciones finales: Cambios normativos.

V. Referencias bibliográficas.

VI. Índice tablas y gráficos.

VII. Anexos.

A. Artículos científicos publicados.

B. Presentación de los resultados de la tesis doctoral en foros académicos y empresariales.
Carta de Interés.

C. Mención a tesis industrial.

I. Agradecimientos.

*A mi mujer LOLA y a mis dos hijos, LOLA y MANOLO,
que han padecido mis ausencias estos años a consecuencia de esta tesis.*

*Sin tu apoyo, paciencia, cariño, y ayuda inestimable, Lola,
ni esto, ni casi nada en mi vida, habría sido posible.*

*A mi PADRE,
que supo inculcarme sus valores -honradez y esfuerzo- desde niño y al que tanto le debo.
Papá, gracias por todo lo que me enseñaste y por lo que hiciste de mí.*

A mi hermana, "CHIQUI", de manera especial, como es ella.

*A mi tío FERNANDO, con el que tengo pendiente celebrar no solo esto,
sino cosas más importantes de la vida que nosotros sabemos.*

*A mis sobrinos, tíos, primos y resto de familia, también política,
que siempre ha estado ahí, apoyándome incondicionalmente.*

*A mis amigos, a todos,
pero fundamentalmente a los especiales -ellos lo saben-, que son los amigos de verdad.*

*A mis directores de tesis y a todos los compañeros y amigos del sector cementero,
que tanto me han ayudado y enseñado a lo largo de estos últimos años.*

*Y..., a los que ya no están y tanto quiero.
De manera especial a mi MADRE,
la principal responsable de esto y de casi todo lo que he conseguido.*

*Y por supuesto a CONSU,
que como mi propia madre me decía, era mi segunda madre.*

Cuanto os echo de menos. Y cuanto habría disfrutado hoy teniéndooos junto a mí.

II. Resumen. Palabras clave.

Las fábricas de cemento son plantas que presentan unos consumos energéticos muy importantes, tanto térmicos como eléctricos. *El 70 % del coste variable de una cementera se dedica a energía -33 % térmica y 37% eléctrica aproximadamente-*. Una fábrica de cemento media en España puede consumir entre 8 y 9 millones de euros de electricidad al año, en función del tamaño de la misma y del nivel de producción en el que se encuentre.

Esta tesis doctoral tiene como objetivo principal desarrollar una metodología dirigida a minimizar el coste eléctrico de una fábrica de cemento, haciendo uso de distintas herramientas de Inteligencia Artificial -Redes Neuronales, Algoritmos *Backpropagation* y Algoritmos Genéticos, fundamentalmente-, de manera que se consiga una mayor competitividad reduciendo los costes en las plantas. Con tal objetivo se desarrollan las distintas arquitecturas de redes neuronales, así como el planteamiento matemático de los algoritmos genéticos para optimizar el coste eléctrico de las fábricas.

Nuestro objetivo se alcanzará abordando de manera simultánea tres cuestiones diferentes que afectan al coste eléctrico:

1.- Optimización del coste eléctrico operacional. El objetivo es reducir el consumo eléctrico de una fábrica de cemento, operando sobre ciertas variables del proceso productivo. Para ello se analizará con detalle el consumo eléctrico en cada una de las fases del proceso y se buscará la combinación de las variables seleccionadas que reduzca el consumo y haga mínimo el coste eléctrico -eficiencia eléctrica-. El sistema intentará reducir los kWh/t de cemento producida.

2.- Optimización de los precios eléctricos regulados. Es posible mejorar la eficiencia del coste eléctrico en una fábrica de cemento, desplazando el consumo de electricidad a los periodos en los que esta tiene menor coste. El objetivo será optimizar el coste energético, centrándonos en el €/kWh consumido (según los periodos: P1, P2, ..., P6).

3.- Optimización de la compra de electricidad en el mercado. Se utilizarán técnicas de inteligencia artificial para predecir el precio de compra spot de la electricidad en cada momento. De esta manera estaremos en disposición de compararlo con el precio futuro y

comprar al más económico. El objetivo será optimizar el precio del kWh (€/kWh) o bien €/t de cemento producida.

Para el desarrollo de esta tesis doctoral, en primer lugar se ha llevado a cabo un análisis sistemático de la literatura basado en tres bases de datos: Scopus, Web of Science y ABI/Inform Collection.

El análisis sistemático de literatura no ha arrojado demasiada información, pues se han encontrado un número de artículos muy reducido -14 en total- en los que se aborda el problema planteado en nuestra investigación. Es por ello por lo que se adoptó la decisión de completar la fase documental de la tesis con un panel de expertos y encuestas, consultando con un total de 42 expertos y profesionales del sector cementero. Cabe destacar que los expertos, procedentes de todas las empresas cementeras que operan en España y de la Agrupación de Fabricantes de Cemento de España (OFICEMEN), contaban con una gran formación interdisciplinar: ingenieros civiles e industriales, economistas, químicos, etc.

Para el desarrollo de esta investigación, también se ha tomado información y datos experimentales (producción en las distintas etapas, consumos energéticos de cada fase del proceso productivo, etc.) de la fábrica de cemento de la ciudad de Málaga (España), de la compañía cementera FYM HeidelbergCement Group.

Las fuentes de información -literatura científica existente y consulta a expertos- han constituido la base principal para el desarrollo de la metodología para reducir el coste eléctrico.

Las herramientas de Inteligencia Artificial planteadas para esta investigación han sido, fundamentalmente, las redes neuronales artificiales, el algoritmo *Backpropagation* y los algoritmos genéticos. El modelo desarrollado podría ser aplicado a cualquier planta cementera de vía seca del mundo. Por otro lado, introduciendo ciertos cambios en los parámetros iniciales, también podría ser aplicable a otro tipo de industrias electrointensivas.

La innovación principal de este trabajo de investigación se basa en el hecho de utilizar una metodología que incide, a la vez, sobre tres aspectos distintos a la hora de reducir el coste eléctrico de las plantas de fabricación de cemento: variables de proceso, costes eléctricos regulados y precio de la electricidad en el mercado. El hecho de integrar de manera simultánea y en una misma metodología estas 3 cuestiones, posibilita una optimización del

coste eléctrico que permite llegar más allá de lo que lo han hecho investigaciones previas existentes, que se centran solo en uno de esos factores.

Aunque no será objeto de esta tesis el entrenamiento de estas herramientas con datos reales está prevista su aplicación práctica en una fase posterior de la investigación. En este sentido se han iniciado conversaciones con una firma de ingeniería andaluza de ámbito internacional, que ha manifestado su interés por el modelo desarrollado, de cara a su aplicación mediante un proyecto piloto que se pondría en marcha en una fábrica de cemento andaluza.

Por otro lado, los resultados obtenidos en esta tesis sientan las bases para futuras investigaciones, dado que, como se ha indicado, el modelo es perfectamente reproducible en otro tipo de industrias electrointensivas.

Se abre, así, una interesante línea de investigación con la aplicación a otros sectores y la comparación intersectorial.

Palabras Clave:

Cemento - Inteligencia Artificial (IA) - optimización del coste eléctrico - Redes Neuronales Artificiales (RNA) - Algoritmos Genéticos - Algoritmo Backpropagation - fábrica, - industria.

III. Abstract.

Cement manufacturing plants require large amounts of thermal and electrical energy. Seventy percent of the variable cost is attributable to energy: approximately 33% to kiln thermal energy and 37% to electrical energy. An average cement factory in Spain consumes between 8 and 9 million euros of electricity per year, depending on the size and production level of the plant.

This doctoral thesis has the main objective of minimising the electrical cost of a cement factory by using different artificial intelligence (AI) tools – mainly neural networks, backpropagation algorithms and genetic algorithms – so that greater competitiveness in costs is achieved in plants.

Different architectures of neural networks and the mathematical approach of genetic algorithms to optimise the electrical cost of factories will be developed in this doctoral thesis.

Our objective will be achieved by simultaneously addressing three different variables which affect electricity costs:

1.- OPERATIONAL ELECTRICITY COST OPTIMISATION. The purpose is to reduce electricity consumption in a cement factory by modifying certain variables of the production process. To do this, electricity consumption at the different stages of the process will be analysed and the selected variables combination that minimise electricity consumption and reduce cost will be sought (electrical efficiency). This methodology will attempt to reduce the kWh/t of cement produced.

2.- REGULATED ELECTRICITY PRICE OPTIMISATION. It is possible to improve electrical cost efficiency in a cement factory by shifting electricity consumption to the periods when it has the lowest cost. The goal will be to optimise the energy cost, focusing on the unit cost (€) per kWh consumed (according to the periods P1, P2, ..., P6).

3.- OPTIMISATION OF ELECTRICITY PROCUREMENT ON THE MARKET. Artificial intelligence (AI) techniques will be used to predict spot purchase prices of electricity. In this way we will be able to compare it with future prices, so that we can buy

the cheaper of the two. The objective will be to optimise the kWh price (€/kWh) or € of each ton of cement produced.

In developing this doctoral thesis, firstly a systematic literature analysis was carried out, based on three scientific literature databases: Scopus, Web of Science, and ABI/Inform Collection.

The results of the systematic literature analysis were very poor, and a very small number of articles were found - 14 in total – that addressed the problem posed in our research. That is why the decision to consult a total of 42 experts and professionals in the cement sector, through surveys and an experts panel, was taken. It should be noted that the experts, who represent all cement companies operating in Spain and from the Spanish Cement Manufacturers Association (OFICEMEN), had a wide range of interdisciplinarity expertise, including civil and industrial engineers, economists, chemists, and more.

To develop this research, information, and experimental data (production in the different stages, energy consumption of each phase of the production process, etc.) of the cement factory of FYM HeidelbergCement Group in Málaga (Spain) have been considered.

Information sources – existing scientific literature and expert consultations – have been very useful in developing a methodology to reduce the electrical cost.

The primary artificial intelligence tools used in this investigation have been artificial neural networks, the backpropagation algorithm, and genetic algorithms. The methodology that has been developed can be applied to any dry process cement plant in the world. By introducing certain changes in initial parameters, it could also be applicable to other electro-intensive industries.

The innovation of this research work is based on the use of a methodology which affects three different aspects at the same time when it comes to reducing the electrical cost of cement plants: process variables, regulated electricity costs, and the market price of electricity. Taking all three of these factors into account within the same methodology will enable much greater electrical cost optimisation than previous research already undertaken that focuses on only one aspect.

Although the training of these tools with real data will not be the object of this thesis, practical application is planned in a later phase of the research. In this regard, conversations with an Andalusian engineering firm of international scope have begun. They have indicated their interest in the model we have developed, in order to apply it through a pilot project that would be launched in an Andalusian cement factory.

On the other hand, the results presented in this document will be useful for future researchers, since, as indicated, the model is perfectly reproducible in other electro-intensive industries.

An interesting line of research with applications in other sectors and cross-sectoral comparison is thus opened.

Keywords:

Cement, Artificial Intelligence (AI), -electrical cost optimization - Artificial Neural Network (ANN) - Genetic Algorithms (GA) - Backpropagation Algorithm - factory - industry.

IV. Contenido.

Capítulo 1. INTRODUCCIÓN.

1.1. Introducción.

El sector cementero español ha sufrido una crisis muy severa entre 2008 y 2014. El consumo de cemento se redujo desde 55,9 millones de t hasta 10,8 millones de t, lo que supuso un decremento del 80,67%. Andalucía es la primera comunidad autónoma de España en producción y consumo de cemento, siendo la evolución de la producción en el caso andaluz muy similar al español. Dada la importancia de Andalucía en el sector cementero, será objeto de algunos comentarios específicos a lo largo de este trabajo. Así, por ejemplo, el consumo de cemento en Andalucía se redujo desde 10,5 millones de t hasta 1,8 millones de t entre 2008 y 2014, lo cual supuso un decremento del 82,6 %. Esta contracción tan desmesurada del mercado afectó, y sigue afectando de manera muy importante, a las cuentas de resultados de las compañías que operan en España en el sector cementero.

Para paliar los efectos de esta crisis, las compañías cementeras españolas y andaluzas se vieron obligadas a cambiar su estrategia y comenzaron a exportar grandes cantidades de cemento y clínker a otros lugares del mundo. Los mercados domésticos -tanto el español como el andaluz- no eran suficientes para absorber la capacidad de producción de cemento instalada. Así, en 2018 la capacidad instalada en Andalucía ascendía a 7.500.000 t/año de cemento, mientras que el consumo anual se situó en 2.500.000 t de cemento aproximadamente. Para paliar este diferencial tan notable, la exportación ha supuesto durante los años más duros de la crisis -y también actualmente- una cuestión fundamental. De hecho, además de los 2,5 millones de t de cemento comercializado en Andalucía, las exportaciones llegaron a situarse en el pasado en el entorno de las 2.000.000 t, situando a las fábricas, aproximadamente, en el 60 % de su capacidad.

España ha sido tradicionalmente el primer país exportador de cemento/clínker de la Unión Europea y el octavo del mundo, siendo Andalucía, en los últimos años, la región española más exportadora.

En 2016 tuvo lugar un incremento del 5,9 % en las exportaciones de cemento y clínker en España y del 26% en Andalucía. Esto se tradujo en pasar en España de 9.233.979 t a 9.782.631 t y, en Andalucía, de 2.174.307 t a 2.739.706 t Sin embargo, en los últimos años el sector cementero español ha experimentado un decremento en las exportaciones de cemento y clínker muy notable (-23% en 2019 y -3,4 % en 2020). Con un escenario en el que las exportaciones se encuentran tan limitadas, se hace muy difícil asegurar la supervivencia del sector, pues como se ha dejado entrever anteriormente, el mercado doméstico resulta del todo insuficiente.

Los datos de exportación de cemento y clínker reflejan una clara pérdida de competitividad, que tiene su origen, entre otros factores, en los altos costes eléctricos que soporta la industria española, muy por encima de los del resto de Europa. Los costes eléctricos de la industria española pueden llegar a ser, en algunos casos, hasta un 30% superiores a los de otros países europeos. No obstante, existen otros factores como el ascenso de precios de los derechos de emisión de dióxido de carbón y los bajos niveles de sustitución térmica en comparación con otros países europeos, que también afectan directamente a esta pérdida de competitividad y que están poniendo en grave riesgo el futuro del sector. Estos factores serán analizados en mayor profundidad en el apartado 1.2.

El proceso de investigación en el que se basa esta tesis doctoral se ha centrado en el sector cementero español y andaluz. No obstante, las conclusiones que se extraen pueden resultar extrapolables a cualquier fábrica de cemento del mundo de vía seca. Incluso cambiando ciertos parámetros iniciales y llevando a cabo ciertas modificaciones de partida en el modelo, podría utilizarse para otras empresas electro intensivas que operaran en otros sectores. El resultado de este trabajo de investigación – reducción del coste eléctrico de una fábrica de cemento-, contribuirá a mejorar la competitividad del sector y su viabilidad futura.

1.2. Justificación del tema: la pérdida de competitividad en el sector.

En este apartado abordaremos los tres factores que más están afectando en estos momentos a la pérdida de competitividad del sector cementero español y andaluz:

a) Ascenso de precios de los derechos de emisión de dióxido de carbono. El régimen de comercio de derechos de emisión de la UE (RCDE UE) – en inglés EU-Emissions Trading System (EU-ETS)- constituye una importante herramienta de la política europea de lucha contra el cambio climático de cara a reducir las emisiones de gases de efecto invernadero. Este régimen es el principal mercado de carbono del mundo y el de mayor tamaño. Su funcionamiento se basa en el principio de limitación y comercio.

Las empresas reciben o compran derechos de emisión con los que pueden comerciar entre sí en función de sus necesidades. El límite sobre el número total de derechos disponibles garantiza que éstos tengan un valor.

Al final de cada año, las empresas deben entregar suficientes derechos para cubrir todas sus emisiones ya que, en caso contrario, se les imponen fuertes sanciones. Si una empresa reduce sus emisiones puede conservar sus derechos sobrantes para cubrir necesidades futuras, o bien venderlos a otra empresa que no tenga suficientes (European Union, 2020).

Entre 2005 y 2007 asistimos a un periodo de asignaciones gratuitas de derechos a las empresas. Entre 2008 y 2012, con el Acuerdo de Kioto, la asignación gratuita pasó a ser parcial.

A partir de 2013 y hasta 2020 (Fase III) asistimos a un periodo con una reducción importante de las asignaciones gratuitas. Estas asignaciones se calculan para cada instalación industrial de acuerdo con la siguiente fórmula:

$$A = BM * HAL * FCL * CSCF$$

Siendo:

- A: Asignación gratuita.
- BM: Benchmark del producto. Supone las t de CO₂ emitidas para fabricar una t de clínker del 10% de las fábricas más eficientes desde el punto de vista ambiental de la UE en el periodo 2007-08. Para cemento gris, el benchmark estaba situado en 766 kg. de CO₂/t de clínker. El de cemento blanco en 987 kg de CO₂/t de clínker. Las fábricas españolas emitieron en 2019 de media 799 kg de CO₂ /t. de clínker producido. Como puede verse,

nuestras fábricas se encontraban por encima de este benchmark, con lo cual habrán de soportar mayores costes a la hora de adquirir estos derechos de emisión. Cabe indicar que resulta muy complicado cumplir con el benchmark fijado por la UE, pues entre este 10% de fábricas más eficientes, se encuentran algunas que tienen posibilidad de utilizar materias primas descarbonatadas, con lo cual parten de emisiones de CO₂ de proceso mucho más bajas, con independencia de su eficiencia. Nos encontramos ante un factor que limita objetivamente la mejora de los costes de adquisición de derechos de emisión gratuitos.

- HAL: Historical Activity Level de cada fábrica, es decir su nivel de actividad histórico. La UE toma para cada planta, para la asignación de 2013-2020, el mayor de dos valores: mediana del periodo 2005-08 y media 2009-10. Para el periodo 2021-25, se tendrá en cuenta la media de 2014/18. Además, para evitar que las fábricas se beneficien de no producir cemento vendiendo derechos de emisión, impone la obligación de que la producción se sitúe por encima del 50% del HAL inicial, para optar a conseguir el 100% de los derechos.

- FCL: Factor Carbon Leakage. La UE ha fijado una serie de sectores que presentan riesgo de fuga de carbono -carbón leakage-, es decir que potencialmente podrían deslocalizarse a causa de los costes de emisión de CO₂. Aquellos sectores con riesgo de deslocalización claro tendrán un FCL=1 (100% de los derechos gratuitos).

- CSCF: Cross Sectorial Correction Factor. Se trata de un factor que se aplica para evitar que la industria exceda la cantidad máxima de emisiones gratuitas asignadas -CAP industrial¹-.

La fase IV es la comprendida entre los años 2021 y 2030. En esta fase están previstas nuevas medidas que dificultarán mucho más la consecución de derechos de asignación gratuitos. Cabe destacar dos medidas.

¹ Derechos de emisión gratuitos asignados para la globalidad del sector industrial.

En primer lugar, el benchmark para cemento gris pasará de 766 kg a 693 kg de CO₂ por t de clínker gris fabricada. Para el cemento blanco pasará de 987 kg a 957 kg de CO₂ por t de clínker gris fabricada.

Por otro lado, en este periodo está prevista una asignación dinámica de derechos en función del HAL alcanzado. Para el periodo 2021-25, la UE toma para cada fábrica la media de producción entre 2014-2018. Para el periodo 2026-30 se tendrá en cuenta la media de producción entre 2019-23. Se podrían dar tres situaciones diferentes:

- 85% HAL < Producción < 115% HAL: se mantienen los derechos gratuitos.
- Producción < 85% HAL: se pierden derechos de asignación gratuitos.
- Producción > 115% HAL: Se obtienen nuevos derechos gratuitos.

Podemos concluir que, a partir de 2021, las novedades incorporadas al régimen de comercio de derechos de emisión que se han expuesto en este apartado y que tienen que ver fundamentalmente con el HAL y con el benchmark, contribuirán significativamente al incremento de los costes de emisión de CO₂. De esta manera, a las fábricas españolas les resultará mucho más difícil competir con otros países a la hora de exportar cemento y clínker al exterior.

El precio de los derechos de emisión de CO₂ será determinante a la hora de fijar el coste ambiental en los próximos años. Estamos asistiendo a un continuo aumento del precio de los derechos de emisión (en octubre de 2021 había sobrepasado los 60 €/t de CO₂), sujeto a factores exógenos al sector cementero, y a una desaparición progresiva de los derechos gratuitos de emisión.

b) Bajos niveles de sustitución térmica en comparación con otros países europeos. La Comunicación de la Comisión Europea “*Cerrar el círculo: un plan de acción de la UE para la economía circular*”, de diciembre 2015, indica expresamente que “*cuando no se pueden evitar o reciclar los residuos, en la mayoría de los casos y tanto desde el punto de vista medioambiental como económico, es preferible recuperar su contenido energético en vez de depositarlos en vertederos*”. LA UE, entre las Mejores Técnicas Disponibles (MTDs) incluidas en los documentos BREF redactados para el sector cementero, incluye y

recomienda expresamente la valorización energética de residuos en hornos de cementeras, como una práctica medioambientalmente sostenible.

En España, en el año 2019, 29 de las 33 fábricas de cemento operativas, estaban autorizadas a valorizar energéticamente residuos en sus hornos. En este año se emplearon un total de 921.555 t de combustibles alternativos, alcanzándose un nivel de sustitución energética en nuestro país del 30,7 %. Los residuos que más se utilizan en España son Combustibles Derivados de Residuos (CDRs), Neumáticos Fuera de Uso (NFUs) y harinas animales (Fundación CEMA, 2020).

En el caso de Andalucía, según la Fundación Laboral Andaluza del Cemento y el Medio Ambiente (FLACEMA, 2018), el porcentaje de sustitución térmica ha evolucionado desde el 24,8% en el año 2017 al 31% en 2019.

A nivel europeo, en el año 2019, según Fundación CEMA (2019), el porcentaje de sustitución de combustibles fósiles por residuos, sobre todo si nos centramos en los países más avanzados económicamente y más responsables desde el punto de vista ambiental, fue bastante superior. Las cementeras austriacas presentan un nivel de sustitución del 81%; las suecas del 69%; las alemanas del 68,9% y las suizas del 68,1%, solo por poner algunos ejemplos. La media de la EU 28 ascendió al 46,5%.

Estos datos muestran como tanto Andalucía como España se encuentran lejos de los niveles de sustitución térmica de los países europeos más avanzados desde el punto de vista económico y ambiental.

La valorización energética presenta una serie de beneficios:

- Supone una solución al problema de gestión de los residuos, contribuyendo a reducir su depósito en vertedero, que se trata de la opción menos deseable desde el punto de vista ambiental.
- Reduce las emisiones globales de CO₂ (tanto las asociadas al depósito en vertederos como las asociadas a los residuos con biomasa), ayudando de esta manera a combatir el cambio climático.

- Reduce el empleo de combustibles fósiles en las fábricas de cemento, por lo que se fabrica un cemento más sostenible, a la vez que se ahorran combustibles fósiles que están limitados por la naturaleza.

- Aumenta la competitividad del sector y proporciona estabilidad al empleo. El hecho de que las fábricas andaluzas y españolas tengan niveles de valorización tan bajos supone un hándicap y una limitación importante a la hora de competir con fábricas de otros países con un uso más intensivo de este tipo de combustibles, o bien que presenten costes de producción más bajos. Los combustibles fósiles tradicionales -fundamentalmente el coque de petróleo- tienen un coste mucho mayor que los combustibles que proceden de residuos.

Influir en el nivel de sustitución de combustibles fósiles por residuos no resulta tampoco una opción de reducción de costes sencilla, dado que depende de diferentes factores en los que una cementera no puede influir de manera directa: disponibilidad de residuos, relación social con los grupos de interés (stakeholders), regulaciones legales, aspectos técnicos e industriales, etc.

- c) Aumento de los costes eléctricos. Los costes de energía juegan un papel muy importante en el proceso de producción de cemento. El 70% de los costes de una fábrica de cemento son costes variables; de ellos, a su vez, el 70% son atribuibles a costes de energía (33 % térmica y 37% eléctrica). Por lo tanto, los costes eléctricos vienen a representar algo más de $\frac{1}{4}$ de los costes totales de fabricación de cemento (alrededor del 25,9%).

Según cálculos realizados con datos facilitados por OMIE² (2019), una fábrica de cemento media que opere en España, país con uno de los costes eléctricos industriales mayores de la UE, con una producción aproximada de 1.000.000 t de cemento anuales, consume alrededor de 119.900 MWh, lo que supone un coste de unos 8.872.600 millones de € de electricidad al año (tomando un precio medio de 74 €/MWh). Estos datos muestran claramente, la importancia que para la competitividad de una fábrica de cemento tienen los costes eléctricos (Swanepoel, 2013 y Shaohog *et al.*, 2012). Por otro lado, el coste eléctrico de la industria electro intensiva española pueden llegar a ser, en algunos casos, hasta un 30%

² OMIE: Operador del Mercado Ibérico de Energía.

superior al de otros países europeos (Eurostat. Estadísticas de precios eléctricos de Eurostat, 2019; OMIE, 2019).

La fijación de precios eléctricos en España, al igual que en otros países, sigue un sistema marginalista. Los distintos generadores casan ofertas con los demandantes y reciben un mismo precio (el más alto), resultante del cruce de las curvas de oferta y demanda. Al precio de la generación de la electricidad, hay que sumarle una serie de costes regulados (peajes por potencia, por energía, impuestos, pagos por electricidad, etc.), resultando así el coste eléctrico efectivo. Con este estudio se pretende obtener una mejora en la eficiencia eléctrica reduciendo el consumo eléctrico en las fases críticas del proceso de producción de cemento, operando en los periodos con costes eléctricos regulados más bajos y optimizando la compra de la electricidad del mercado.

A pesar de la pérdida de competitividad que experimenta el sector cabe indicar, en cuanto a la eficiencia energética que, según datos del GCCA Association (2020), las fábricas españolas son sensiblemente más eficientes que la media europea (EU-25). Las plantas españolas consumen alrededor de 119,9 kWh/t cemento producida, frente a las 126 kWh/t. cemento producida en las fábricas europeas (datos de 2016, 2017 y 2018). Por lo tanto, aunque soportan un coste eléctrico mayor (Eurostat. Estadísticas de precios eléctricos de Eurostat, 2019; OMIE, 2019), las fábricas españolas son más eficientes que la media europea.

1.3. Planteamiento del problema.

Tal y como se ha expuesto en el apartado anterior, el sector cementero español se enfrenta a un claro problema de pérdida de competitividad. Esta falta de competitividad tiene su origen en una serie de factores tales como:

- Coste de los derechos de emisión de CO₂, que las compañías deben comprar en el contexto del Sistema de Comercio de Emisiones de la Unión Europea (EU -ETS, European Union Emissions Trading System). El mismo se ha incrementado de 7,54 € en enero de 2018 a más de 60 € en octubre de 2021. Aunque hay expertos que no descartan una corrección técnica o una recogida de beneficios por parte de los fondos de inversión en el C/P que

contribuya a mantener o reducir el precio, no son pocos los que piensan justo lo contrario, argumentando el papel que jugará la reducción progresiva del número de derechos gratuitos disponibles.

- Bajos niveles de recuperación energética (valorización energética de residuos). En 2019, solo el 30,7% de la energía térmica de los hornos de cemento españoles, provino de la valorización de residuos, mientras que en la UE-28 este porcentaje se situó en el 46,5%. Existen países, como el caso de Austria, Suecia, Alemania o Suiza, según Fundación CEMA, 2020, en los que este porcentaje se sitúa por encima del 65 %, lo cual da cuenta del potencial de mejora que podría alcanzarse en esta cuestión.

- Altos costes eléctricos. Los costes eléctricos de la industria electro intensiva española pueden llegar a ser, en algunos casos, hasta un 30 % superiores a los de otros países europeos (Eurostat. Estadísticas de precios eléctricos de Eurostat. 2019; OMIE, 2019).

El contexto empresarial generado por estos factores no favorece en absoluto a las cementeras españolas que, como se comentó anteriormente, deben competir en muchos casos con plantas con unos costes de producción mucho más bajos.

Planteado el problema de falta de competitividad al que nos enfrentamos, debemos añadir que no resulta sencillo -en algunos casos completamente inviable- incidir sobre los tres factores señalados como máximos responsables de esta situación. Así, a una fábrica de cemento le resulta imposible incidir directamente sobre el Sistema Europeo de Comercio de Emisiones (EU-ETS), pues este depende íntegramente de decisiones de la Unión Europea. Sin embargo, aunque existen ciertos condicionantes externos, sí se podrían adoptar ciertas medidas para incrementar los porcentajes de sustitución de combustibles tradicionales por otros derivados de residuos (CDRs), lo cual contribuiría claramente a una reducción de los costes de fabricación.

Por otro lado, también resultaría factible centrarse en la optimización del coste eléctrico de las fábricas, para intentar mejorar todo lo posible el problema de pérdida de competitividad al que se enfrenta el sector. Es en este aspecto donde se centra la presente tesis doctoral.

1.4. Objetivos y subobjetivos.

El objetivo principal de este trabajo de investigación consiste en diseñar una metodología de análisis de costes eléctricos y evolución de precios de la electricidad basada en herramientas de Inteligencia Artificial (IA), que permita optimizar el coste eléctrico actuando sobre las pautas de operación de la fábrica y sobre las estrategias de compra y uso de electricidad, de cara contribuir a una mejora de la competitividad empresarial.

El proceso de investigación que se ha seguido en esta tesis doctoral desarrolla el planteamiento teórico para alcanzar nuestro objetivo, siendo objeto de investigaciones futuras el desarrollo práctico y empírico de un proyecto piloto en fábrica.

El objetivo genérico se alcanza abordando cinco subobjetivos:

1. Llevar a cabo una revisión sistemática de la literatura para identificar y analizar estudios previos en los que se haya desarrollado alguna metodología aplicable parcial o totalmente a este fin.

2. Desarrollar un análisis cuantitativo detallado del sector cementero español, desde un punto de vista del consumo eléctrico, realizando un estudio pormenorizado de los distintos costes, cuantificados, que forman parte del coste eléctrico de la industria cementera española, que sirva como base para completar el proceso de investigación y contribuir al objetivo global de optimizar el coste eléctrico mediante técnicas de IA.

3. Analizar las distintas herramientas de IA disponibles para la optimización del coste eléctrico en cementeras y seleccionar las más adecuadas para nuestra investigación.

4. Analizar los factores que más podrían contribuir en la composición del precio de la energía. Este aspecto será clave para avanzar en la investigación pues será un input fundamental para diseñar el modelo de IA.

5. Analizar los factores que más podrían influir en el consumo eléctrico en cada una de las fases del proceso de producción de cemento, para incluir las conclusiones de este análisis en el modelo de IA.

1.5. Metodología

Esta tesis doctoral se enmarca dentro de una línea de investigación que persigue la elaboración de un modelo integrado para optimizar el coste eléctrico del sector cementero.

El coste eléctrico supone para este sector industrial, al igual que para muchos otros, un factor de competitividad decisivo.

Para ello, dentro del modelo planteado se han optimizado tres aspectos diferentes: (1) el consumo de los equipos de la planta interviniendo sobre distintas variables del proceso productivo; (2) los costes eléctricos regulados y (3) el proceso de compra de la electricidad.

En primer lugar, se ha llevado a cabo una revisión sistemática de la literatura, que se aborda en profundidad en el apartado 2.2. Considerando las escasas aportaciones de esta revisión bibliográfica, se decidió llevar a cabo de forma complementaria consultas a expertos sectoriales a través de encuestas y de un panel de expertos, que se detallan en los apartados 2.3. y 2.4. La información obtenida, tanto de la literatura previa como de los expertos, resultó de gran utilidad de cara a determinar el planteamiento del modelo, las distintas variables a tener en cuenta en el mismo, así como las herramientas de IA más adecuadas para dar solución a cada uno de los tres aspectos que consideraríamos en el modelo.

Para el desarrollo de esta investigación se ha hecho uso de datos del proceso productivo y consumo eléctrico de la fábrica de cemento de Málaga (España), que han sido facilitados por la empresa FYM HeidelbergCement Group. Esta planta, que sigue el proceso de vía seca para producir clínker, se encuentra ubicada en el distrito Este del término municipal de Málaga, en la barriada de la Araña. Se trata de la fábrica más antigua de Andalucía, contando con más de 110 años de historia. En su larga historia la fábrica de cemento ha experimentado una constante evolución para mejorar. En el año 2000 fue pionera en el sector cementero cuando consiguió el certificado medioambiental ISO 14001 para sus instalaciones.

En los últimos años ha invertido cerca de 130 millones de euros en mejorar, de manera continua y sistemática, el rendimiento energético de sus instalaciones industriales de una manera eficiente y sostenible, con el consiguiente ahorro de consumo energético y reducción de emisiones, lo que le ha hecho valedora del Certificado del Sistema de Gestión Energética ISO 50001: 2011 de AENOR. Estas inversiones y apuesta continua por la sostenibilidad de su actividad, la han convertido en una de las cinco fábricas de cemento más eficientes de Europa.

El detalle de la metodología desarrollada será expuesto en el capítulo 2.

1.6. Estructura de la tesis

El contenido de la tesis doctoral se desarrolla en el apartado IV. Tras el capítulo introductorio, el segundo capítulo se centra en la metodología seguida a lo largo del trabajo. A continuación, en el capítulo 3, se aborda un análisis comparativo de los precios eléctricos en España y en la UE.

Los capítulos 4 y 5 están dedicados a desarrollar el modelo de IA que nos servirá para abordar el problema planteado en esta investigación. En el capítulo 4 se analiza la optimización del coste eléctrico asociada a las variables de proceso, tanto el consumo de los equipos de planta como los costes eléctricos regulados. El capítulo 5 se dedica a la optimización del coste eléctrico basada en la compra de la electricidad en el mercado.

Finalmente, en el capítulo 6 se ofrecen las conclusiones de la investigación, discusión de resultados y propuesta de líneas futuras de investigación.

Capítulo 2. METODOLOGÍA.

2.1. Introducción.

En este capítulo se aborda en detalle la metodología seguida en la presente investigación. En el apartado 2.2. se ha expuesto la revisión sistemática de la literatura que se ha llevado a cabo. La misma ha dado como resultado un número muy reducido de artículos relacionados con nuestra temática (14). En este mismo apartado se han analizado algunas de las características más importantes de los artículos seleccionados. Considerando el número tan reducido de artículos relacionados con el tema objeto de estudio, se ha creído conveniente llevar a cabo tanto encuestas a expertos (apartado 2.3.), para obtener información de tipo cuantitativa, como un panel de expertos, que ha aportado información cualitativa para el desarrollo de la metodología (apartado 2.4.). En el apartado 2.5. se han analizado de manera genérica las distintas herramientas disponibles para abordar el tipo de problema al que nos enfrentamos en nuestro trabajo. En el punto 2.6. nos centraremos en las principales técnicas de aprendizaje automático y algoritmos que existen en la actualidad, de cara seleccionar aquellos más idóneos y que nos resulten de mayor utilidad para dar solución a nuestro problema: optimizar el coste eléctrico en fábricas de cemento.

2.2. Revisión Sistemática de la Literatura.

Con objeto de establecer la situación del tema objeto de estudio, se ha llevado a cabo una revisión sistemática de la literatura en las tres principales bases de datos de publicaciones científicas: Scopus, Web of Science (WoS) y ABI Inform Collection. Con ello queda cubierto el primero de los subobjetivos propuestos en el apartado 1.4.

En la literatura científica, se pueden encontrar dos tipos de revisiones de literatura (Cronin, *et al.*, 2008): la revisión tradicional o narrativa y la revisión sistemática de la literatura. La revisión sistemática de la literatura difiere de la primera en que los hallazgos se pueden replicar (Hemingway y Brereton, 2009). Una revisión sistemática puede definirse como 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 la práctica de políticas” (Tranfield *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, 2003; Alfalla-Luque *et al.*, 2013; Curbelo *et al.*, 2018; Fabbe-Costes, 2009; Andrés y Maheut, 2020; Pacheco *et al.*, 2011; Sánchez Cazorla *et al.*, 2016).

El análisis del contenido de los artículos seleccionados se puede llevar a cabo tanto con datos cualitativos como cuantitativos y tanto inductivamente como deductivamente (Elo y Kyngas, 2007 y Sánchez Cazorla *et al.*, 2016). Las revisiones sistemáticas seleccionan, filtran y resumen grandes volúmenes de información, facilitando así el análisis bibliográfico. Como es una técnica sistemática, puede ser replicada por otros investigadores (Weber, 1990).

Para el desarrollo de la revisión de la literatura se han seguido las recomendaciones de trabajos previos (Tranfield *et al.*, 2003; Medina-López *et al.*, 2010), estableciendo un proceso en cinco etapas:

- (1) Identificación del campo de estudio y del período a analizar.
- (2) Selección de fuentes de información.
- (3) Búsqueda de referencias.
- (4) Gestión y depuración de resultados de búsqueda y
- (5) Análisis de los resultados.

El campo de estudio de nuestra investigación se centra en la optimización del coste eléctrico en empresas cementeras haciendo uso de la IA. El período de búsqueda incluía hasta el 1 de mayo de 2021, fecha en la que se realizó la última actualización. Las fuentes de información seleccionadas, como se indicó anteriormente, fueron las bases de datos de Scopus, Web of Science y ABI Inform Collection.

Los criterios de búsqueda se centraron en las palabras clave del campo de estudio: *electricity, optimization, cement, artificial intelligence, industry y energy*. Inicialmente se realizó una búsqueda considerando sólo artículos que incluyeran estas palabras en título, resumen y *keywords*, pero obtuvimos una cantidad ingente de trabajos. Concretamente 28.729 artículos en Scopus, 18.670 en Web of Science y 2.191 en ABI Inform Collection. Por ello, establecimos una doble estrategia de búsqueda para seleccionar solo artículos referidos a la optimización del consumo eléctrico en cementeras mediante técnicas de IA

En primer lugar, se llevó a cabo una búsqueda considerando únicamente los artículos que incluyesen en el título, resumen y *keywords* las siguientes cadenas de búsqueda: (1) Electricity AND Optimization AND Cement; (2) Electricity AND Optimization AND

Artificial Intelligence; (3) Electricity AND Optimization AND Cement AND Artificial Intelligence.

A continuación, debido, como hemos indicado, al número ingente de trabajos encontrados, centramos la búsqueda en artículos que incluyesen sólo en el título las siguientes cadenas de búsqueda; (1) Electricity AND Artificial Intelligence; (2) Electricity AND Optimization AND Industry; (3) Energy AND Optimization AND Cement; (4) Energy AND Optimization AND Artificial Intelligence.

Con estas búsquedas aparecieron un total de 477 artículos potencialmente revisables: 211 artículos en Scopus, 247 artículos en Web of Science y 19 en ABI Inform Collection.

Los 477 artículos fueron evaluados por su idoneidad para nuestros objetivos de investigación. Siguiendo el mismo proceso aplicado por otras revisiones de la literatura (Frishammar *et al.*, 2012; Mok *et al.*, 2015), se llevó a cabo una selección de artículos más estricta. Para llevar a cabo la cuarta fase de la revisión sistemática de la literatura -gestión y depuración de resultados de búsqueda- se elaboró una hoja en formato Excel.

Los artículos inicialmente obtenidos fueron revisados, en una primera fase, a través del análisis de títulos y resúmenes. Tras el análisis de los mismos, se pudo constatar que muchos de los artículos o hacían referencia de manera muy tangencial al tema objeto del estudio, o ni tan siquiera lo trataban. Solo un total de 14 abordaban realmente en los objetivos específicos de nuestra investigación.

En la tabla 1 se acompaña un cuadro detallado con los resultados numéricos de las distintas búsquedas que se han llevado a cabo para realizar el análisis sistemático de la literatura.

SCOPUS	ARTICLE TITTLE- ABSTRACT - KEYWORDS	ARTICLE TITTLE	TOTAL INTERÉS
"Electricity" & "Artificial Intelligence"		18	3
"Electricity" & "Optimization" & "Industry"		7	1
"Electricity" & "Optimization" & "Cement"	19		
"Energy" & "Optimization" & "Cement"		13	2
"Electricity" & "Optimization" & "Artificial Intelligence"	161	0	1
"Energy" & "Optimization" & "Artificial Intelligence""		8	
"Electricity" & "Optimization" & "Cement" & "Artificial Intelligence"	0		
TOTAL POTENCIALMENTE REVISABLES	180	31	7
WEB OF SCIENCE	ARTICLE TITTLE- ABSTRACT - KEYWORDS	ARTICLE TITTLE	TOTAL INTERÉS
"Electricity" & "Artificial Intelligence"		16	2
"Electricity" & "Optimization" & "Industry"		9	
"Electricity" & "Optimization" & "Cement"	51		
"Energy" & "Optimization" & "Cement"		16	1
"Electricity" & "Optimization" & "Artificial Intelligence"	142		
"Energy" & "Optimization" & "Artificial Intelligence""		13	
"Electricity" & "Optimization" & "Cement" & "Artificial Intelligence"	0		
TOTAL POTENCIALMENTE REVISABLES	193	54	3
ABI INFORM COLLECTION	ARTICLE TITTLE- ABSTRACT - KEYWORDS	ARTICLE TITTLE	TOTAL INTERÉS
"Electricity" & "Artificial Intelligence"		4	4
"Electricity" & "Optimization" & "Industry"		0	
"Electricity" & "Optimization" & "Cement"	1		
"Energy" & "Optimization" & "Cement"		0	
"Electricity" & "Optimization" & "Artificial Intelligence"	9	0	
"Energy" & "Optimization" & "Artificial Intelligence""		0	
"Electricity" & "Optimization" & "Cement" & "Artificial Intelligence"	5		
TOTAL POTENCIALMENTE REVISABLES	15	4	4
TOTAL ARTÍCULOS POTENCIALMENTE REVISABLES	388	89	477
TOTAL ARTÍCULOS A ANALIZAR			14

Tabla 1. Resultados de las búsquedas del análisis sistemático de la literatura. Fuente: Elaboración propia.

Con los 14 artículos que han servido de base para el proceso de investigación (Tabla 2) se acometió la quinta de las fases del estudio sistemático de la literatura -análisis de los resultados- (Medina-López *et al.*, 2010; Tranfield, *et al.*, 2003). Como puede verse en la tabla 2, considerando los temas de los que tratan, destacan los dedicados bien a estudiar el ahorro energético en cementeras o a pronosticar el precio de la energía haciendo uso de IA. Los resultados del análisis de la bibliografía previa relacionada con la optimización del coste eléctrico operando sobre variables del proceso, se abordan en el apartado 4.2. Los relacionados con la optimización del coste eléctrico operando sobre el precio del mercado, en el apartado 5.2.

TEMA DE ESTUDIO	SECTOR	ARTÍCULOS
Minimización del coste eléctrico utilizando I. A.	Intersectorial	Khotanzad, 2018.
Predicción del consumo eléctrico de industrias	Industria en general	Azadeh <i>et al.</i> , 2015.
Ahorro energético en plantas cementeras incluyendo soluciones integrales y gestión del horno.	Cementero	Castañón <i>et al.</i> , 2014.
	Cementero	Swanepoel <i>et al.</i> , 2013.
	Cementero	Swanepoel, 2013.
	Cementero	Shaohog <i>et al.</i> , 2012.
AI en la industria	Industria en general	Andrew, 2017.
Predicción del precio eléctrico utilizando AI	Intersectorial	Wellesley, 2001.
	Intersectorial	Hurtado <i>et al.</i> , 2014.
	Intersectorial	Zhang y Cheng, 2008.
	Intersectorial	Georgilakis, 2007.
	Intersectorial	Sreekumar <i>et al.</i> , 2020.
	Intersectorial	Théate <i>et al.</i> , 2020.
Aproximación general a la AI	Intersectorial	Andrew y Zhang, 2017.

Tabla 2. Temática de los artículos analizados. Fuente: Elaboración propia.

Por otro lado, en la tabla 3 se recoge un listado con los títulos de los 14 artículos seleccionados para análisis y las revistas en las que los mismos fueron publicados.

AUTORES	TÍTULO	REVISTA DE PUBLICACIÓN
Khotanzad, 2018	Using artificial intelligence to develop electricity load forecasts	TradeFair Group Publications, Ltd
Zhang y Cheng, 2008	Day-ahead electricity price forecasting using artificial intelligence	IEEE Electrical Power & Energy Conference
Georgilakis, 2007.	Artificial intelligence solution to electricity price forecasting problem	Applied Artificial Intelligence (ISSN 0883-9514)
Azadeh <i>et al.</i> , 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)
Castañón <i>et al.</i> , 2014.	Energy and environmental savings via optimisation of the production process at a Spanish cement factory	Journal of Cleaner Production Elsevier (ISSN: 0959-6526)
Swanepoel <i>et al.</i> , 2013.	Integrated energy optimisation for the cement industry: A case study perspective	Energy Conversion and Management (ISSN: 0196-8904)
Sreekumar <i>et al.</i> , 2020.	One Day Ahead Indian Electricity Price Forecasting Using Intelligently Tuned SVR	2020 IEEE International Power and Renewable Energy Conference
Swanepoel, 2013.	Modelling for Integrated Energy Optimisation in Cement Production	Energy conversion and Management (ISSN: 0196-8904)
Shaohog <i>et al.</i> , 2012.	Research on the Key Technology of Energy Management and Optimization in Cement Enterprises	Advanced Materials Research (ISSN 1662-8985)
Théate <i>et al.</i> , 2020.	An Artificial Intelligence Solution for Electricity Procurement in Forward Markets	Energies 2020, 13, 6435; DOI: 10.3390/en13236435
Andrew, 2017.	Artificial Intelligence is the New Electricity	Newstex Global Business Blogs
Wellesley, 2001.	EnvaPower's New Artificial Intelligence Software Makes Managing Electricity a No-Brainer	PR Newswire, NY
Andrew y Zhang, 2017.	The Optimistic Promise of Artificial Intelligence; Andrew Ng and Tong Zhang on how AI is going to be like electricity, transforming every industry	Wall Street Journal on line (ISSN: 2574 9579)
Hurtado <i>et al.</i> , 2014.	Estimating the offer price of electricity in Colombia by using artificial intelligence	Revista de Métodos Cuantitativos para la Economía y la Empresa (ISSN: 1886-516X)

Tabla 3. Relación de artículos seleccionados (títulos y autores) y revistas en las que se publicaron. Fuente: Elaboración propia.

De la tabla 4 se desprende que los años en los que se centran las investigaciones y estudios de los distintos artículos seleccionados, están comprendidos entre 1979 y 2019.

PERIODO ESTUDIO	
1979/2009	1
1999	1
2006, 7, 8	1
2007	1
2010	1
2011, 12	1
2012, 13	1
2012	1
2017	1
2018/19	2
General	3
TOTAL	14

Tabla 4. Período estudio. Fuente: Elaboración propia.

Por otro lado, también podemos señalar que los artículos tenidos en cuenta para nuestra investigación fueron publicados entre los años 2001 y 2020 (Tabla 5).

AÑO DE PUBLICACIÓN	
2001	1
2007	1
2008	1
2012	1
2013	2
2014	2
2015	1
2017	2
2018	1
2020	2
TOTAL	14

Tabla 5. Año publicación. Fuente: Elaboración propia.

En la figura 1 se ofrece información relativa al número de autores que firman los artículos seleccionados. Como puede apreciarse la gran mayoría de los artículos

(concretamente 5 de ellos, que representan al 36 % del total), fueron firmados por un solo autor.

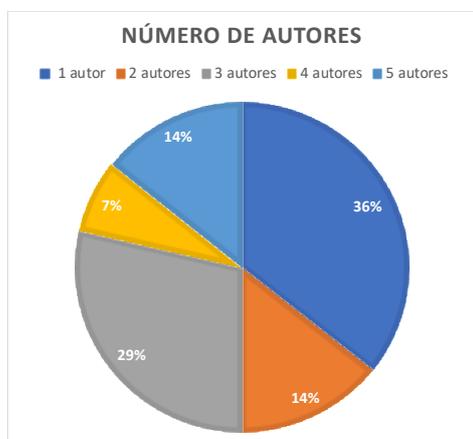


Figura 1. Número de autores. Fuente: Elaboración propia.

En la primera columna de la tabla 6 se han detallado las 22 universidades a las que pertenecen los autores de los artículos seleccionados. En la segunda columna de la tabla se indica el número de artículos publicados por cada una de las universidades indicadas.

INSTITUCIONES / UNIVERSIDADES	
Drilling Info (Consultora)	1
Dalian University of Technology (China)	1
Creta University (Grecia)	1
Teran University.	1
Dalhousie University (Canada)	1
School of Business (Australia)	1
ETSI Minas de León (Spain)	1
Facultad de Química (Universidad de Oviedo).	1
Instituto de Ciencias de la Educación "Eduardo Torroja" (CSIC). Madrid (España).	1
Facultad de Farmacia Universidad San Pablo CEU Madrid, España.	1
North West University. Pretorie, South Africa	2
School of Control, Science and Engineering. Univ. Jinan (China)	1
Enva Power.	1
Standford University	2
Tencert Holdings Ltd.	1
Baidu Inc.	1
Google Inc.	1
EAFIR University. Medellín (Colombia)	1
Montefiore Institute, Univ. Liège, Bélgica	1
Delhy University	1
TOTAL	22

Tabla 6. Universidades investigadoras. Fuente: Elaboración propia.

En la tabla 7 se ofrece información relativa a las distintas revistas en las que se han publicado los artículos.

REVISTA PUBLICACIÓN	
Power Magazine	1
Electrical Power & Energy Conference	1
Applied Artificial Intelligence (ISSN 0883-9514)	1
International Journal of Advanced Manufacturing Technology (ISSN: 1443-3015)	1
Journal of Cleaner Production Elsevier (ISSN: 0959-6526)	1
Energy Conversion and Management (ISSN: 0196-8904)	2
Advanced Materials Research (ISSN 1662-8985)	1
Newstex Global Business Blogs	1
PR Newswire, NY	1
Wall Street Journal on line (ISSN: 2574 9579)	1
Revista de Métodos Cuantitativos para la Economía y la Empresa (ISSN: 1886-516X)	1
2020 IEEE International Power and Renewable Energy Conference	1
Energies 2020 (1996-1073)	1
TOTAL	14

Tabla 7. Revista de publicación. Fuente: Elaboración propia.

En la figura 2 se ofrece una distribución geográfica de los artículos por continentes. La gran mayoría de los 14 trabajos analizados fueron desarrollados en América del Norte-EEUU (un total de 4) y Asia (otros 4).

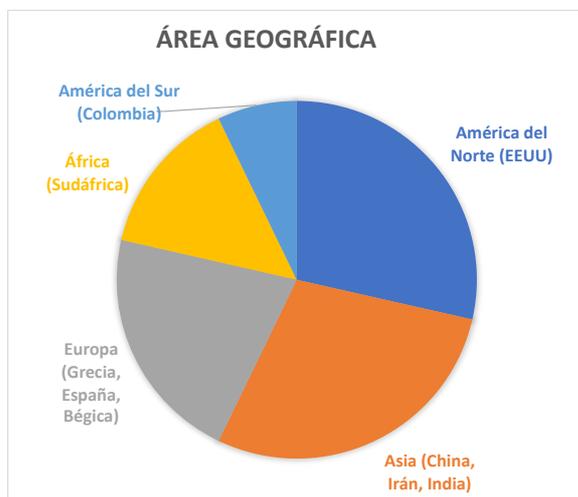


Figura 2. Área geográfica. Fuente: Elaboración propia.

Por último, se puede señalar que la mayor parte de las investigaciones de los artículos que se han analizado (un total de 11), fueron empíricas.

2.3. Encuestas a expertos y estudio cuantitativo.

El hecho de haber encontrado en la revisión sistemática de la literatura un número bajo de artículos referidos al tema objeto de investigación, y que además contaban con información incompleta relativa a los objetivos perseguidos, justifica la decisión de acometer estudios adicionales en el sector que permitan avanzar en el conocimiento y mejora de los temas estudiados. Para ello emplearemos encuestas y panel de expertos, que nos permitirán conocer las particularidades del consumo eléctrico de las fábricas de cemento, así como dar cumplimiento a los subobjetivos planteados.

Coryn y Scriven (2008) señalan en relación con los procesos de evaluación de la investigación científica, que la revisión por pares y la bibliometría son los métodos más utilizados, siendo la revisión por pares el más predominante. Estos autores hacen una distinción entre dos tipos de revisiones por pares utilizadas en la investigación científica. Una de ellas constituye un proceso utilizado para evaluar a investigadores individuales, productos de investigación o propuestas de investigación (como las revisiones de artículos en revistas); la otra se refiere a la revisión / evaluación mediante un panel de expertos. Sin embargo, el panel de expertos no siempre se utiliza como método de evaluación. El panel de expertos que hemos llevado a cabo en nuestra investigación ha servido para obtener datos cualitativos que serán empleados en nuestra investigación, pero no para acometer ningún tipo de revisión.

La revisión de un panel de expertos se considera el estándar de oro para determinar la calidad de la investigación (Bulter y McAllister, 2011; Rons *et al.*, 2011). El Comité de Ciencia, Ingeniería, Medicina y Políticas Públicas sugirió que la revisión de expertos es el método óptimo para evaluar la investigación aplicada (Committee on Science, Engineering and Public Policy, National Academy of Sciences, National Academy of Engineering, Institute of Medicine Policy and Global Affairs, 2001). Ha quedado suficientemente demostrado que se trata de un procedimiento efectivo para mejorar el comportamiento de la investigación y proporcionar a su vez información adicional sobre la calidad de la investigación (Barbosa y Grayson, 2009; Lane *et al.*, 2011).

Lawrenz *et al.* (2012), analizan el estudio llevado a cabo en relación con los procesos utilizados en dos tipos de revisiones de paneles de expertos de centros de investigación. Estos procesos han resultado de utilidad para la planificación de nuestro panel de expertos.

Cabe mencionar la dificultad que aparece habitualmente a la hora de encontrar expertos sin conflictos de intereses cuando se utiliza el panel de expertos, identificada por Quinlan *et al.* (2008) y Rons *et al.* (2011). En ambos casos se señala que la elección de pares activos altamente cualificados que cubran todos los aspectos de la investigación es el factor más importante para una revisión exitosa.

En esta fase de investigación se ha tenido en cuenta la opinión de 42 expertos del sector cementero español en temas eléctricos: directores industriales, directores de fábricas, asesores energéticos, responsables de la Agrupación de Fabricantes de Cemento de España (OFICEMEN), responsables de la Agrupación de Fabricantes de Cemento de Andalucía (AFCA), etc.

Para recabar datos cuantitativos, que serán objeto de estudio en este apartado 4.3., se enviaron encuestas a 11 expertos del sector cementero. Estas encuestas han servido para llevar a cabo un análisis desglosado de los costes eléctricos del sector cementero español, completamente novedoso y que no se había llevado a cabo anteriormente, según la información proporcionada por OFICEMEN.

Para el panel de expertos, que ha proporcionado una parte importante de los datos cualitativos que utilizaremos en nuestra investigación (apartados 4.3. y 5.3.), se han llevado a cabo entrevistas personales mediante cuestionarios a los otros 31 expertos. Entre los 31 expertos que colaboraron para aportar la información cualitativa, se encontraban 5 considerados expertos en materia de transformación digital e IA. A estos se les solicitó que completaran un cuestionario para valorar las posibles herramientas de IA a utilizar en el proyecto de investigación que nos ocupa.

Quinlan *et al.* (2008) sostienen que, a la hora de reunir equipos de expertos, resulta fundamental contar con revisores con experiencia interdisciplinar, además de con expertos en la materia concreta a estudiar. Los expertos seleccionados para nuestra investigación cumplían estas características. Por una parte, todos 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. Además, con los expertos seleccionados se cubre la totalidad de empresas cementeras que operan en España.

Para obtener los datos cualitativos y cuantitativos que han servido para nuestra investigación, se emplearon en el panel de expertos las siguientes encuestas y cuestionarios:

1) Cuestionario para analizar la mayor o menor influencia en el precio de la electricidad, de las distintas variables -meteorológicas, tecnologías de generación eléctrica, precios futuros de la electricidad, laboralidad, estacionalidad, etc.- Finalmente las variables seleccionadas por los expertos fueron las que se utilizaron en la arquitectura de las Artificial Neural Networks (ANN) que se esquematiza en la figura 26.

2) Cuestionario para analizar aquellas variables sobre las que se puede influir, incurriendo en mínimo coste e inversión, de cara a reducir el consumo eléctrico durante el proceso de producción. Los expertos propusieron 2 variables en la fase de cantera y trituradora, 1 en la fase de pre-homogeneización, 4 en el molino de crudo, 2 en los ciclones, 2 en el molino de carbón, y 4 en el molino de cemento. Estas variables serán analizadas de manera más detallada más adelante.

3) Cuestionario para valorar las herramientas de IA más adecuadas para acometer la optimización del gasto eléctrico en las cementeras. Como hemos indicado, 5 directivos eran expertos en materia de IA.

4) Para recabar los datos cuantitativos se han enviado encuestas a otros 11 expertos del sector cementero: una a cada una de las 10 compañías cementeras que operan en España y otra al director técnico de OFICEMEN. Estas encuestas han servido fundamentalmente para llevar a cabo un estudio desglosado de los costes eléctricos regulados del sector. Este análisis resultará de utilidad tanto para la presente como para futuras investigaciones sobre el tema (apartado 4.3.).

5) Finalmente se mantuvieron entrevistas telefónicas individuales, -no en grupo, para no condicionar las respuestas- con todos y cada uno de los expertos consultados, para profundizar en las respuestas proporcionadas en los cuestionarios.

Los resultados de la información cuantitativa obtenida mediante las encuestas a expertos se detallarán en los próximos capítulos.

2.4. Panel de expertos y estudio cualitativo.

En el estudio cualitativo del sistema eléctrico del sector, basado en un panel de expertos, han participado un total de 31 personas. Para ello se han mantenido entrevistas personales (algunas presenciales y otras telefónicas) con los expertos. De entre los 31 directivos que han participado, se ha contado con 5 que, además, eran especialistas en materia de Inteligencia Artificial. Se han tratado distintos aspectos y se han obtenido diversas conclusiones e implicaciones que serán abordadas en los apartados 4.4. y 5.3.

2.5. Herramientas disponibles para la optimización

Las tecnologías y herramientas disponibles para la optimización y mejora de la producción y las operaciones industriales son muchas y variadas. Entre ellas cabe destacar el *Internet of Things* (IoT), la minería de datos, el aprendizaje automático (*machine learning*), la impresión en 3D, el *blockchain* y los vehículos autónomos, entre otros. Cada una de estas herramientas/tecnologías tiene un papel diferente y contribuye a la resolución de problemas diferentes.

Para abordar el objetivo de reducción del coste eléctrico de las fábricas de cemento, de acuerdo con el planteamiento de esta tesis, se han identificado, a partir del estudio bibliográfico, tres tecnologías que resultarán de la máxima utilidad:

1.- Aprendizaje automático. El aprendizaje automático *-machine learning-* es una rama de la IA que se basa en el diseño de algoritmos (secuencias de instrucciones y órdenes creadas con el fin de solucionar problemas específicos), que permiten a las máquinas y ordenadores aprender de los datos sin necesidad de la intervención humana constante. Es decir que, una vez programados inicialmente, siguen aprendiendo con el tiempo sin necesidad de intervención del programador. En definitiva, el *machine learning* utiliza métodos computacionales y estadísticos, que ayudan al sistema a aprender patrones a partir de los datos, de cara a ayudar en la toma de decisiones. Su punto fuerte es que el proceso de aprendizaje se automatiza y va mejorando con el tiempo de entrenamiento a medida que consume mayor cantidad de datos, sin requerir la intervención humana.

El machine learning y el análisis de datos aplicado al mundo de la empresa, es lo que se conoce como *Business Intelligence* (Barlow, 2015).

En función de los datos de entrada, se pueden dar distintos tipos de aprendizajes:

a. Aprendizaje supervisado. Es aquel que utiliza datos etiquetados (ofrecen información acerca de la salida), para deducir la función de comportamiento del hecho estudiado. Los datos son pares de objetos (de entrada y resultado deseado) que posibilitan el objetivo de crear una función capaz de predecir el valor correspondiente a cualquier objeto de entrada válido, tras haber visto y aprendido de una serie de ejemplos (Lara, 2014). El aprendizaje supervisado se suele usar en:

- Problemas de clasificación. Se trata de obtener distintas categorías y son adecuados para problemas de diagnósticos, detección de fraude de identidad, etc.

- Problemas de regresión. La regresión es un proceso estadístico que se utiliza para estimar la relación entre variables. Ayuda a entender la variación de la variable dependiente al producirse un cambio en una de las variables independientes. En los problemas de regresión se intenta predecir un valor continuo, como es el caso de predicciones meteorológicas, predicciones de precios, expectativas de vida, de crecimiento, etc.

b. No supervisado. Se trata de un modelo que se ajusta a las observaciones, pero en el que no existe un conocimiento a priori. Es el propio algoritmo el que identifica los procesos de manera inteligente sin que se le ofrezcan previamente ejemplos de los cuales aprender. Se suele utilizar en problemas de clusterización en los que se buscan grupos de registros que son similares entre sí y al mismo tiempo diferentes al resto.

c. Aprendizaje por refuerzo. En este tipo de aprendizaje se fija un objetivo al sistema, pero tampoco se le dan pautas ni instrucciones que le sirvan para ir aprendiendo como alcanzarlo. El sistema debe ir actuando por sí solo para ir acercándose y alcanzando el objetivo marcado. El sistema dispone de distintas acciones que irá combinando hasta la consecución del objetivo. Cuando se acerca al objetivo se le ofrece una recompensa; cuando se aleja no se le da.

2.-Internet of Things (IoT). De entre todas las herramientas digitales disponibles para dar solución al problema planteado, el aprendizaje automático/machine learning que se acaba de exponer, resultará fundamental. Esta tecnología utiliza como "materia prima" para el proceso de aprendizaje, grandes volúmenes de datos, que en la mayoría de los casos se recolectan utilizando tecnologías de IoT. El IoT es un concepto que hace referencia a un conjunto de aparatos, objetos y equipos conectados a Internet y comunicados entre sí - pueden ser sensores, dispositivos mecánicos, objetos cotidianos como electrodomésticos, ropa, etc.- que ayudan a recoger datos e información. Esta información resultará de utilidad para alimentar los procesos de aprendizaje del machine learning. En las plantas cementeras, este objetivo se cubre con los elementos de medida e instrumentación del control distribuido de la planta, que utiliza decenas de dispositivos, repartidos por las distintas etapas del proceso productivo, cada uno de los cuales recoge cada día miles de datos diferentes. Se trata por lo tanto de una interacción de máquina a máquina, conocida con el nombre de interacción M2M (machine to machine).

3.- Minería de datos. Data Mining. Cuando se aborda el concepto de "datos", aparecen cuestiones que interesa citar de cara a conocer en profundidad el funcionamiento de las herramientas de IA que utilizaremos. El *Big Data* consiste en desarrollar mecanismos capaces de procesar y gestionar grandes cantidades de datos, de cara a encontrar patrones y/o modelos repetitivos que nos permitan conseguir información útil para la toma de decisiones (Pérez, 2014). En el Big Data (datos masivos) se dan tres características: volumen, velocidad y variedad de los datos. El big data se basa en la afirmación de que se deben guardar y conservar todos los datos posibles -hoy puede hacerse a un coste muy competitivo-, dado que conocemos las preguntas de hoy, pero no las del mañana. (García *et al.*, 2016).

A través del *Data Science*, se pueden utilizar los datos para generar información que nos ayude de manera directa a solucionar problemas que mejoren la vida de las personas y hacer de esta manera un mundo mejor.

Dentro del amplio concepto que supone el big data, se encuentran las técnicas de *minería de datos y aprendizaje automático*, que sirven para extraer la información que contienen los datos y ayudar en la toma de decisiones (Bramer, 2007).

La Minería de datos -data mining (DM)- es la fase más importante de un proceso conocido como *Knowledge Discovery in databases (KDD)*, y se define como el conjunto de técnicas que permiten explorar de manera automática o semiautomática grandes bases de datos (Figura 3) (Lara, 2014; Pérez, 2014 y García *et al.*, 2016).

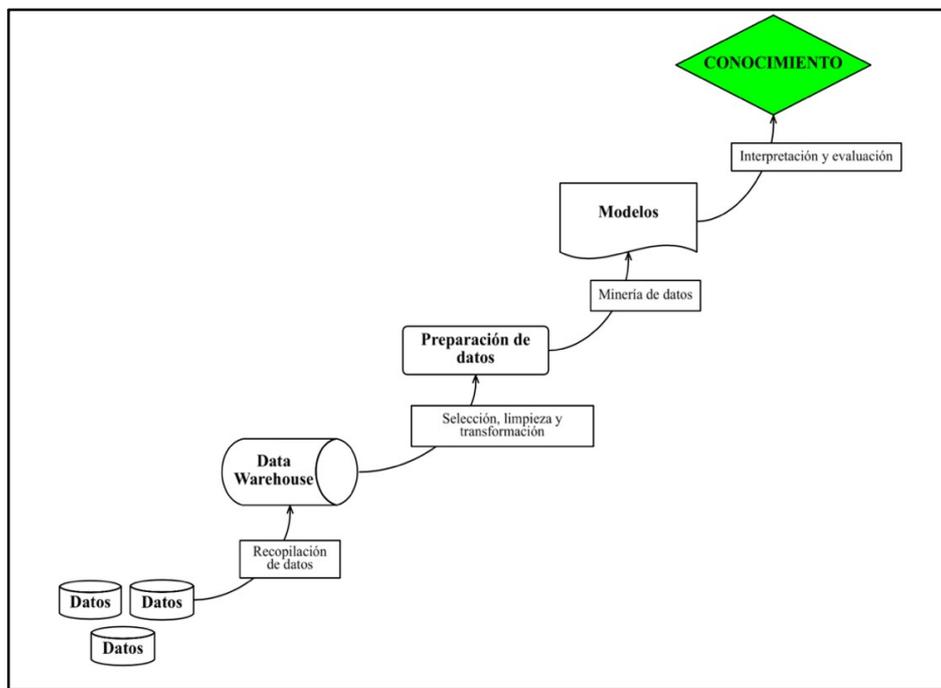


Figura 3. Proceso de KDD. Fuente: Elaboración propia.

El proceso de *Knowledge Discovery in databases (KDD)*, consta de 4 fases que expondremos a continuación:

Fase I.- Recopilación de datos. En esta primera fase se toman los datos que provendrán de una o de varias fuentes y se guardan en un almacén de datos o *data warehouse*.

Fase II.- Preparación de datos. Los datos almacenados en el data warehouse deben ser transformados en un conjunto de datos que sea consistente para obtener información útil para la toma de decisiones, que es el verdadero objetivo del proceso. Recientemente ha surgido el término *Smart data*, para hacer referencia a dos importantes características de los datos: la veracidad y el valor de los mismos. El objetivo de esta fase será filtrar el ruido y mantener los datos valiosos, de manera puedan ser utilizados para la toma de decisiones inteligentes que nos ayuden a dar solución al problema planteado. La preparación de datos consta a su vez de tres subfases:

- Selección de datos. A través de técnicas de muestreo adecuadas se seleccionará el subconjunto de datos, diferenciando las variables objetivo y las variables independientes.

- Limpieza de datos. Consiste en tratar los datos que pueden influir en un análisis inexacto o bien proporcionar resultados incorrectos. De esta manera se identificarán valores atípicos (*outliers*), datos erróneos, datos irrelevantes y datos incompletos que habrá que obviar.

- Transformación. Se trata de preparar los datos de entrada acorde a la técnica de minería de datos que se empleará.

Una vez preparados los datos, lo cual resulta un paso obligatorio, ya que sin ello los algoritmos de extracción de conocimiento no podrían ejecutarse u ofrecerían resultados erróneos, se aplican en algunos casos -cuando el tiempo de ejecución de los algoritmos o el tamaño de los datos resulta prohibitivo- técnicas de reducción de datos (García *et al.*, 2015; García *et al.*, 2016 y Han *et al.*, 2011).

Fase III.- Minería de datos (*Data mining*): Obtención de un modelo en el que están implícitos los patrones de comportamiento observados en el hecho que se está analizando. Habitualmente se distingue entre técnicas predictivas (para predecir comportamientos, valores, etc.) y técnicas descriptivas, que describen los datos aportados al sistema.

Fase IV.- Interpretación y evaluación. Consiste en evaluar la calidad de los modelos e interpretarlos, de cara a obtener el conocimiento buscado.

Finalmente podemos concluir que el conocimiento y la información final obtenida tras el proceso descrito, no solo dependerá del algoritmo empleado y del proceso de aprendizaje que le ayude a funcionar. La calidad de los datos minados que se le proporcionen al sistema será fundamental para que las predicciones tengan éxito y resulten de utilidad para alcanzar el objetivo buscado.

2.6. Algoritmos y técnicas de aprendizaje automático.

En este apartado se expondrán y analizarán las principales técnicas de aprendizaje automático y algoritmos que existen en la actualidad, de cara seleccionar aquellos más

idóneos y que nos resultarán de utilidad para dar solución a nuestro problema: optimizar el coste eléctrico en fábricas de cemento. Los algoritmos seleccionados se utilizarán en los capítulos 4.4, 4.5 y 5.4, que se dedicarán de manera específica a desarrollar el modelo de optimización del coste eléctrico.

I. Árboles de decisión. Se trata de algoritmos de aprendizaje supervisado que se utilizan habitualmente para la toma de decisiones cuando nos enfrentamos a escenarios con riesgos, costes, beneficios y opciones múltiples. Son conjuntos de decisiones organizadas en una estructura jerárquica, de tal manera que la decisión final a tomar se puede determinar siguiendo las condiciones que se van cumpliendo desde la raíz del árbol hasta alguna de sus hojas. Son estructuras en forma de árbol, en las cuales se van representando de manera secuencial distintas condiciones y acciones (Hernández *et al.*, 2004).

Para el desarrollo de este tipo de algoritmos se siguen los siguientes pasos:

- Definición del problema.
- Configuración de la estructura del árbol.
- Asignación de probabilidades a los distintos estados de naturaleza.
- Estimación de resultados para cada alternativa posible y estados de naturaleza.
- Resolución del problema obteniendo como resolución la ruta con el resultado óptimo.

II. Redes Neuronales Artificiales. Conocidas en inglés como Artificial Neural Networks, (ANN), son modelos matemáticos basados en el comportamiento biológico de las neuronas humanas y en cómo se organizan formando la estructura del cerebro (Pérez, 2007). Pueden utilizar métodos de aprendizaje supervisados, pero también no supervisados, fundamentalmente cuando se enfrentan a problemas de agrupamiento.

Las redes neuronales son conjuntos de neuronas artificiales, conectadas de una forma concreta y organizadas en capas, cuyo objetivo es aprender, modificándose automáticamente a sí mismas, de forma que puedan llegar a realizar tareas complejas que no podrían ser realizadas mediante la programación clásica. Las redes neuronales permiten automatizar funciones, basándose en el aprendizaje, de cara a predecir hechos futuros y su vez clasificar

distintas situaciones. Existen diversos tipos de ANN que se han tenido en cuenta a lo largo de nuestra investigación antes de decidimos por la más adecuada:

- Redes Monocapa. Este tipo de redes suelen utilizarse para dar solución a problemas simples.
- Redes neuronales Convolucionales. Es una variación de las redes multicapas que se utiliza para tareas de visión artificial *-computer vision-* es decir, clasificación y segmentación de imágenes.
- Redes Neuronales Recurrentes (RNR). Resultan de gran utilidad para resolver problemas en los que se trabaja con secuencias de datos, y no datos de carácter individual (imágenes, textos escritos, palabras, etc.). También se han utilizado en ciertas ocasiones para predecir precios eléctricos.
- Redes Neuronales de base radial. Han sido utilizadas frecuentemente para determinar propiedades de distintos fluidos y para el modelado medioambiental. En el sector de la minería es frecuente utilizarlas para valorar la calidad de las materias primas obtenidas.
- Redes neuronales multicapa (*MPLs-Multilayer Perceptron*). Este tipo de redes se utilizan para dar solución a problemas más complejos en los que intervienen variables de diversa naturaleza. Nos resultará de utilidad a la hora de dar solución a algunas cuestiones abordadas en nuestro proceso de investigación, (Pereira *et al.*, 2013).

En la figura 4 se presenta una representación gráfica del funcionamiento de una neurona artificial. Como puede verse, la suma de las distintas entradas multiplicadas por sus pesos asociados determina el impulso nervioso que recibe cada una de las neuronas. Este valor es procesado dentro de la neurona mediante una función de activación $-f(x)-$ que devuelve el valor y lo envía como valor de salida de la neurona.

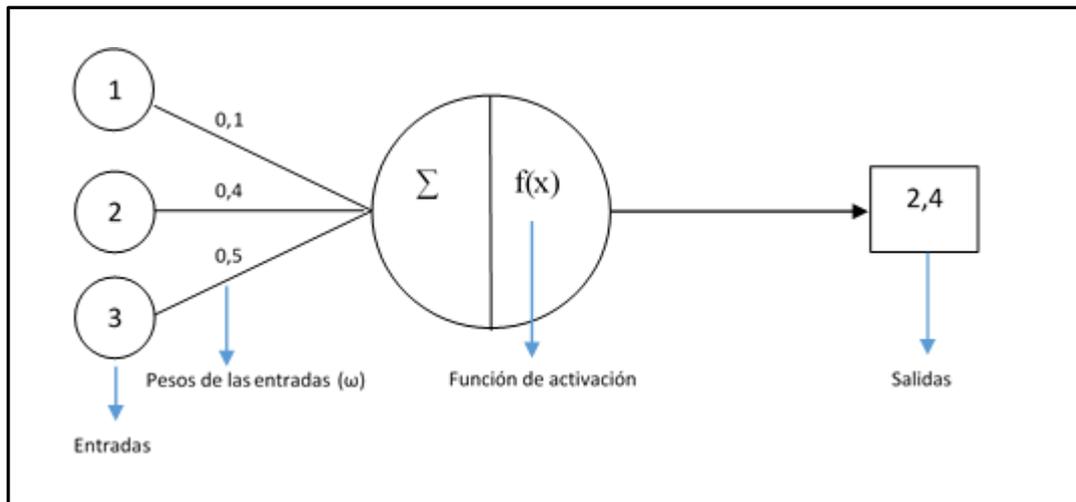


Figura 4: Neurona artificial. Fuente: Elaboración propia.

A semejanza del cerebro humano, que está compuesto por neuronas interconectadas entre sí, las redes neuronales reciben una serie de valores de entrada; cada una de estas entradas llega a un nodo llamado neurona. Como se indicó anteriormente, el primer paso a la hora de poner en funcionamiento una red neuronal consiste en seleccionar adecuadamente los datos de entrada. Para ello, según Hernández *et al.* (2004), resulta fundamental que los datos sean relevantes, es decir que sean datos que afecten realmente al resultado final que intentamos predecir. Además, será importante sintetizar y seleccionar un conjunto de datos no muy amplio, que realmente sirva para predecir el resultado buscado. Si no aseguramos la relevancia de los datos, es muy posible que la red neuronal no funcione correctamente.

Las neuronas de la red están a su vez agrupadas en capas que forman la red neuronal. Existen tres tipos de capas (Hernández *et al.*, 2004):

- Capa de entrada. Es la que recibe la información del exterior.
- Capas ocultas. Las que procesan la información internamente.
- Capa de salida. Es la que obtiene la respuesta de la red, aportada por las capas ocultas, y la transfiere al exterior.

Cada una de las neuronas de la red posee a su vez un peso, un valor numérico (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 sería un modelo de regresión lineal a la que se le sumaría un sesgo -conocido como bias- “b”:

$$Y = X_1 * \omega_1 + X_2 * \omega_2 + X_3 * \omega_3 + b$$

Pero 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 para mejorar su rendimiento y aprender a realizar su función correctamente. El entrenamiento de la red se realiza modificando los pesos de las neuronas introducidos (ω), de manera que finalmente consiga acercarse lo más posible a los resultados deseados (resultado real). El sistema irá modificando los pesos, buscando siempre que el valor obtenido en la función de regresión lineal se acerque lo máximo posible al valor obtenido en la realidad. Surge así una de las redes más extendidas y utilizadas en el ámbito de la IA, conocida como Perceptrón Multicapa -*Multilayer Perceptron-MLP*-, y que como se ha indicado, resultará de máxima utilidad, para dar cumplimiento a nuestro objetivo (Pereira *et al.*, 2013 y Lara, 2014).

En este modelo se van introduciendo datos de entrenamiento a la red. El proceso de entrenamiento será fundamental para la red neuronal, pues le permitirá ir acercándose cada vez más al resultado real que debe predecir. Cada grupo de datos se denomina “época”. Los datos van avanzando desde la capa de entrada a las capas ocultas y a la capa de salida. 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 para cada grupo de pesos y el resultado correcto, utilizando para ello derivadas parciales.

Veremos a continuación como el algoritmo de entrenamiento *Backpropagation* consigue ir minimizando al máximo el error (E). La red calculará los errores como la variación que tiene lugar entre el resultado obtenido y el resultado procedente de los datos reales que sirven de aprendizaje a la red para cada grupo de pesos. Las salidas erróneas se propagan hacia atrás en la red neuronal, desde la capa de salida hacia las neuronas de la capa oculta. Estas neuronas solo recibirán una fracción de la señal total del error, en función de

los pesos de cada una (ω). Para minimizar este error, el algoritmo utilizará el método *Mean Squared Error (MSE)*. El mismo expresará el error 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 $\frac{1}{2}$, de manera que se simplifique el cuadrado cuando calculemos la derivada parcial de la función error respecto a los pesos concretos. La derivada servirá para obtener la variación del error respecto a la variación de los pesos.

$$E = \frac{1}{2} (y - S)^2 \longrightarrow \frac{\partial E}{\partial \omega}$$

E: Error

y: Valor real

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. Cuantas más capas tenga la red y cuanto más densa sea, podrá operar con funciones más complejas. El funcionamiento expuesto puede observarse de forma esquemática en la figura 5 (funcionamiento de una red neuronal de 3 capas).

Este sistema se conoce también como *Sistema de Caja Negra*, pues lo que ocurre con los datos de entrada en las capas ocultas, hasta obtener los de salida, no es conocido por el usuario. El perceptrón realiza cálculos complejos en estas capas para obtener el resultado de salida.

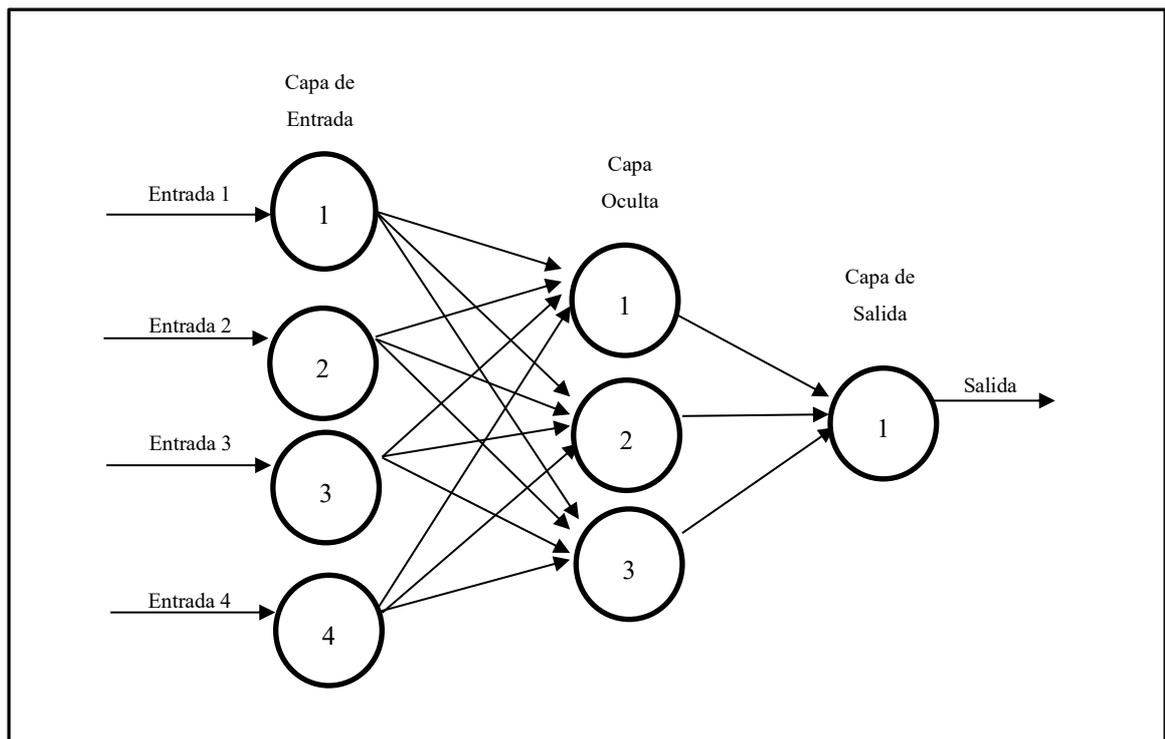


Figura 5. Funcionamiento de la Red Neuronal con el algoritmo Backpropagation.

Fuente: Elaboración propia.

Como ya se ha indicado, cada neurona, a la hora de generar la salida una vez procesado el dato de entrada correspondiente, hace uso de una función de activación. En función de que el umbral sea mayor o menor, la respuesta de cada neurona será mayor o menor. Para configurar nuestra red neuronal multicapa se han analizado diversas funciones de activación disponibles, tales como:

- Función lineal.
- Función Sigmoide.
- Función Tangente hiperbólica.
- Función Escalón.
- Función Rectified Linear Unit (RELU).
- Función Leaky RELU.

III. Máquinas vectores de soporte (Support Vector Machine). Son métodos de aprendizaje supervisados, que originalmente se idearon para resolver problemas de

clasificación binaria. En la actualidad han evolucionado y se emplean también para resolver problemas de regresión, agrupamiento y multclasificación (Pérez, 2007; Carmona, 2014, Nagi *et al.*, 2010; Nagi *et al.*, 2008).

IV. Redes bayesianas. Pertenecen al conjunto de paradigmas de aprendizaje supervisado denominados “Modelos gráficos probabilísticos”. Se trata de un método gráfico en el cual se muestran una serie de variables aleatorias (nodos) y las dependencias condicionantes que existen entre ellas, haciendo uso de un gráfico acíclico dirigido (Directed Acyclic Graph) (Hernández *et al.*, 2004; Castillo, *et al.*, 1997).

V. Lógica difusa (fuzzy logic). Según Filho *et al.*, (2004), se trata de una extensión de la lógica clásica, que utiliza las llamadas “funciones de pertenencia” para medir la afinidad que tiene una muestra de datos con respecto a un grupo, de manera que asigna a cada elemento un grado de pertenencia dentro del intervalo cerrado (0, 1). Esta herramienta ayuda a cuantificar la incertidumbre.

Esta metodología según Hernández *et al.*, (2004), resulta de gran utilidad para trabajar con recolecciones de datos cuyos límites no estén claramente definidos. Sirve para explicar muchos hechos cotidianos del mundo en que vivimos, como por ejemplo para simular posibles estrategias de gestión empresarial.

VI. Vecinos más cercanos (K-NN). Es un método de aprendizaje no supervisado que utiliza una función de distancia para clasificar un nuevo ejemplo dentro de un conjunto. Para ello se selecciona el parámetro “k” que indica el número de vecinos más cercanos que se tendrá en cuenta para establecer la comparación. El factor “k” es clave en este modelo, pues influye en la bondad del sistema.

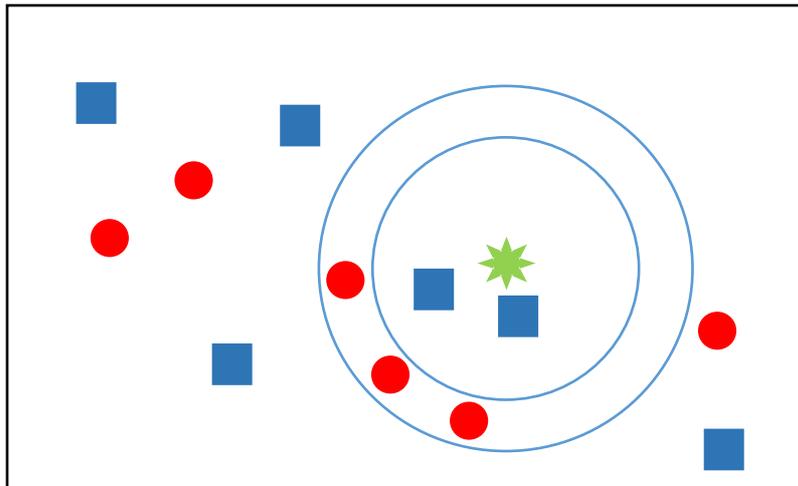


Figura 6. Ejemplo de K Vecinos más cercanos. Fuente: Elaboración propia.

La figura 6 muestra como para $K=2$ el algoritmo clasificaría la estrella verde dentro de la clase “cuadrado azul”. Sin embargo, para un $K=5$, el mismo quedaría clasificado dentro de la clase “círculo rojo”.

Este algoritmo se utiliza tanto en clasificación como en regresión y aprende a través de los distintos registros que existan en la base de datos. Para operar se basa en la distancia euclídea:

$$(x_i - x_j)^2 + (y_i - y_j)^2 \quad // \quad d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

Compara el comportamiento del caso a predecir con los “ k ” vecinos más cercanos, es decir, con aquellos con la d_{ij} más pequeña (Hernández *et al.*, 2004.; Pérez, 2007).

VII. **K-medias (K-means).** Es un algoritmo de clasificación no supervisada (clusterización) que agrupa objetos en k grupos basándose en sus características. El agrupamiento se realiza minimizando la suma de distancias entre cada objeto y el centroide de su grupo o clúster (Haben *et al.*, 2016; Ali *et al.*, 2016). Así, los elementos que comparten características semejantes estarán juntos en un mismo grupo, separados de los otros grupos con los que no comparten características. En este algoritmo se desconoce de antemano el valor de la etiqueta clase.

Se trata del algoritmo más utilizado para llevar a cabo un agrupamiento basado en prototipos. El prototipo se define como el centroide del grupo, es decir, el punto medio

de los objetos (Hernández *et al.*, 2004). Para establecer los grupos se utiliza, al igual que en el caso anterior, la distancia euclídea.

Podemos aplicar K-means en:

- Segmentación de clientes.
- Agrupación de textos que hablan de temas similares.
- Geoestadística.
- Comunidades de redes sociales.
- Prevención del crimen.

VIII. Algoritmos genéticos. Se trata de un método que imita los principios de la evolución natural para hallar una solución óptima a un problema de optimización. El sistema parte de una población inicial de individuos con una determinada codificación genética. La población va evolucionando de manera que solo determinados cromosomas -los mejores- serán seleccionados para formar parte de la nueva población. Para ello se aplican de manera continua mecanismos de selección, recombinación y mutación de cromosomas. Este ciclo evolutivo continúa hasta que se da un determinado criterio de parada. Este criterio, por ejemplo, podría ser un número concreto de generaciones o ciclos, hasta que se alcance un determinado criterio de convergencia (Nagi *et al.*, 2010). Este método puede utilizarse combinando con otros algoritmos como las ANN y las máquinas de vectores soporte, con el objetivo de aumentar el rendimiento y proporcionar al modelo una solución más robusta (Carmona, 2014; Michalewicz, 1999; Nagi *et al.*, 2010; Nagi *et al.*, 2008).

Capítulo 3. ANÁLISIS COMPARATIVO DE LOS PRECIOS ELÉCTRICOS EN ESPAÑA Y EN LA UE-28.

3.1. Introducción.

En este capítulo se analiza la evolución que han seguido los precios de la electricidad en España y en la UE-28. Por otro lado, se establece una comparativa entre países y se detalla aquellos factores que más influyen sobre el precio de la electricidad.

3.2. Análisis comparativo de los precios eléctricos en España y en la UE-28.

Con la información extraída de distintas fuentes bibliográficas consultadas, se ha llevado a cabo una comparativa del precio eléctrico de la industria electro intensiva española (20.000-150.000 MWh) con la europea, concluyendo que España presenta uno de los costes eléctricos más altos de la UE. Los datos ofrecidos por la Oficina Europea de Estadística - Eurostat- sobre la evolución de los precios del MWh para la industria electro intensiva, muestran claramente como el precio de la energía en España es superior al de la gran mayoría de sus competidores directos.

Los datos comparados del precio eléctrico de la industria electro intensiva de los 28 países de la UE, con un consumo de entre 20.000 MWh y 150.000 MWh, que es franja en la 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 4 países: Chipre, Malta y Reino Unido e Irlanda (Tabla 8).

De esta manera, según la estadística de Eurostat de precios de electricidad para consumidores no domésticos, con consumos entre 20.000 y 150.000 MWh del año 2018 (último año que abarca nuestro estudio), los países de la UE 28 tienen un precio medio del MWh de 61,3 €, mientras que en España este alcanza los 78,8 €. Algunos precios de competidores directos de España para este mismo período son: Bélgica, 55,12 €; Alemania, 48,82 €; Francia, 53,1 €; Italia, 71,2 €; Portugal, 63,95 € (Tabla 25).

GEO/TIME	20.000-70.000 MWh		70.000-150.000 MWh		2018	2018
	2018 S1	2018 S2	2018 S1	2018 S2	(50% / 50%)	(10% / 90%)
European Union - 28 countries	0,0626	0,0648	0,0568	0,0610	0,0613	
European Union - 27 countries (2007-2013)	:	:	:	:		
Euro area (0,0603	0,0622	0,0539	0,0588	0,0588	
Belgium	0,0516	0,0598	0,0494	0,0597	0,055125	
Bulgaria	0,0672	0,0667	0,0625	0,0596	0,064	
Czechia	0,0620	0,0639	0,0633	0,0628	0,063	
Denmark	0,0497	0,0576	0,0516	0,0546	0,053375	
Germany (until 1990 former territory of the FRG)	0,0501	0,0516	0,0457	0,0479	0,048825	
Estonia	0,0576	0,0624	0,0575	0,0623	0,05995	
Ireland	0,0888	0,0951	0,0807	0,0868	0,08785	
Greece	0,0623	0,0697	:	:		
Spain	0,0866	0,0807	0,0692	0,0786	0,0788	0,0749
France	0,0554	0,0542	0,0514	0,0514	0,0531	
Croatia	0,0647	0,0644	0,0576	0,0588	0,061375	
Italy	0,0722	0,0781	0,0624	0,0721	0,0712	
Cyprus	0,1152	0,1576	0,1026	0,1397	0,128775	
Latvia	0,0558	0,0570	0,0468	0,0502	0,05245	
Lithuania	0,0541	0,0622	0,0520	0,0555	0,05595	
Luxembourg	0,0408	0,0425	0,0343	:		
Hungary	0,0598	0,0627	0,0598	0,0672	0,062375	
Malta	0,0989	0,0986	0,0953	0,0951	0,096975	
Netherlands	0,0519	0,0559	0,0505	0,0576	0,053975	
Austria	0,0522	0,0567	0,0470	0,0514	0,051825	
Poland	0,0516	0,0532	0,0444	0,0467	0,048975	
Portugal	0,0641	0,0693	0,0590	0,0634	0,06395	
Romania	0,0591	0,0635	0,0551	0,0630	0,060175	
Slovenia	0,0528	0,0557	0,0500	0,0531	0,0529	
Slovakia	0,0639	0,0614	0,0552	0,0625	0,06075	
Finland	0,0466	0,0517	0,0475	0,0482	0,0485	
Sweden	0,0441	0,0515	0,0381	0,0445	0,04455	
United Kingdom	0,0954	0,0979	0,0916	0,0920	0,094225	
Iceland	:	:	:	:		
Liechtenstein	:	:	:	:		
Norway	0,0486	0,0596	0,0413	0,0507	0,05005	
Montenegro	0,0421	0,0375	:	:		
North Macedonia	0,0626	0,0660	0,0545	0,0746	0,064425	
Serbia	0,0548	0,0548	0,0553	0,0549	0,05495	
Turkey	0,0480	0,0534	0,0463	0,0531	0,0502	
Bosnia and Herzegovina	0,0484	0,0512	0,0343	0,0342	0,042025	
Kosovo	:	:	:	:		
Moldova	:	:	:	:		
Ukraine	0,0540	0,0547	0,0530	0,0548	0,054125	
Georgia	0,0419	0,0503	:	0,0494		

Tabla 8. Precio kWh para la industria electro intensiva (Bands IE 20.000-70.000 MWh e IF:70.000-150.000 MWh). Fuente: Estadísticas Eurostat, 2019.

Por lo tanto, podemos concluir que el coste eléctrico de la industria electro intensiva en España, durante 2018, fue unos 25/30 € superior al coste de países como Francia o Alemania.

En el primer semestre de 2019 el precio de la electricidad en España experimentó una tendencia a la baja. Así el precio del MWh, para consumidores no domésticos con

consumo entre 20.000 y 150.000 MWh, se situó en 77,94 €/MWh mientras que la media de la EU 28 subió hasta 66,46 €/MWh. (Eurostat. Estadísticas de precios eléctricos de Eurostat. 2019). En el primer semestre de 2021, último periodo con datos oficiales publicados por Eurostat al cierre de esta tesis doctoral, se redujo la diferencia entre los precios eléctricos de España (66,2 €/MWh) y los de la UE28 (65,45/MWh). (Eurostat. Estadísticas de precios eléctricos de Eurostat. 2021). No obstante cabe señalar que la industria electro intensiva europea en general, a partir del segundo semestre de 2021, ha experimentado una subida del precio eléctrico exponencial, que ha contribuido a agravar más el problema del coste eléctrico, objeto de análisis en esta investigación.

En el mes de octubre de 2021, el precio promedio mensual estuvo por encima de los 135 €/MWh en casi todos los mercados eléctricos europeos, llegando a superar los 210 €/MWh en algunos casos. La excepción fue el mercado Nord Pool de los países nórdicos, con un promedio de 57,10 €/MWh. En cambio, el precio promedio mensual más elevado, de 217,63 €/MWh, fue el del mercado IPEX de Italia, seguido por el del mercado N2EX del Reino Unido, de 211,67 €/MWh. En el resto de los mercados, los promedios estuvieron entre los 139,49 €/MWh del mercado EPEX SPOT de Alemania y los 199,92 €/MWh del mercado MIBEL de Portugal (AleaSoft Energy Forecasting).

Como pone de manifiesto el Consejo de Reguladores del Mercado Ibérico de la Electricidad (MIBEL) en su informe “Estudio comparativo de los precios MIBEL (contado y plazo) con otros mercados europeos y su relación con el mercado único”, de julio de 2019, más de la mitad del diferencial que sufre la industria electro intensiva española se corresponde con los elevados precios de nuestro mercado eléctrico. El resto del diferencial proviene de costes del sistema y de distintas compensaciones que reciben las industrias europeas competidoras y no las españolas.

Así, la industria en general ha perdido con el mecanismo de retribución del servicio de interrumpibilidad. Este constituía una herramienta fundamental con la que contaba la industria, para reducir el diferencial de precios con Europa, pero desafortunadamente sufrió una importante reducción del 40% entre 2018 y 2019. En julio de 2020, el servicio de interrumpibilidad de la industria electro intensiva se sustituyó por este mecanismo de “Reserva Estratégica para la Respuesta Rápida”, que en estos momentos se encuentra en desarrollo.

Otro ejemplo de la dificultad añadida que supone el mercado eléctrico para la industria electro intensiva, lo encontramos en el “Mecanismo de compensación de costes de emisiones indirectas de gases de efecto invernadero” de 2018. A pesar de que la Comisión Europea permitiría destinar el 25% del total de ingresos de las subastas de derechos de emisión a compensar el CO₂ indirecto que paga la industria en su factura de electricidad (en 2018, más de 1.300 millones), el Ministerio para la Transición Ecológica creó para 2019 un mecanismo de compensación por una cuantía muy inferior. Concretamente se fijaba una cantidad máxima de 91 millones de euros (70 aportados por el propio Ministerio). Para la industria electro intensiva en general, una reducción tan significativa de los fondos destinados a compensar el CO₂ indirecto que emitía, supuso un gran varapalo. El sector cementero, por decisión de la UE, no ha podido beneficiarse de este mecanismo de compensación en ningún momento.

Los trabajos futuros deberán actualizar este análisis económico del aumento de los costes eléctricos, pues a la fecha de finalización de esta tesis doctoral, el Estatuto de Electointensivos está aprobado pero pendiente de implementación, por lo que se desconoce su impacto económico real.

En el apartado 4.3 se desarrollará un análisis del precio eléctrico, centrado de manera específica en de la industria cementera. Para el mismo se ha vuelto a utilizar el formato estadístico que ofrece la Oficina Europea de Estadística (Eurostat) y se han considerado los consumos energéticos situados entre dos rangos o bandas de consumo: Band IE: 20.000-70.000 MWh y Band IF: 70.000-150.000 MWh, dado que es en ellos donde se sitúan las plantas cementeras. Pero se ha de tener en cuenta que la mayor parte de las fábricas estarían en el segundo rango. Por lo tanto, se debe calcular una media ponderada, que confiera mayor peso al segundo rango (entre el 90% y el 95%), para obtener un coste eléctrico aproximado para el sector cementero español, que sea lo más realista posible (Tabla 8).

En la figura 7 se compara gráficamente la evolución del precio de la energía eléctrica de la industria electro intensiva española y europea (EU-28), situada en las franjas de consumo 20.000/150.000 MWh, por semestres, para el periodo 2007- primer semestre de 2019. Se puede comprobar como a partir del año 2011, el precio eléctrico que soporta la industria española es superior al de la media de la UE-28. Concretamente en 2018 la energía en España fue un 27,96 % más cara que en la UE-28 (Eurostat. Estadísticas de precios eléctricos de Eurostat, 2019).

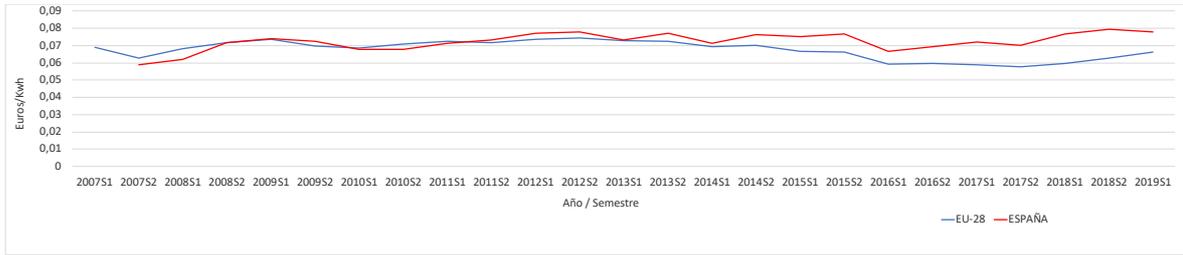


Figura 7. Coste eléctrico de la industria electro intensiva española vs EU (28) (20.000-150.000 MWh) por semestres, entre 2007 y 2018. Expresado en €/ kWh. Fuente: Elaboración propia a partir de datos de Eurostat, 2019.

Por otro lado, OMIE ofrece información precisa acerca de los precios diarios, y también horarios, de la electricidad en nuestro país. Además, ofrece información acerca de los precios mínimos, medios y máximos diarios (ejemplos en la Figura 8 y Tabla 9) (OMIE, 2019). Esta información resultará de gran utilidad para nuestra investigación, a la hora de extraer conclusiones acerca de cómo afectan al precio diario eléctrico, los distintos factores.

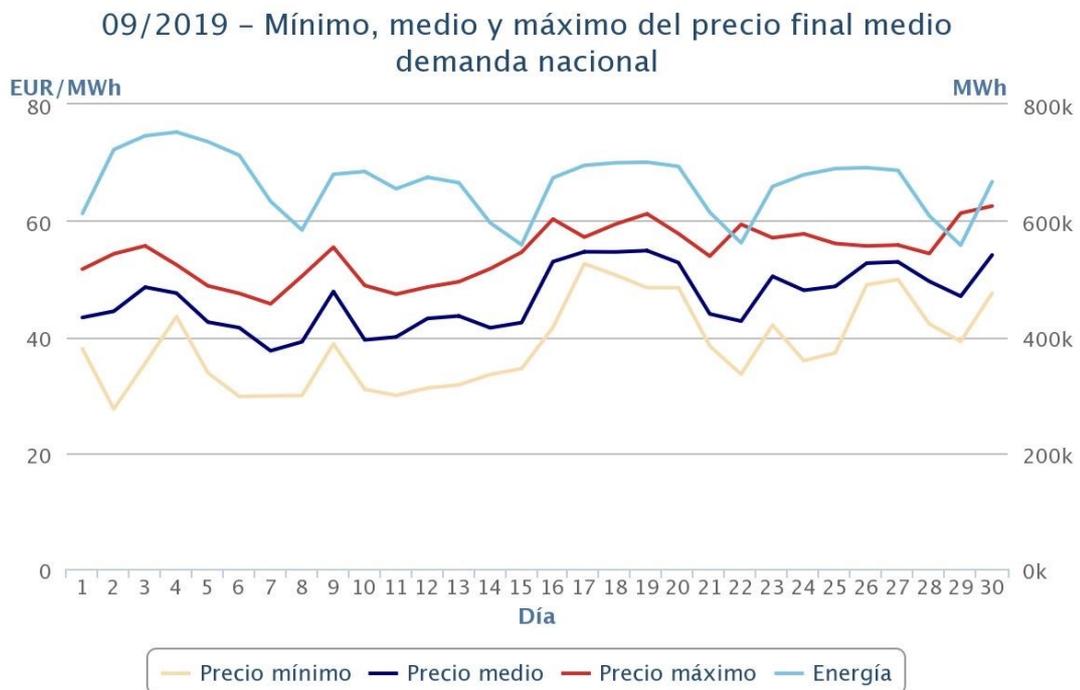


Figura 8. Precio mínimo, medio y máximo. Septiembre 2019. Fuente OMIE.

Serie	Precio mínimo (€/MWh)	Precio medio (€/MWh)	Precio máximo (€/MWh)	Energía de adquisición (MWh)
1	37,91	43,3	51,63	612.288
2	27,53	44,37	54,27	722.304
3	35,41	48,52	55,64	746.124
4	43,46	47,49	52,37	752.431
5	33,75	42,5	48,75	735.872
6	29,68	41,54	47,45	712.517
7	29,79	37,56	45,65	632.989
8	29,85	39,11	50,43	583.784
9	38,76	47,77	55,41	679.748
10	30,92	39,44	48,82	684.463
11	29,88	39,94	47,31	654.749
12	31,14	43,13	48,55	674.628
13	31,69	43,56	49,45	665.261
14	33,48	41,52	51,7	596.123
15	34,48	42,42	54,53	558.290
16	41,57	52,92	60,25	673.652
17	52,56	54,62	57,14	695.104
18	50,6	54,59	59,39	699.535
19	48,44	54,82	61,16	700.520
20	48,44	52,75	57,75	693.359
21	38,37	43,91	53,86	614.161
22	33,53	42,67	59,34	561.540
23	41,99	50,39	57,03	658.738
24	35,87	47,98	57,71	679.071
25	37,2	48,65	56,04	689.527
26	48,94	52,66	55,62	691.128
27	49,83	52,88	55,78	686.587
28	42,18	49,52	54,32	608.120
29	39,18	46,96	61,28	557.546
30	47,48	54,06	62,5	666.890

Tabla 9. Precio mínimo, medio y máximo. Septiembre 2019. Fuente OMIE.

A pesar del mayor coste eléctrico de la industria española, las fábricas españolas son más eficientes que las europeas en cuanto al consumo eléctrico por tonelada de cemento producida. En Europa se consumen de media 126 kWh por tonelada de cemento producida (datos medio de 2016, 2017 y 2018) (GCCA Association, 2020), mientras que en España, según datos aportados por OFICEMEN, se consumen 119,9 kWh por tonelada de cemento producida.

3.3. Factores que influyen en el sobreprecio de la electricidad en España.

Existen determinados factores que podrían explicar el sobreprecio de la electricidad en España:

1.- El incremento del precio de los derechos de emisión de CO₂ de las centrales de generación durante 2018, que ha estado en el entorno de los 14 Euros por tonelada de CO₂. Esto ha provocado que las centrales de carbón aumenten su coste en 12 Euros /MWh y las centrales de ciclo combinado en 5 Euros /MWh durante ese ejercicio.

2.- El incremento del precio del gas, debido en gran medida a que la mayoría de los contratos de suministro están referenciados al precio del petróleo; este último ha estado creciendo entre enero y octubre de 2018. Por otro lado, los contratos de suministro de gas también están referenciados al precio Spot del gas en los mercados internacionales.

3.- El aumento de la demanda comentado anteriormente.

4.- Las condiciones climatológicas extremas (ola de calor) presentes en los meses de julio y agosto. Esto provoca que la demanda de electricidad en esos meses sea superior a la del resto.

5.- El Mix energético / dependencia energética. La energía eléctrica proviene de distintas fuentes: renovables, combustibles fósiles, energía nuclear, etc. Es de esperar, por lo tanto, que el precio del kWh difiera según el origen de la energía.

Hasta 2017 las energías renovables, debido a su falta de desarrollo, fueron más caras que las energías no renovables. Aunque por las energías renovables no hay que pagar ningún precio por el consumo de recursos, puesto que son naturales y dependen mayoritariamente de factores climatológicos, el coste viene condicionado principalmente por la amortización de las instalaciones a lo largo de su vida útil (inversión inicial de capital, costes de mantenimiento y costes operacionales), lo cual supone un coste importante. En el caso de las energías no renovables hay que sumar, además, el precio del combustible necesario para generar la electricidad. Sin embargo, pese a tener este elemento adicional (combustible), el coste total podría llegar a ser inferior en algunos casos, ya que las infraestructuras no presentan un coste de amortización tan elevado como en el caso de las renovables. En la figura 9 puede verse el mix energético de producción (cobertura de la demanda eléctrica) de energía en España en 2020.

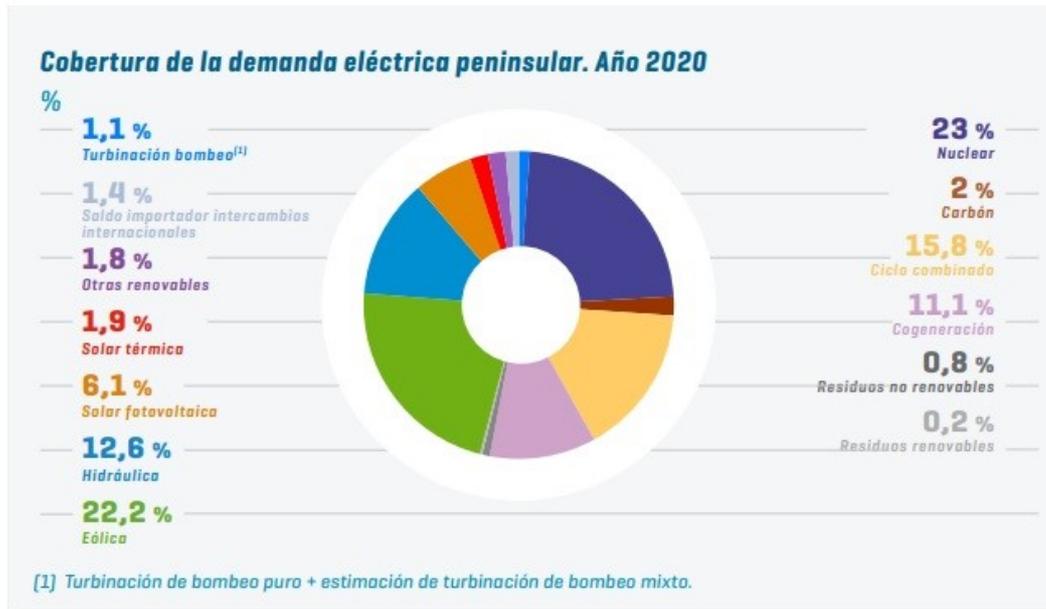


Figura 9: Mix energético de cobertura de la demanda eléctrica peninsular en 2020. Fuente: REE.

Pero no toda la energía consumida por un país se genera con recursos propios. En la figura 10 podemos ver la evolución de la dependencia energética de España en comparación con la media europea, observándose un diferencial considerable. Entre 2011 y 2018, España importó un promedio del 75 % de los recursos energéticos no renovables que consumió, mientras que la Unión Europea importó alrededor del 53 %. Es importante mencionar que las importaciones de recursos suponen un mayor coste que el consumo de recursos propios. Por lo tanto, este hecho justifica también el incremento del precio de la energía en España.

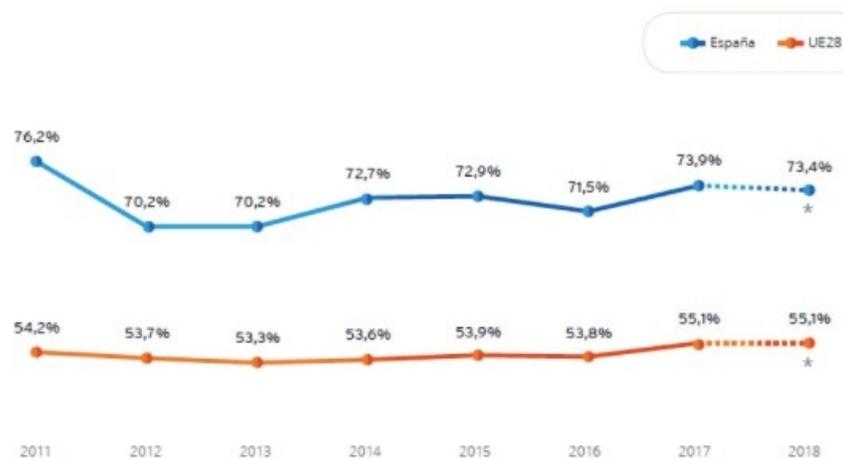


Figura 10: Evolución dependencia energética española vs EU. Fuente: APPA.

La dependencia energética se puede atribuir a la disponibilidad de recursos naturales, y más concretamente, a los combustibles fósiles. Países como Inglaterra, Noruega o Rusia disponen de grandes reservas de petróleo, lo cual les permite prescindir de importaciones energéticas, e incluso beneficiarse económicamente de las exportaciones. Pese a que España goza de una climatología perfecta para aprovechar la energía del sol, la falta de desarrollo y la escasez de infraestructuras limitan la producción intensiva de energía solar, a pesar del fuerte despliegue de esta tecnología durante los últimos años, por lo que se requiere emplear otros medios de producción alternativos.

6.- Mercado de futuros eléctricos.

La evolución del precio del mercado eléctrico a futuro se representa en las figuras 11 y 12. El precio del mercado a futuro había pasado de mantenerse estable en 2016 a subir considerablemente a lo largo de 2017. Como se puede observar, no solo ha mantenido la tendencia alcista, sino que también se ha incrementado la ratio de aumento. Si observamos las variaciones anuales entre 2017 y 2018, el precio del mercado de futuro aumentó de enero a diciembre de 2017 en un 20,5%, mientras que, en el mismo periodo de 2018, aumentó un 26%. El precio del mercado de futuros (FWD), en enero de 2018 fue de 49,15 €/MWh y en diciembre de 2018 de 61,89 €/MWh. Las causas que justifican este incremento son básicamente las mismas que provocaron el incremento en el mercado SPOT. Estos datos muestran en 2018 un incremento de precios incluso mayor que en 2016 y 2017 (Figura 11).

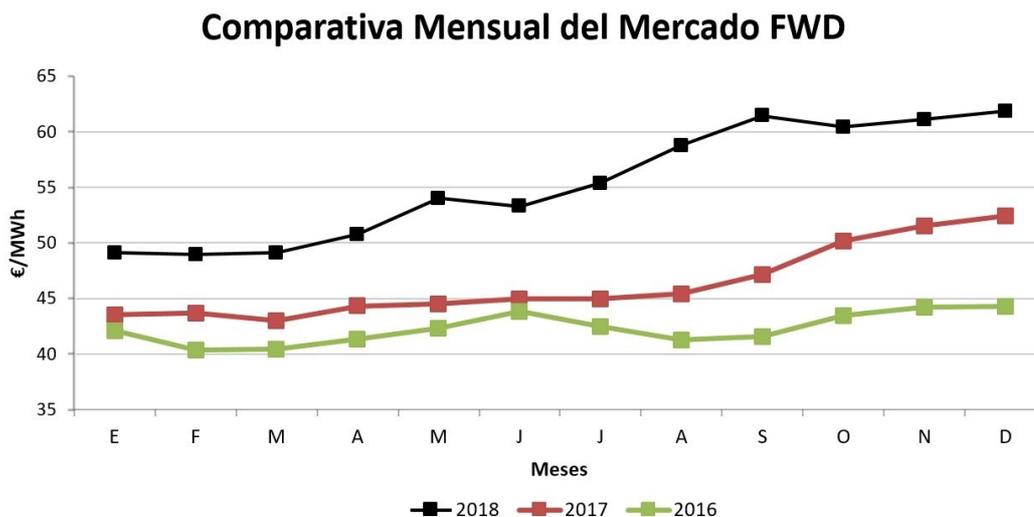


Figura 11: Comparativa mensual del Mercado FWD. Fuente: Indicadores de energía –IpsomManager – www.ipsom.com.

En la figura 12 se muestra que existe cierta relación entre los precios SPOT y FWD a lo largo de los años (IpsomManager, 2018).

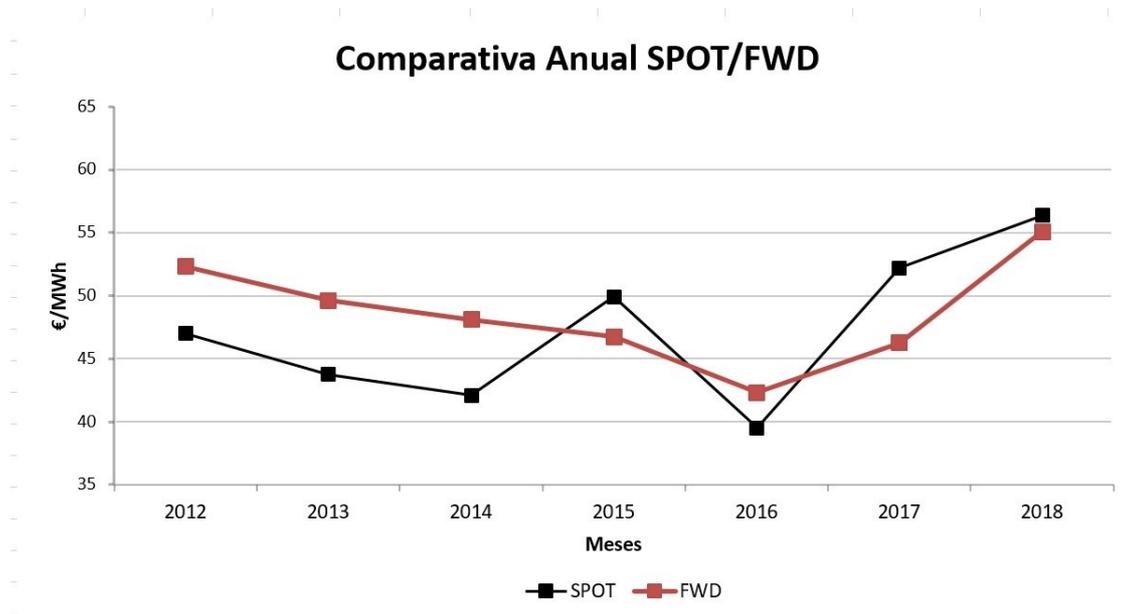


Figura 12: Comparativa anual mercado SPOT/FWD entre 2012 y 2018. Fuente: Indicadores de energía – IpsomManager – www.ipsom.com.

Los seis factores señalados afectan de manera notable al precio de la energía eléctrica (Chicco *et al.*, 2016). Para nuestro objetivo de optimizar el consumo eléctrico de una fábrica de cemento, utilizando distintas herramientas de IA, resultará fundamental tener en cuenta todos y cada uno de los condicionantes expuestos en este apartado. Así, a lo largo de todo el capítulo 5 se tendrán en cuenta estos factores a la hora de analizar la optimización del coste eléctrico operando sobre el precio eléctrico del mercado.

Capítulo 4. OPTIMIZACIÓN DEL COSTE ELÉCTRICO OPERANDO SOBRE VARIABLES DE PROCESO.

4.1. Introducción

En los apartados 2.5 y 2.6 se detallaron las herramientas de IA más utilizadas hoy en día para dar solución a distintos problemas y se analizaron los algoritmos y técnicas de aprendizaje automático. Mediante el análisis sistemático de la literatura, el panel y las encuestas a expertos, se han valorado las herramientas y metodologías más idóneas, para dar solución al problema concreto que se ha planteado en nuestro proceso de investigación y se ha obtenido información que resultará relevante a la hora de aplicar nuestra metodología. Esta información será expuesta de manera más detallada en los apartados 4.2. y 4.3.

Como se ha detallado anteriormente, nuestro modelo abordará tres aspectos diferentes de cara a optimizar el coste eléctrico en plantas cementeras: (1) el consumo de los equipos de la planta interviniendo sobre distintas variables del proceso productivo (optimización eléctrica operacional); (2) la optimización de los costes eléctricos regulados y (3) el proceso de compra de la electricidad. Los dos primeros aspectos se refieren a variables de proceso y serán analizados en el presente capítulo. El tercer aspecto, será objeto del análisis en el capítulo 5.

Una parte importante de la información utilizada para evaluar el consumo eléctrico ha sido suministrada por la fábrica de cemento de Málaga (España), del grupo FYM HeidelbergCement Group. El caso analizado es completamente análogo al de otras plantas cementeras que tengan un proceso de vía seca, por lo que los resultados obtenidos se podrán aplicar a cualquier planta de fabricación de cemento del mundo de este tipo.

4.2. Revisión de literatura

La revisión sistemática de la literatura nos permitió establecer seis temáticas diferentes sobre las que tratan los artículos seleccionados (Tabla 2). A continuación, se detallan cada una de ellas y se explica la contribución de cada artículo seleccionado a los distintos subobjetivos marcados en esta tesis doctoral. Como se puede comprobar, en la

mayor parte de los casos se obtiene una información de gran valía para avanzar en los subobjetivos detallados en el apartado 1.4.

Las temáticas abordadas fueron:

a.- Minimización del coste eléctrico mediante el uso de IA. Un artículo (Khotanzad, 2018) trató este tema y las conclusiones fundamentales fueron las siguientes:

- Contar con previsiones meteorológicas precisas resulta fundamental para predecir los precios futuros.
- La IA, con el uso de redes neuronales artificiales (ANN) y machine learning, puede mejorar las previsiones de precios eléctricos
- La volatilidad del precio de la energía hace que resulte complicado predecirlo en el futuro.
- Los modelos de ANN multicapa de perceptrón resultan de gran utilidad para predecir los precios diarios de la electricidad. Para ello resulta fundamental elegir adecuadamente los factores que tendrán mayor influencia.

b.- Predicción del consumo eléctrico de industrias. Sólo se encontró un artículo, en el que se aplican algoritmos genéticos para reducir los errores del sistema predictivo de IA (Azadeh *et al.*, 2015). Estos algoritmos utilizan métodos basados en el proceso genético de los organismos vivos. Se utilizan mayoritariamente para resolver problemas de búsqueda del óptimo.

c.- Ahorro energético en cementeras, incluyendo soluciones integradas y de gestión del horno. Un total de cuatro artículos trataron esta temática. El primero de los artículos (Castañón *et al.*, 2014) abordó el proceso para optimizar el consumo energético (térmico), de la fábrica de cemento de La Robla (Tudela Veguín), haciendo uso de herramientas estadísticas y no de IA. La planificación inicial y algunos aspectos metodológicos iniciales de este caso servirán de referencia para nuestro estudio.

Por su parte, Swanepoel *et al.* (2013) abordan un modelo de simulación llevado a cabo en 4 plantas que hizo posibles ahorros energéticos (eléctricos y térmicos) del 7,1 %. Para alcanzar estos ahorros se puso en marcha una metodología de gestión, que tuvo en cuenta el molino de crudo, horno, molino de carbón, trituradoras, molinos de cemento y componentes auxiliares. A partir de ahí se ideó una metodología para desplazar la carga entre los distintos días de la semana y estaciones del año, buscando siempre los momentos más

económicos desde el punto de vista energético. El análisis de esta metodología, aunque se refiriera también al coste térmico, resultará de interés para la presente investigación a la hora de adaptar el consumo eléctrico a los momentos más económicos (Hurtado *et al.*, 2014).

Swanepoel (2013), abordó el problema del mercado de cemento en Sudáfrica, donde ha tenido lugar un importante incremento de los costes de electricidad, lo cual ha provocado una importante presión sobre los productores internacionales. Para reducir la factura eléctrica se ha implementado un *Sistema de Gestión de la Energía (Energy Management System -EMS)*. Este sistema, además de controlar las fases de mayor consumo, traslada la demanda eléctrica a los momentos diarios más económicos.

Finalmente, Shaohog *et al.* (2012), se centran en el control y gestión de la energía térmica. Algunos de los factores que se detallan en esta publicación, si bien se refieren expresamente al consumo térmico, resultan de interés para la investigación que nos ocupa.

d.- La IA en la industria fue abordada por Andrew (2017), exponiendo como la IA está cambiando la industria en general. El artículo presentó al aprendizaje automático, herramienta fundamental que se utilizará en nuestra investigación, como *el arte y la ciencia de los algoritmos que dan sentido a los datos*.

e.- Predicción del precio eléctrico utilizando IA. El artículo de Wellesley (2001) mostró el funcionamiento de un software específico de la empresa Enva Power llamado A4I. Este software utiliza ciertas capacidades de autoaprendizaje, para convertir datos en información altamente rentable para la gestión eléctrica.

Hurtado *et al.* (2014), presentaron una metodología para estimar los precios diarios a los que se oferta la energía que producen los principales recursos hídricos y térmicos de Colombia. Para ello se emplearon dos técnicas de IA: la lógica difusa y las Redes Neuronales. La lógica difusa es una técnica que utiliza el lenguaje y la inteligencia humana a través de las matemáticas, para generar reglas de comportamiento en el sistema. Las redes neuronales utilizan modelos de caja negra y funcionan tal y como se explicó en el apartado 2.6. Una de las conclusiones de mayor interés de este artículo, es que es fundamental tener en cuenta la influencia del portafolio de generación eléctrica para predecir los precios.

Zhang y Cheng (2008) y Georgilakis (2007), explicaron cómo los modelos de ANN multicapa de perceptrón resultan de gran utilidad para predecir los precios diarios de la

electricidad. Para ello resulta fundamental elegir adecuadamente los factores que tendrán mayor influencia. Para reducir los errores del sistema mediante el aprendizaje se utiliza el algoritmo de propagación de error.

Otros artículos, Sreekumar *et al.* (2020); Tranfield *et al.* (2003) y Théate *et al.* (2020), analizaron cómo los modelos de ANN multicapa de perceptrón, el algoritmo de entrenamiento Backpropagation y el de optimización Descenso del Gradiente, resultan de gran utilidad para predecir los precios futuros diarios de la electricidad.

f- Inteligencia Artificial en general. Andrew y Zhang (2017), dos de los mejores expertos en el campo de la IA, explican las grandes oportunidades de la misma en diversos sectores, abordando también el campo industrial objeto de nuestra investigación.

Por otro lado, se han analizado tres tesis doctorales (Gilvonio y Inche, 2005; Mora y Minchala, 2015 y Solano, 1994), en las que se abordan aspectos concretos de esta temática. En una de ellas, Gilvonio y Inche (2005), se estudia el ahorro térmico en el horno de clínker y el ahorro eléctrico en la molienda de cemento, introduciendo modificaciones que requieren inversiones de mayor calado. En esta tesis se analizan las variables que permitirán lograr ahorros de energía en la fabricación de cemento, a fin de proponer una estrategia para lograr la excelencia operativa. El diagnóstico inicial de esta tesis resulta de utilidad para alcanzar el subobjetivo cinco de nuestra investigación (apartado 1.4.).

Tras el análisis detallado de los artículos seleccionados, se obtuvieron las siguientes conclusiones:

a) Seis de los catorce artículos, se centraban en el análisis de diferentes cuestiones que tienen que ver con la optimización de la compra de electricidad en los mercados y que se analizan en el capítulo 5. Las conclusiones más importantes que ese extrajeron fueron:

+ Los modelos de ANN multicapa de perceptrón, el algoritmo de entrenamiento Backpropagation y el de optimización Descenso del Gradiente, resultan de gran utilidad para predecir los precios futuros diarios de la electricidad (Hurtado *et al.*, 2014; Khotanzad, 2018; Georgilakis, 2007; Wellesley, 2001; Zang y Chen, 2008).

+ La meteorología (aspectos como la temperatura, el viento y la lluvia), juega un papel fundamental para predecir precios futuros (Khotanzad, 2018; Zang y Chen, 2008).

+ El porfolio de generación eléctrica supone otra importante variable que afecta al precio diario de la electricidad (Hurtado *et al.*, 2014).

+ Además de las ANN, pueden utilizarse otras herramientas, como algoritmos genéticos (Azadeh *et al.*, 2015) y lógica difusa (Hurtado *et al.*, 2014) para predecir los precios futuros diarios de la electricidad.

b) Se ha podido constatar que dos artículos, aunque hacían alguna referencia muy general al sector cementero, a la IA y /o a la industria, no abordaban de manera profunda ninguno de los tres aspectos analizados en nuestra investigación (Andrew, 2017; Andrew y Tong, 2017).

c) De los trabajos analizados, tan solo cuatro hacían referencia al sector cementero y a los aspectos analizados en este paper (Castañón *et al.*, 2014; Shaohog *et al.*, 2012; Swanepoel, 2013 y Swanepoel *et al.*, 2013).

+ El primero de los artículos (Castañón *et al.*, 2014) aborda el proceso para optimizar el consumo energético (térmico), de la fábrica de cemento de La Robla (Tudela Veguín), haciendo uso de herramientas estadísticas y no de IA. La planificación inicial y algunos aspectos metodológicos iniciales de este caso han servido de referencia para nuestro estudio.

+ En el segundo de los artículos (Swanepoel *et al.*, 2013), se aborda un modelo de simulación llevado a cabo en 4 plantas cementeras que hizo posibles ahorros energéticos (eléctricos y térmicos) del 7,1 %. Para alcanzar estos ahorros se puso en marcha una metodología de gestión, que tuvo en cuenta el molino de crudo, horno, molino de carbón, trituradoras, molinos de cemento y componentes auxiliares. A partir de ahí se ideó un modelo para desplazar la carga entre los distintos días de la semana y estaciones del año, buscando siempre los momentos más económicos desde el punto de vista energético. El análisis de esta metodología, aunque se refiriera también al coste térmico, ha resultado de interés para la presente investigación a la hora de adaptar el consumo eléctrico a los momentos más económicos.

+ El tercer artículo (Swanepoel, 2013), aborda el problema del mercado de cemento en Sudáfrica, donde ha tenido lugar un importante incremento de los costes de electricidad, lo cual ha provocado una importante presión sobre los productores internacionales. Para reducir la factura eléctrica se ha implementado un Sistema de Gestión de la Energía (Energy

Management System -EMS). Este sistema, además de controlar las fases de mayor consumo, traslada la demanda eléctrica a los momentos diarios más económicos.

+ Finalmente el cuarto artículo (Shaohog *et al.*, 2012), se centra en el control y gestión de la energía térmica. Algunos de los factores que se detallan en esta publicación, aunque no se refieran al consumo eléctrico, resultan de interés para la investigación que nos ocupa.

Por otro lado, estos artículos solo en algunos casos se centraban en el sector cementero (Castañón *et al.*, 2014; Shaohog *et al.*, 2012; Swanepoel, 2013; Swanepoel *et al.*, 2013). En otros se referían a la industria en general (Andrew, 2017 y Azadeh *et al.*, 2015), o incluso se trataban de artículos intersectoriales (Andrew y Tong, 2017; Hurtado *et al.*, 2014; Khotanzad, 2018; Georgilakis, 2007; Wellesley, 2001; Zhang y Cheng, 2008).

Además de estos artículos se ha analizado una tesis doctoral (Gilvonio y Inche., 2005), en la que se estudia el ahorro térmico en el horno de clínker y el ahorro eléctrico en la molienda de cemento, introduciendo modificaciones en determinadas variables. También se han analizado otras dos tesis doctorales (Mora y Minchala, 2015 y Solano, 1994), en las que se abordan otros aspectos concretos de esta temática.

4.3. Consultas a expertos. Análisis del precio eléctrico de la industria cementera española.

Tras la revisión sistemática de la literatura y para completar la información necesaria a la hora de tomar decisiones acerca del diseño de la metodología a emplear, se llevó a cabo un estudio basado en encuestas y panel de expertos, en el cual participaron un total de 42 personas.

Las encuestas, utilizadas fundamentalmente para obtener datos cuantitativos, fueron formuladas a un total de 11 personas. En el panel de expertos participaron 31 personas que aportaron datos cualitativos sobre comportamiento de los precios de la electricidad, costes operativos de los distintos equipos de producción, variables de proceso que afectan al consumo eléctrico, flexibilidad en las condiciones de marcha/parada de cada uno de ellos y rutinas de operación. Como ya se indicó anteriormente, de entre los 31 expertos que

colaboraron con los datos cualitativos, a 5 de ellos, considerados expertos en materia de IA, se les solicitó que completaran un cuestionario para valorar las posibles herramientas a utilizar.

La participación de los expertos ha supuesto un gran valor añadido para la investigación, dada la gran experiencia y conocimiento del sector que presentaban los mismos. Para obtener los datos cualitativos del panel de expertos se utilizaron dos cuestionarios y una entrevista telefónica. En concreto:

- 1) Cuestionario para analizar los costes regulados y la mayor o menor influencia de las distintas variables de proceso. Las variables seleccionadas por los expertos fueron las que se utilizaron en la arquitectura de ANN que se esquematiza en la figura 9.
- 2) Cuestionario para valorar las herramientas más adecuadas para solucionar el problema planteado en este artículo. Como hemos indicado, un total de 5 eran expertos en materia de IA. El uso de ANN con el algoritmo Backpropagation y los algoritmos genéticos resultaron las técnicas seleccionadas por el 80% de los expertos consultados, lo cual coincide con las herramientas utilizadas de manera mayoritaria en los artículos de la literatura previa analizados (Hurtado *et al.*, 2014; Khotanzad, 2018; Georgilakis, 2007; Wellesley, 2001; Zang y Chen, 2008).
- 3) Finalmente se mantuvieron entrevistas telefónicas individuales, no en grupo, para obtener información sin condicionar las respuestas, con todos y cada uno de los expertos consultados, para profundizar en las respuestas proporcionadas en los cuestionarios.

Con toda la información recabada a través de la revisión sistemática de la literatura, encuestas y panel de expertos del sector cementero, se determinó tanto el modelo de trabajo como las herramientas de AI más idóneas para la optimización del consumo eléctrico, desde un punto de vista operacional. Esto se aborda en este capítulo 4.

Las encuestas a expertos han permitido, por otro lado, desarrollar una metodología para el cálculo del precio eléctrico de la industria cementera española, en la que se contemplan los costes eléctricos regulados del sector (información recogida a través de encuestas y cuestionarios sectoriales a responsables de las empresas cementeras que operan en España) y el precio de la electricidad en España (OMIE).

Para desarrollar este cálculo del precio eléctrico, previamente se ha obtenido la información necesaria para desarrollar un estudio del coste eléctrico regulado medio anual entre 2009 y 2018, desagregado por tarifas según los distintos tipos de tensión y también agregado (Tabla 16). En este apartado se han analizado 6 parámetros-componentes distintos que conforman los costes/ingresos de la electricidad en la industria: Ingresos por el servicio general de interrumpibilidad, peajes eléctricos, impuesto eléctrico, pagos por capacidad, costes del servicio general de interrumpibilidad y fideicomiso de Eficiencia Eléctrica (FEE).

Este estudio resulta de gran utilidad, tanto para esta investigación como para otras futuras, a la hora de conocer pormenorizadamente los componentes que integran los costes eléctricos regulados del sector.

Se trata de un estudio que abarca la totalidad de las compañías y fábricas de cemento que operaron en España durante 2018. La opinión de los expertos sectoriales consultados, de la patronal cementera española -OFICEMEN-, y el análisis sistemático de la literatura llevado a cabo en primer lugar, han confirmado que se trata de un trabajo totalmente novedoso e innovador y que no se había llevado a cabo con anterioridad.

Para este estudio hemos elaborado una tabla (tabla 10), con la siguiente información, referida a los años 2009–2018.

- a) Potencia media instalada por el sector en España (MW).
- b) Energía consumida por el sector en España (MWh).
- c) Peajes por potencia (€/MW).
- d) Peajes por energía (€/MWh).
- e) Impuesto Eléctrico (€/MWh).
- f) Pagos por capacidad (€/MWh).
- g) Pagos por Servicio general de Interrumpibilidad (€/MWh).
- h) Pago Fondo de Eficiencia Energética (€/MWh).
- i) Ingresos por Servicio general de Interrumpibilidad (€/MWh).

Los datos han sido aportados por la patronal cementera española OFICEMEN y sus empresas asociadas. Considerando los seis capítulos -desde c) hasta h)-sin tener en cuenta la potencia, la energía y los ingresos por servicios generales de interrumpibilidad (ISGI), se obtienen para cada año los costes eléctricos regulados del sistema completamente desglosados (Tabla 10).

AÑO / TARIFA	POTENCIA MEDIA (MW)	ENERGÍA (MWh)	PEAJES POR POTENCIA (€/MWh)	PEAJES POR ENERGÍA (€/MWh)	TOTAL PEAJES (€/MWh)	IMPUESTO ELÉCTRICO (€/MWh)	PAGOS POR CAPACIDAD (€/MWh)	SGDI (Interrumpibilidad) (€/MWh)	FONDO EFICIENCIA ENERGÉTICA (€/MWh)	TOTAL COSTES BRUTOS DEL SISTEMA (€/MWh) (Ctes. Elec. Regulados)	INGRESOS SGDI (€/MWh)	TOTAL COSTES NETOS DEL SISTEMA (€/MWh)
2009	636	3.024.515	5,31	4,59	9,9	3,12	1,24	0	0	14,26	-18,3	-4,04
2010	635	2.952.799	7,45	6,15	13,6	3,18	1,23	0	0	18,01	-15,81	2,20
2011	632	2.569.952	8,59	6,14	14,73	3,64	1,98	0	0	20,35	-18,29	2,06
2012	598	2.215.929	9,69	7,06	16,75	3,82	2,05	0	0	22,62	-17,23	5,39
2013	528	1.945.645	10,92	5,3	16,22	3,65	1,95	0	0	21,82	-14,76	7,06
2014	521	2.152.870	12,23	3,48	15,71	0,54	1,87	0	0	18,12	-11,32	6,80
2015	494	2.199.082	11,17	3,29	14,46	0,52	1,61	1,86	0,31	18,76	-8,31	10,45
2016	485	2.246.007	10,61	3,31	13,92	0,49	0,94	2,07	0,25	17,67	-9,17	8,50
2017	474	2.284.180	10,25	3,21	13,46	0,53	0,9	2,17	0,28	17,34	-9,25	8,09
2018	487	2.338.374	10,35	3,23	13,58	0,61	0,88	1,26	0,25	16,58	-5,8	10,78

Tabla 10. Costes eléctricos regulados sector cementero español. Elaboración propia a partir de datos facilitados por empresas cementeras y OFICEMEN.

Si a los costes eléctricos regulados se les suma el precio de la electricidad en España para cada año (Figura 13), se obtiene el coste total eléctrico de la industria cementera que en 2018 se situó en 73,87 €/MWh (Figura 14).

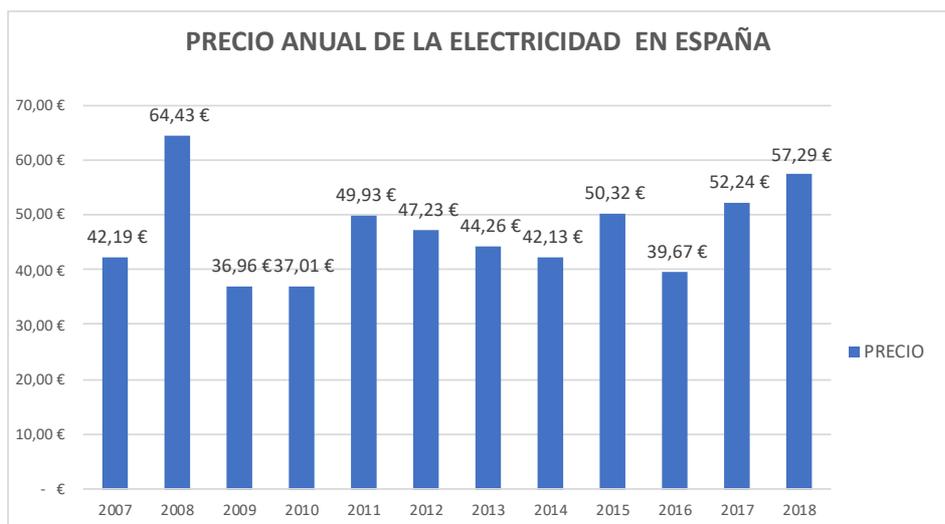


Figura 13. Precio de la electricidad en España (€/MWh). Fuente: Elaboración propia a partir de datos de OMIE y OMIP (OMIE, 2019; OMIP, 2021).

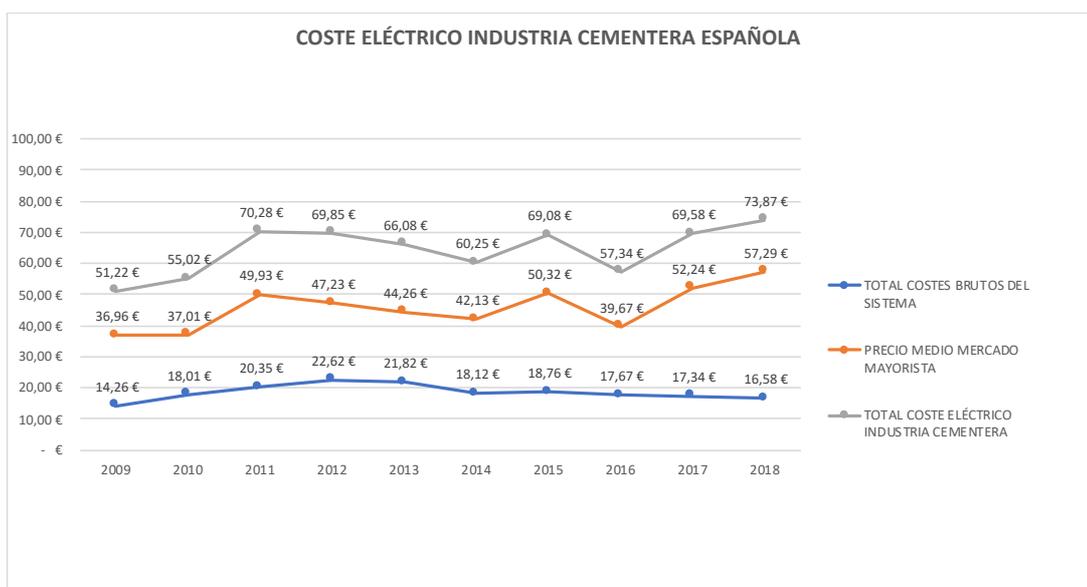


Figura 14. Coste eléctrico total industria cementera española (€/MWh). Fuente: Elaboración propia a partir de datos facilitados por las empresas cementeras, OFICEMEN y OMIE (OMIE, 2019).

Los datos obtenidos mediante las encuestas permiten conocer la parte regulada; por tanto, resultarán de gran utilidad en fases futuras de esta investigación en las que se implemente este modelo en una fábrica mediante un proyecto piloto.

Para verificar la validez de los datos cuantitativos obtenidos del sector y que se reflejan en la tabla 10, se consideró fundamental llevar a cabo un chequeo de contraste entre

el *coste eléctrico bruto de la industria cementera*, obtenido a partir de la suma de los costes regulados facilitados en las encuestas de la industria cementera (tabla 10), más el coste eléctrico que aparece en las estadísticas que ofrece el Operador del Mercado Ibérico Español, OMIE) (Figura 13) y las estadísticas facilitadas por Eurostat referidas a 2018 y que se reflejan en la Tabla 8 (Estadísticas de precios eléctricos de Eurostat. 2019). De esta manera en nuestro chequeo de contraste, para 2018, compararemos lo siguiente:

a) El precio eléctrico obtenido de la suma de costes brutos regulados del sistema (16,58 €/MWh) y precio medio del mercado mayorista ofrecido por OMIE (57,29 €/MWh), asciende a 73,87 €/MWh (Figura 14).

b) Estadísticas de Eurostat. Para el sector cementero, centrándonos en el formato estadístico que ofrece Eurostat, debemos considerar los consumos energéticos situados entre dos rangos o bandas: Band IE: 20.000-70.000 MWh y Band IF: 70.000-150.000 MWh. Pero se ha de tener en cuenta que la mayor parte de las plantas cementeras estarían en el segundo rango. Por lo tanto, se debe calcular una media ponderada, que confiera mayor peso al segundo rango (entre el 90% y el 95%), para obtener un coste eléctrico aproximado para el sector cementero español, lo más realista posible. Asignando un peso del 10% al rango de 20.000 – 70.000 MWh y del 90 % al rango de 70.000-150.000 MWh, el precio obtenido asciende a 74,9 €/MWh (Eurostat. Estadísticas de precios eléctricos de Eurostat. 2019) (Tabla 8).

Como puede comprobarse, en el apartado b) se obtiene un dato muy similar al del apartado 1. Si se hubiera tomado un valor algo superior al 90%, habríamos obtenido un precio incluso inferior a 74,9 €/MWh y por lo tanto más cercano a los 73,87 €/MWh obtenidos en el apartado a) (Figura 14).

Los resultados obtenidos (73,87 €/MWh. vs 74,9 €/MWh.), aunque deben ser muy similares, no tienen por qué coincidir con exactitud. Para el cometido de realizar un chequeo de contraste -comprobar la validez de los datos de costes regulados aportados por la industria cementera- es suficiente verificar que son muy similares. Resulta razonable que los costes regulados del sistema eléctrico cementero que hemos obtenido difieran sensiblemente de la medida ponderada de los costes brutos del conjunto de sectores electrointensivos.

Por otro lado, cabe destacar, que las encuestas realizadas a los expertos han servido para conseguir datos sobre el porcentaje de uso de la potencia eléctrica contratada en los distintos periodos de coste de la electricidad (información cuantitativa). Esta información resultará de gran utilidad a la hora de analizar y abordar en nuestra investigación los costes eléctricos regulados (apartado 4.5.).

En España, las tarifas eléctricas de alta tensión (con potencias contratadas superiores a 450 kW en alguno de los periodos, es decir, tarifas de acceso 6.X.), ofrecen 6 periodos horarios (P1, ..., P6). Cada uno de esos periodos tiene un coste eléctrico diferente, siendo el P6 el más barato y el P1 el más caro. Esta tarifa tiene diferentes precios de la energía según el periodo en el que se consuma, con lo que en la factura vendrá reflejada la energía consumida en cada uno de los periodos, con su precio por periodo correspondiente, siendo el P1 el periodo más caro y el P6 el más barato. Esta información resultará de utilidad a la hora de optimizar el consumo eléctrico identificando los periodos a los que habría que desplazar el grueso del consumo eléctrico para conseguir un coste más bajo.

En la figura 15 se pueden apreciar los porcentajes de utilización de la potencia eléctrica de cada uno de esos periodos sobre el total de la energía contratada por parte de las cementeras españolas entre los años 2009 y 2018.

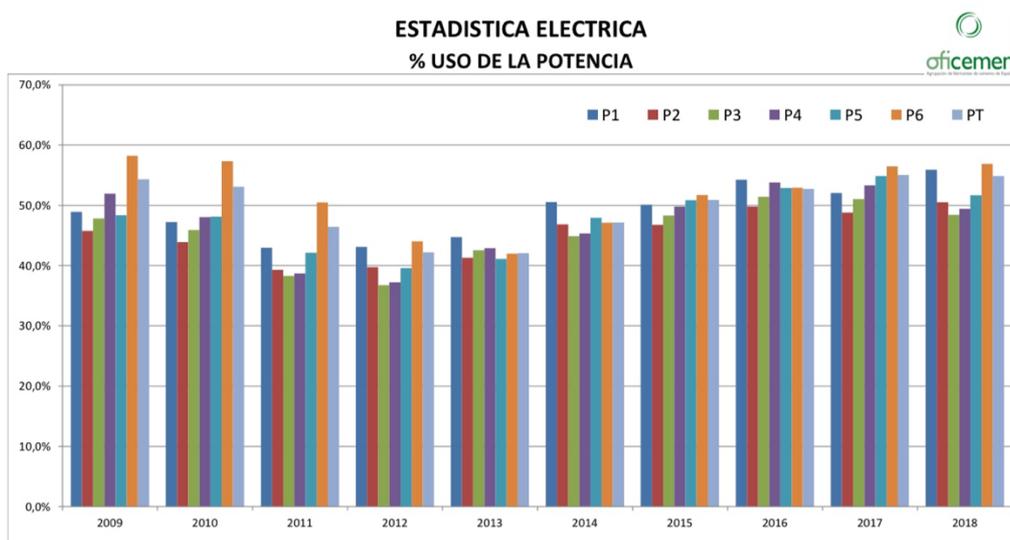


Figura 15. % de uso de la potencia contratada en España (2009-2018). Fuente OFICEMEN.

En la figura 16 disponemos de la misma información (% de la potencia utilizada respecto a la contratada por periodos), pero en esta ocasión desagregada según las tarifas de acceso en la que está cada una de las fábricas. La tarifa de acceso (6.1. A, 6.1.B, 6.2, 6.3 y 6.4) dependen del nivel de tensión de conexión a la red que tenga cada instalación. Han sido sustituidas con la nueva normativa por la nomenclatura 6.1TD, 6.1TDVE, 6.2 TD, 6.3TD y 6.4TD.

- Tarifa 6.1. A. Esta tarifa pertenece, igual que al resto de las que siguen, a las de alta tensión y tiene una tensión de 1 kV hasta 30 kV.
- Tarifa 6.1. B. Para empresas con una tensión de 30 kV hasta 36 kV.
- Tarifa 6.2. Está destinada a usuarios que precisen de una tensión de 36 kV hasta 72,5 kV.
- Tarifa 6.3. Para las industrias que necesitan tensiones entre 72,5 kV hasta 145 kV.
- Tarifa 6.4. Para niveles de tensión iguales o superiores a 145 kV.

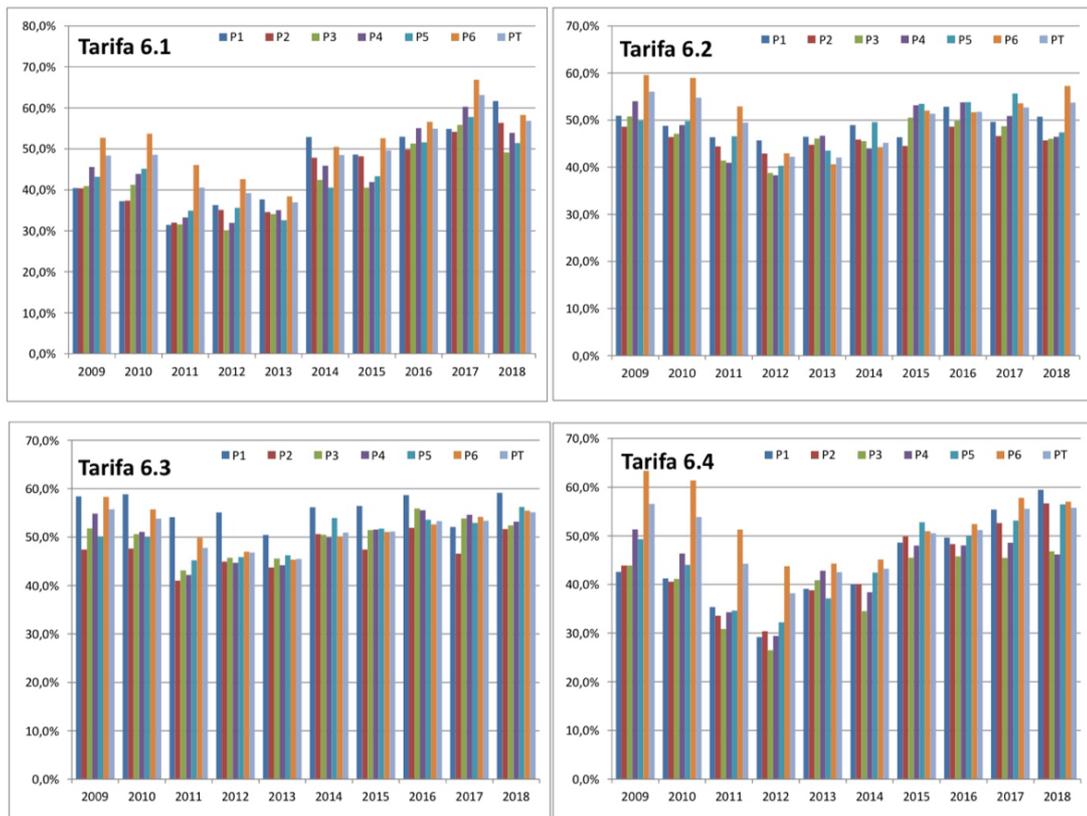


Figura 16. % de uso de la potencia contratada en España, según tarifas de tensión contratada (2009-2018). Fuente OFICEMEN.

Los expertos también han aportado datos eléctricos de modulación del consumo para 2018 (información cuantitativa). Se han tenido en cuenta como parámetros los 6 periodos distintos de consumo eléctrico que operan en España (P1, ...P6). Esta información resultará de utilidad para nuestra tesis doctoral, a la hora de desplazar el consumo eléctrico a los periodos más económicos. Como se indicó anteriormente, esta cuestión ha sido objeto de estudio en el capítulo 4.5.

La Figura 17, permitirá comparar por un lado el número de horas totales de cada uno de los periodos (P6: 5048 h., P5: 1008 h., P4: 770 h., P3: 462 h., P2: 656 h. y P1: 616 h.), con el porcentaje de consumo eléctrico (MWh) registrado por las cementeras españolas durante cada periodo (67,7%, 9,7%, 6,8%, 3,9%, 7% y 4,7%). El objetivo de las plantas cementeras, y también uno de los objetivos que se perseguirá en esta tesis doctoral a la hora de intentar optimizar el coste eléctrico en las fábricas -capítulo 4, apartado 4.5.- será conseguir que los MWh utilizados durante los periodos más económicos (P6, P5), estén por encima del número de horas disponible en esos periodos.

Centrémonos en un ejemplo concreto observando la figura 17. El calendario de periodos eléctricos horarios dispone de un total de 5.048 horas en el periodo P6. Esto supone un total del 57,62% de las 8.760 h. totales disponibles en un año. Las fábricas cementeras han sido capaces de consumir durante 2018 el 67,7 % de la electricidad de sus fábricas en este periodo -Figura 17-. Como se ha explicado anteriormente se trata de un aspecto claramente positivo. Las fábricas han sido capaces de desplazar parte de su consumo eléctrico a periodos en los que la electricidad tiene un coste menor, de manera que han conseguido mayor eficiencia en materia de coste eléctrico.

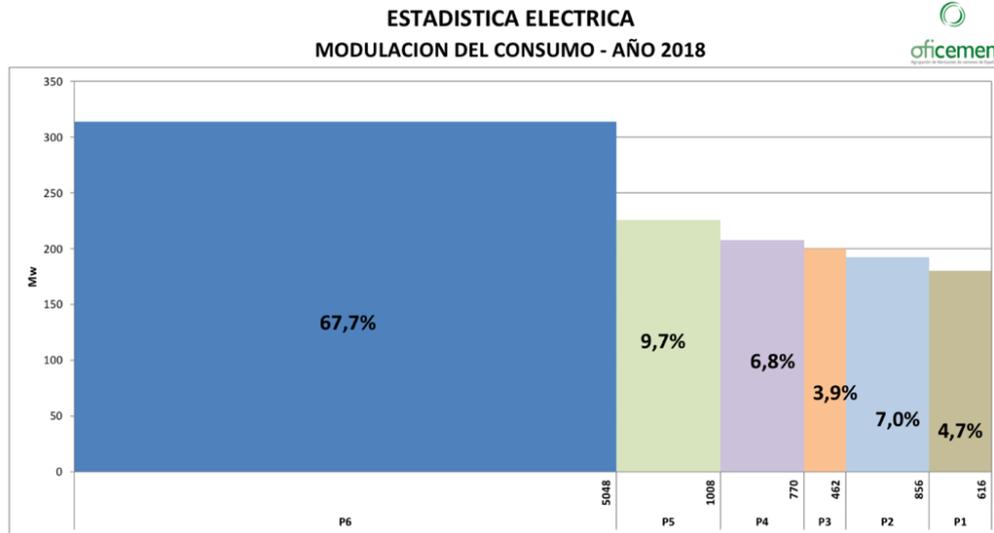


Figura 17. Modulación del consumo eléctrico de las fábricas españolas durante 2018. Fuente OFICEMEN.

En la Figura 18 podemos observar la misma modulación eléctrica de la industria cementera española durante 2018, pero desagregada según las potencias contratadas (6.1, 6.2, 6.3 y 6.4).

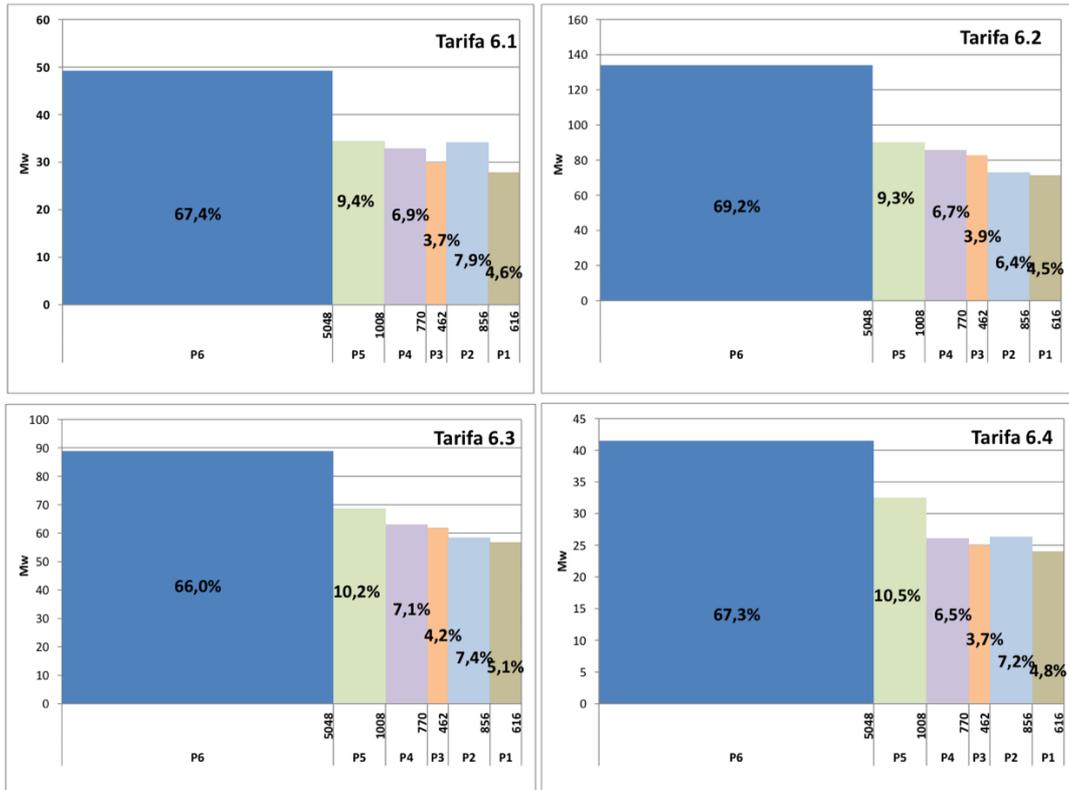


Figura 18 Modulación del consumo eléctrico de las fábricas españolas durante 2018, según tarifas de tensión contratada. Fuente OFICEMEN.

El panel de expertos también ha proporcionado información acerca de aquellos factores que más influyen en el consumo eléctrico en cada fase del proceso de fabricación de cemento. Esta información ha complementado de manera importante la información obtenida sobre el particular mediante el análisis bibliográfico, resultando de gran utilidad a la hora de abordar la metodología desarrollada en el apartado 4.4. De cara a que los expertos pudieran determinar aquellas variables sobre las que se puede incidir de manera más o menos sencilla, y sin incurrir en altos costes ni montantes de inversión, para conseguir reducciones en el consumo eléctrico, se ha dividido el proceso de fabricación de cemento en un total de 9 fases. Las variables determinadas para cada fase del proceso de fabricación de cemento, de acuerdo con la información aportada por los expertos, y que se utilizarán en los modelos de optimización del coste eléctrico han sido las siguientes:

Fase 1. Cantera y Cinta trituradora.

- Tamaño de salida de la trituradora primaria: $V(1)_{F1}$.
- Tamaño de salida de la trituradora secundaria $V(2)_{F1}$.

Fase 2. Pre-homogeneización y cinta pre-homogeneización-tolva.

Ninguna variable destacable.

Fase 3. Cinta tolva-molino y molino de crudo.

- Tamaño del crudo de entrada: $V(1)_{F3}$
- Velocidad de giro del molino: $V(2)_{F3}$.
- Nivel de llenado del molino $V(3)_{F3}$.
- Diámetro de las bolas $V(4)_{F3}$.

Fase 4. Ciclones, horno y enfriador.

- Aire falso de entrada a los ciclones: $V(1)_{F4}$.

- Granulometría del clínker: $V(2)_{F4}$.

Fase 5. Molino de carbón.

- Tamaño del carbón/granulometría: $V(1)_{F5}$.
- Velocidad de giro del molino de carbón: $V(2)_{F5}$.

Fase 6. Molino de cemento.

- Tamaño del clínker: $V(1)_{F6(M5, M6, M7)}$.
- Tamaño del yeso. $V(2)_{F6(M5, M6, M7)}$.
- Tamaño de otras adiciones. $V(3)_{F6(M5, M6, M7)}$.
- Velocidad de giro del molino: $V(4)_{F6(M5, M6, M7)}$.

Fase 7. Transporte y silos de cemento.

Ninguna variable destacable.

Fase 8. Ensacado.

Ninguna variable destacable.

Fase 9. Servicios auxiliares.

Ninguna variable destacable.

En la figura 19 se incluye un diagrama de flujos con las distintas fases del proceso de fabricación de cemento. Para cada fase se ha incluido el porcentaje de consumo eléctrico, la energía consumida, la potencia instalada y la capacidad máxima.

Esta información se corresponde con datos relativos a la fábrica de cemento de FYM HeidelberCement Group de Málaga (España).

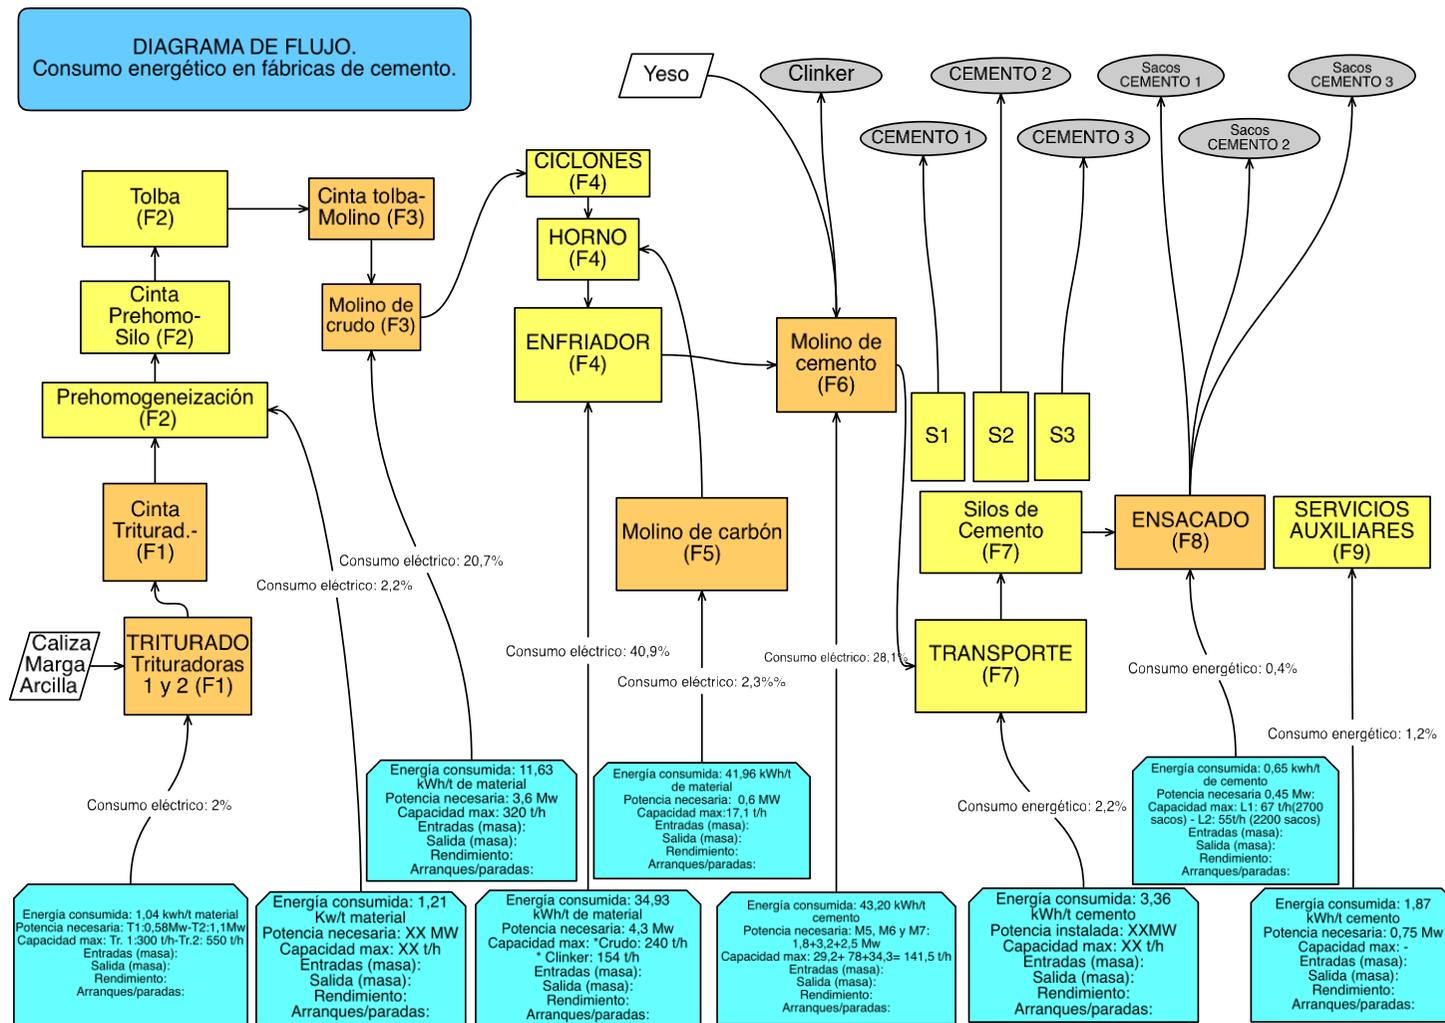


Figura 19. Diagrama de flujo. Consumo energético en fábricas de cemento. (Referido a t. de materiales). Fuente: Elaboración propia.

4.4. Metodología para la optimización eléctrica operacional.

En este caso, tal y como se explica en Parejo *et al.* (2021), trataremos de reducir el coste eléctrico incidiendo en el consumo de la fábrica de cemento; es decir, modificando ciertas variables del proceso productivo, pero sin incurrir ni en costes ni en inversiones importantes. En este apartado tendremos en cuenta tan solo variables que, al ser modificadas, no influyan de manera decisiva ni en el coste ni en los niveles de inversión total. Para ello se ha analizado con detalle el consumo energético en cada una de las fases del proceso y las variables de las que depende, de acuerdo con los resultados del análisis bibliográfico y del panel de expertos. De las 9 fases de las que consta el proceso de fabricación de cemento, analizadas en el apartado 4.3. y que aparecen en la figura 19, se seleccionaron las 5 fases críticas desde el punto de vista del consumo eléctrico: trituración, molienda de crudo, fabricación de clínker, molienda de carbón y molienda de cemento. Aunque no ha resultado ser así en el caso de la fábrica de Málaga, la fase de trituración, según los expertos, sí suele ser relevante en otros muchos casos, de ahí que hayamos decidido tenerla en cuenta como crítica.

Para cada una de las fases se han identificado aquellas variables que presentan mayor incidencia sobre el consumo eléctrico y sobre las que se podría influir de manera sencilla -sin incurrir en grandes costes ni inversiones- para optimizar el consumo eléctrico. Obtendríamos, así, 5 funciones de consumo -según aparece más adelante-, una para cada fase, para las que utilizaremos la siguiente nomenclatura:

- $CE_{(ti)}$: Consumo eléctrico de la trituradora i (kWh).
- $PE_{(ti)}$: Potencia de la trituradora i (kW).
- $CE_{(M)}$: Consumo eléctrico del molino de crudo (kWh).
- $PE_{(M)}$: Potencia del molino de crudo (kW).
- $CE_{(H)}$: Consumo eléctrico del horno (kWh).
- $PE_{(H)}$: Potencia-del horno (kW).
- $CE_{(MC)}$: Consumo eléctrico del molino de carbón (kWh).

- $PE_{(MC)}$: Potencia-del molino de carbón (kW).
- $CE_{(MCEM)}$: Consumo eléctrico del molino de cemento (kWh).
- $PE_{(MCEM)}$: Potencia del molino de cemento (kW).
- $CE(Fx)$: Consumo neto de energía eléctrica en la fase X (kWh).
- $V(n)_{FX}$. Variable “n” con repercusión en el consumo eléctrico en la fase X, siendo $n= 1, 2, \dots // X=1, 3, 4, 5$ y 6.
- ω_{nx} : Peso de la variable “n” en la fase X.
- u : El valor obtenido en cada una de las neuronas de la red, será un modelo de regresión lineal al que se le sumaría un sesgo conocido como “bias” (u).

Se expondrá a continuación la selección de variables con impacto en el consumo eléctrico que se ha llevado a cabo para cada una de las fases del proceso de fabricación de cemento.

1) Extracción de materias primas/triturado. (Fase 1: F1).

En la fábrica de Málaga, en la que nos basaremos para esta parte de la investigación, existen dos trituradoras, una primaria y otra secundaria. Las dos variables que pueden influir en el consumo eléctrico de esta fase y que se incluirán en el proceso de recogida de datos son:

- Tamaño del material de salida de la trituradora 1 (primaria): $V(1)_{F1(t1)}$.
- Tamaño del material de salida de la trituradora 2 (secundaria): $V(2)_{F1(t2)}$.

Para cada pareja de datos/variables de $V(1)_{F1(t1)}$ y de $V(2)_{F1(t2)}$, (a-b, c-d, etc.), obtendremos un resultado de consumo energético (X, Z, Y, ...). El objetivo será minimizar el mismo, es decir determinar aquella pareja de valores de $V(1)_{F1(t1)}$ y de $V(2)_{F1(t2)}$, que hagan mínimo el consumo energético en la F1.

$V(1)_{F1(t1)}$	$V(2)_{F1(t2)}$	$CE(F1)_{(t1)}$
a	B	X
c	D	Z
e	F	Y

$CE_{(t1)}$: Consumo eléctrico de la Trituradora 1.

$H_{(t1)}$: Horas de funcionamiento trituradora 1.

u_1 : sesgo/bias en la función de la trituradora 1.

$CE_{(t2)}$: Consumo eléctrico de la trituradora 2.

$H_{(t2)}$: Horas de funcionamiento trituradora 2.

u_2 : sesgo/bias en la función de la trituradora 2

Cada una de las dos variables - $V(1)$ y $V(2)$ -, afectará al consumo neto de energía de esta primera fase ($CE(F1)_{(t1, t2)}$), con un peso que se expresará con la letra ω .

La función que integraría las dos trituradoras sería:

$$CE(F1)_{(t1,t2)} = PE_{(t1)} F[V(1)_{F1(t1)} * \omega_{11} + u_1] * H_{(t1)} + PE_{(t2)} F[V(2)_{F1(t2)} * \omega_{21} + u_2] * H_{(t2)}$$

2) Molino de crudo. (Fase 3: F3).

Al tratarse de un molino de bolas, las cuatro variables que influyen principalmente en el consumo eléctrico de esta fase son:

- Tamaño del crudo de entrada. $V(1)_{F3}$.
- Velocidad de giro del molino: $V(2)_{F3}$.
- Nivel de llenado del molino: $V(3)_{F3}$.
- Diámetro de las bolas: $V(4)_{F3}$.

Para cada combinación de datos/variables de $V(1)_{F3}$, $V(2)_{F3}$, $V(3)_{F3}$, y de $V(4)_{F3}$ (a-b-c-d, e-f-g-h, i-j-k-l, etc.), obtendremos un resultado de consumo energético (X, Z, Y, ...). El objetivo será minimizar el mismo, es decir determinar aquella combinación de valores de $V(1)_{F3}$, $V(2)_{F3}$, $V(3)_{F3}$, y de $V(4)_{F3}$ que hagan mínimo el consumo energético en la F3.

$V(1)_{F3}$	$V(2)_{F3}$	$V(3)_{F3}$	$V(4)_{F3}$	CE (F3)
a	b	C	d	X
e	f	g	h	Z
i	j	k	l	Y

Actuando de la misma manera que en la fase anterior, obtendríamos:

$$CE(F3)=PE_{(M)}F[V(1)_{F3} * \omega_{13} + V(2)_{F3} * \omega_{23} + u_3 + V(3)_{F3} * \omega_{33} + V(4)_{F3} * \omega_{43} + u_3] * H_{(M)}$$

$CE_{(M)}$: Consumo eléctrico del molino.

$H_{(M)}$: Horas de funcionamiento del molino de crudo.

u_3 : sesgo / bias.

3) Fabricación de clínker (Fase 4: F4).

Las dos variables que se han identificado como de mayor influencia en el consumo eléctrico de esta fase son:

- Aire falso de entrada a los ciclones: $V(1)_{F4}$
- Granulometría del clínker: $V(2)_{F4}$

Para cada combinación de datos/variables de $V(1)_{F4}$, y de $V(2)_{F4}$, (a-b, c-d, e-f, etc.), obtendremos un resultado de consumo energético (X, Z, Y, ...). El objetivo será minimizar el mismo, es decir determinar aquella combinación de valores de $V(1)_{F4}$, y de $V(2)_{F4}$, que hagan mínimo el consumo energético en la F4.

$V(1)_{F4}$	$V(2)_{F4}$	CE (F4)
a	b	X
c	d	Z
e	f	Y

Actuando de la misma manera que en la fase anterior, obtendríamos:

$$CE(F4)=PE_{(H)}F[V(1)_{F4} * \omega_{14} + V(2)_{F4} * \omega_{24} + u_4] * H_{(H)}$$

$CE_{(H)}$: Consumo eléctrico del horno.

$H_{(H)}$: Horas de funcionamiento del horno de clínker.

u_4 : sesgo / bias.

4) Molienda de carbón (Fase 5: F5).

Se han seleccionado las dos variables siguientes como las que pueden influir en mayor medida en el consumo eléctrico de esta fase:

- Tamaño del carbón/granulometría: $V(1)_{F5}$.
- Velocidad de giro del molino: $V(2)_{F5}$.

Para cada combinación de datos/variables de $V(1)_{F5}$, y de $V(2)_{F5}$, (a-b, c-d, e-f, etc.), obtendremos un resultado de consumo energético (X, Z, Y, ...). El objetivo será minimizar el mismo, es decir determinar aquella combinación de valores de $V(1)_{F5}$, y de $V(2)_{F5}$, que hagan mínimo el consumo energético en la F5.

$V(1)_{F5}$	$V(2)_{F5}$	CE (F5)
a	b	X
c	d	Z
e	f	Y

Actuando de la misma manera que en la fase anterior, obtendríamos:

$$CE(F5) = PE_{(MC)} F [V(1)_{F5} * \omega_{15} + V(2)_{F5} * \omega_{25} + u_5] * H_{(MC)}$$

$CE_{(MC)}$: Consumo eléctrico del molino de carbón.

$H_{(H)}$: Horas de funcionamiento del molino de carbón.

u_5 : sesgo / bias.

5) Molino de cemento. (Fase 6: F6).

En la fábrica de Málaga del grupo FYM HeidelbergCement Group existen 3 molinos de cemento: el 5, el 6 y el 7.

Se llevará a cabo una recogida de datos relativos a las cuatro variables que pueden influir en el consumo energético de esta fase:

- Tamaño del clínker: $V(1)_{F6(M5, M6, M7)}$.
- Tamaño del yeso. $V(2)_{F6(M5, M6, M7)}$.
- Tamaño de otras adiciones. $V(3)_{F6(M5, M6, M7)}$.
- Velocidad de giro del molino: $V(4)_{F6(M5, M6, M7)}$.

Para cada combinación de datos/variables de $V(1)_{F6}$, $V(2)_{F6}$, $V(3)_{F6}$, y de $V(4)_{F6}$ (a-b-c-d, e-f-g-h, i-j-k-l, etc.), obtendremos un resultado de consumo energético (X, Z, Y, ...). El objetivo será minimizar el mismo, es decir determinar aquella combinación de valores de $V(1)_{F6}$, $V(2)_{F6}$, $V(3)_{F6}$, y de $V(4)_{F6}$ que hagan mínimo el consumo energético en la F6.

$V(1)_{F6(M5, M6, M7)}$	$V(2)_{F6(M5, M6, M7)}$	$V(3)_{F6(M5, M6, M7)}$	$V(4)_{F6(M5, M6, M7)}$	CE (F6) (M5, M6, M7).
a	b	C	d	X
e	f	G	h	Z
i	j	K	l	Y

Actuando de la misma manera que en la fase anterior, y para cada uno de los tres molinos de cemento, obtendríamos:

$$CE(F6) = PE_{(MCEM)} F [V(1)_{F6} * \omega 16 + V(2)_{F6} * \omega 26 + V(3)_{F6} * \omega 36 + V(4)_{F6} * \omega 46 + u_6] * H_{(MCEM)}$$

$CE_{(MCEM)}$: Consumo eléctrico del molino de cemento.

$H_{(H)}$: Horas de funcionamiento del molino de cemento.

u_6 : sesgo / bias.

Para obtener el consumo total de la fábrica, habrá de tener en cuenta el consumo de las 9 fases -también las 4 que no hemos considerado críticas-. Por lo tanto:

$$CE = CE(F1) + CE(F2) + CE(F3) + CE(F4) + CE(F5) + CE(F6) + CE(F7) + CE(F8) + CE(F9)$$

El objetivo que perseguiremos será minimizar el consumo eléctrico de estas 5 fases, considerando las 14 variables indicadas, de manera que, si para conseguir la minimización se precisan modificaciones en la instalación o en la operativa, éstas no supongan un gasto considerable ni una alta inversión. Se trata de conseguir la combinación óptima de las variables $V(n) F_X$, de las cinco fases del proceso productivo del cemento consideradas críticas, que minimicen el consumo eléctrico de la fábrica.

Para optimizar las 14 variables - $V(n) F_X$ - que afecta a las 5 fases críticas, utilizaremos la estructura de ANN con el algoritmo Backpropagation que aparece en la figura 18 pues, como recomienda la bibliografía analizada y las conclusiones extraídas de los contactos mantenidos con expertos, es la herramienta más efectiva. En la capa de entrada aparecen las 14 variables. Cada una de ellas afectará al consumo eléctrico de una fase “i” diferente -CE (F_i)-. Las fases aparecen reflejadas en la segunda capa de la red neuronal. Cada variable afectará con un peso diferente al consumo de las cinco fases críticas. Los pesos están representados como ω_{ij} .

i: Número de la variable. j: Fase a la que afecta.

Además, para cada fase se cumplirá que:

$$\omega_{11}+\omega_{21}=1 \quad // \quad \omega_{13}+\omega_{23}+\omega_{33}+\omega_{43}=1 \quad // \quad \omega_{14}+\omega_{24}=1 \quad // \quad \omega_{15}+\omega_{25}=1 \quad //$$

$$\omega_{16}+\omega_{26}+\omega_{36}+\omega_{46}=1.$$

La red neuronal, necesitará ser entrenada. Para ello se introducirán en el modelo distintas combinaciones de valores reales de las 14 variables - $V(n)F_i$ -. Para cada combinación de variables la fábrica obtendrá un valor CE de consumo eléctrico real observado (y). Por otro lado, la red neuronal (figuras 4 y 5) realizará una serie de cálculos con pesos aleatorios (ω_{ij}) para cada variable, y se obtendrán distintos valores de salida. El resultado obtenido por la ANN lo denominaremos (s). El objetivo de la red neuronal será minimizar el error (E) entre el valor realmente obtenido en fábrica (y) y el consumo eléctrico que indique la arquitectura de red neuronal para cada combinación de pesos (s).

$$E= \frac{1}{2} (y-s)^2 \quad \longrightarrow \quad \frac{\partial E}{\partial \omega}$$

E: Error.

y: Valor real.

s: Salida de la red neuronal.

Se minimizará el error buscando que las variaciones entre “y” y “s” sean lo menores posibles (haciendo mínimas las derivadas parciales del error que se obtenga del consumo eléctrico en función de cada peso). El error se expresará elevado al cuadrado y multiplicado por $\frac{1}{2}$, para simplificar el resultado de la derivada. El hecho de elevarlo al cuadrado anulará el signo del error, pues para nuestro objetivo resulta indiferente que el mismo sea positivo o negativo. Una vez que el error sea considerado aceptable, podremos entender que la red neuronal está lo suficientemente entrenada y que ofrece valores aceptables para los ω_{ij} .

El siguiente paso, una vez entrenada la red neuronal y conocidos los valores correctos de los pesos ω_{ij} , es decir, como afecta cada una de las variables al consumo de la fábrica en el contexto global de la misma, será introducir distintas combinaciones de valores continuos de las variables $V(n)F_i$, en la red neuronal, de manera que esta calcule, utilizando los pesos que ha determinado como válidos, los consumos eléctricos -CE- previstos. Nuestro objetivo será que la Red Neuronal haga mínimo el consumo eléctrico.

El modelo nos indicará la combinación de valores de las 14 variables que hace mínimo el consumo eléctrico. La estructura de la Red Neuronal con el algoritmo Backpropagation (Figura 20) sería la siguiente:

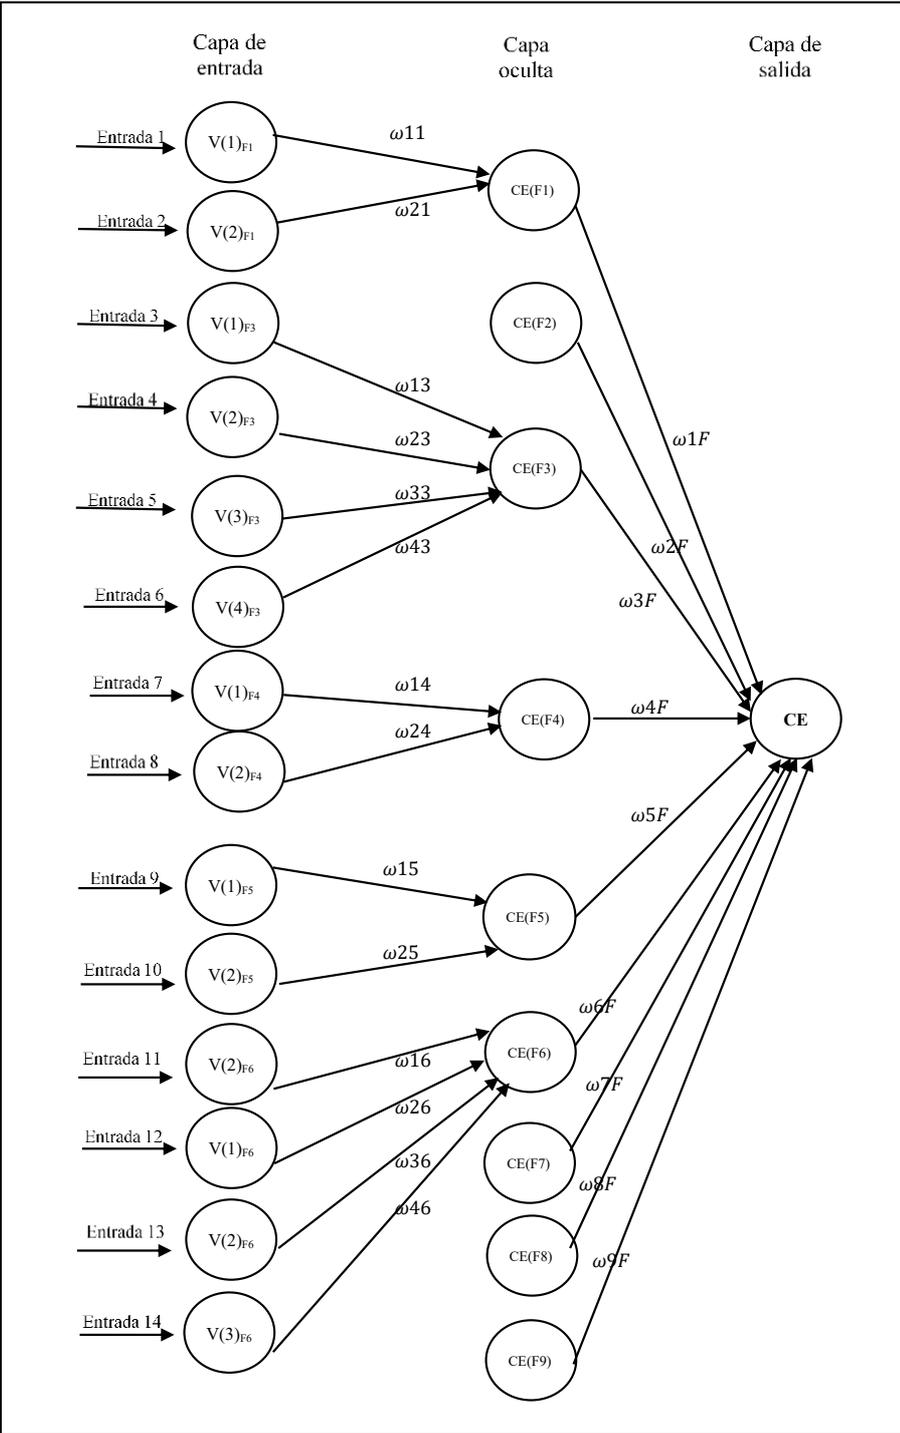


Figura 20. Funcionamiento de la Red Neuronal con el algoritmo Backpropagation.

Fuente: Elaboración propia.

4.5. Metodología para la optimización de los costes eléctricos regulados.

La metodología que se seguirá en este apartado se basará en la posibilidad de mejorar la eficiencia del coste eléctrico en una fábrica de cemento, desplazando el consumo de electricidad a los periodos en los que esta tiene menor coste (Parejo *et al.*,2021).

En España las tarifas eléctricas de alta tensión (con potencias contratadas superiores a 15 kW en alguno de los periodos), ofrecen 6 periodos horarios (P1, ..., P6). Esta tarifa, tal y como ya se explicó en el apartado 4.3., tiene diferentes precios de la energía según el periodo en el que se consuma, con lo que en la factura vendrá reflejada la energía consumida en cada uno de los periodos, con su precio por periodo correspondiente, siendo el P1 el periodo más caro y el P6 el más barato. Los periodos están repartidos a lo largo del año según la tabla siguiente (Figura 21).

Hora	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre	Sábados, domingos y festivos
00:00 - 01:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
01:00 - 02:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
02:00 - 03:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
03:00 - 04:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
04:00 - 05:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
05:00 - 06:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
06:00 - 07:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
07:00 - 08:00	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6
08:00 - 09:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
09:00 - 10:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
10:00 - 11:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
11:00 - 12:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
12:00 - 13:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
13:00 - 14:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
14:00 - 15:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
15:00 - 16:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
16:00 - 17:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
17:00 - 18:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
18:00 - 19:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
19:00 - 20:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
20:00 - 21:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
21:00 - 22:00	P1	P1	P2	P4	P4	P3	P1	P3	P3	P4	P2	P1	P6
22:00 - 23:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6
23:00 - 24:00	P2	P2	P3	P5	P5	P4	P2	P4	P4	P5	P3	P2	P6

Figura 21. Calendarios Energéticos. Distribución de Periodos Aplicables a las Tarifas Eléctricas. Fuente: Circular de la CNMC 3/2020 de 15 de enero de la CNMC por la que se establece la metodología para el cálculo de los peajes de transporte y distribución de la electricidad. GOIENER, (2021). https://www.goiener.com/nuevas-tarifas-electricas-para-empresas__trashed/tarifas-6-xtd/

El objetivo en esta parte de la investigación será optimizar el coste energético, centrándonos en el coste €/kWh, es decir, utilizar siempre el kWh más barato que sea posible (según los periodos: P1, P2, ..., P6).

En este apartado se determinarán igualmente posibles bajadas en las potencias contratadas, cuando ello sea posible, para rebajar el coste fijo de la factura de electricidad.

Tras un análisis de los distintos algoritmos y técnicas de aprendizaje automático disponibles (expuesto en el apartado 2.6.), así como de la opinión de expertos (apartado 4.3.), se ha adoptado la decisión de hacer uso de los algoritmos genéticos, que son herramientas de gran utilidad para solucionar problemas de optimización (Michalewicz, Z., 1999).

Los pasos a seguir en este desarrollo metodológico son tres, que se detallan en los siguientes subapartados.

4.5.1. Traslación del consumo eléctrico de las distintas fases a los periodos P(Y) de menor coste.

Se determinaron las funciones de consumo eléctrico para cada una de las fases del proceso de fabricación de cemento (**9 funciones**) considerando cada uno de los 6 periodos (P1, ..., P6). El proceso de fabricación de cemento puede consultarse en la figura 46. Utilizaremos la siguiente nomenclatura:

- $CE(FX)$. Consumo eléctrico total fase X. Lo mediremos en kWh.
- $PE_{FX} P(Y)$. Potencia eléctrica de la fase X durante el periodo Y. Lo mediremos en kW.
- $H_{FX}P(Y)$. Horas de trabajo en la fase X durante el periodo Y. Lo mediremos en h.

Siendo $X=1, \dots, 9$ e $Y=1, \dots, 6$.

Las funciones de consumo eléctrico serían:

a) Extracción de materias primas/triturado. Comprende el consumo eléctrico desde la extracción de materia prima en la cantera hasta la entrada en el parque de prehomogeneización. (Fase 1: F1).

En el caso de la fábrica de cementos de FYM HeidelbergCement Group en Málaga, existen dos trituradoras. La función sería:

$$\begin{aligned} \text{➤ } CE(F1)_{(t1,t2)} = & PE_{F1}P(1)_{(t1)} * H_{F1}P(1)_{(t1)} + PE_{F1}P(1)_{(t2)} * H_{F1}P(1)_{(t2)} + \\ & PE_{F1}P(2)_{(t1)} * H_{F1}P(2)_{(t1)} + PE_{F1}P(2)_{(t2)} * H_{F1}P(2)_{(t2)} + \\ & PE_{F1}P(3)_{(t1)} * H_{F1}P(3)_{(t1)} + PE_{F1}P(3)_{(t2)} * H_{F1}P(3)_{(t2)} + \\ & PE_{F1}P(4)_{(t1)} * H_{F1}P(4)_{(t1)} + PE_{F1}P(4)_{(t2)} * H_{F1}P(4)_{(t2)} + \\ & PE_{F1}P(5)_{(t1)} * H_{F1}P(5)_{(t1)} + PE_{F1}P(5)_{(t2)} * H_{F1}P(5)_{(t2)} + \\ & PE_{F1}P(6)_{(t1)} * H_{F1}P(6)_{(t1)} + PE_{F1}P(6)_{(t2)} * H_{F1}P(6)_{(t2)}. \end{aligned}$$

b) Homogeneización. Incluye el transporte en cintas transportadoras hasta el molino de crudo. (Fase 2: F2).

$$\begin{aligned} \text{➤ } CE(F2) = & PE_{F2}P(1) * H_{F2}P(1) + PE_{F2}P(2) * H_{F2}P(2) + PE_{F2}P(3) * H_{F2}P(3) + \\ & PE_{F2}P(4) * H_{F2}P(4) + PE_{F2}P(5) * H_{F2}P(5) + PE_{F2}P(6) * H_{F2}P(6). \end{aligned}$$

c) Molino de crudo. Consumo eléctrico del molino y transporte de los elevadores hasta la entrada en la torre de ciclones. (Fase: F3).

$$\begin{aligned} \text{➤ } CE(F3) = & PE_{F3}P(1) * H_{F3}P(1) + PE_{F3}P(2) * H_{F3}P(2) + PE_{F3}P(3) * H_{F3}P(3) + \\ & PE_{F3}P(4) * H_{F3}P(4) + PE_{F3}P(5) * H_{F3}P(5) + PE_{F3}P(6) * H_{F3}P(6) \end{aligned}$$

d) Fabricación de Clíinker. Consumo energético de los ciclones, horno de Clíinker, ventiladores, etc. (Fase 4: F4).

$$\begin{aligned} \text{➤ } CE(F4) = & PE_{F4}P(1) * H_{F4}P(1) + PE_{F4}P(2) * H_{F4}P(2) + PE_{F4}P(3) * H_{F4}P(3) + \\ & PE_{F4}P(4) * H_{F4}P(4) + PE_{F4}P(5) * H_{F4}P(5) + PE_{F4}P(6) * H_{F4}P(6) \end{aligned}$$

e) Molienda de carbón. (Fase 5: F5).

$$\begin{aligned} \text{➤ } CE(F5) = & PE_{F5}P(1) * H_{F5}P(1) + PE_{F5}P(2) * H_{F5}P(2) + PE_{F5}P(3) * H_{F5}P(3) + \\ & PE_{F5}P(4) * H_{F5}P(4) + PE_{F5}P(5) * H_{F5}P(5) + PE_{F5}P(6) * H_{F5}P(6) \end{aligned}$$

f) Molino de cemento. (Fase 6: F6).

En el caso de la fábrica de cementos de FYM HeidelberCement Group en Málaga, existen tres molinos de cemento: (5, 6 y 7). La función sería:

$$\begin{aligned} \text{➤ } CE(F6)_{(M5,M6,M7)} = & PE_{F6}P(1)_{(M5)} * H_{F6}P(1)_{(M5)} + PE_{F6}P(1)_{(M6)} * H_{F6}P(1)_{(M6)} + \\ & PE_{F6}P(1)_{(M7)} * H_{F6}P(1)_{(M7)} + PE_{F6}P(2)_{(M5)} * H_{F6}P(2)_{(M5)} + \\ & PE_{F6}P(2)_{(M6)} * H_{F6}P(2)_{(M6)} + PE_{F6}P(2)_{(M7)} * H_{F6}P(2)_{(M7)} + \\ & PE_{F6}P(3)_{(M5)} * H_{F5}P(3)_{(M5)} + PE_{F6}P(3)_{(M6)} * H_{F5}P(3)_{(M6)} + \\ & PE_{F6}P(3)_{(M7)} * H_{F5}P(3)_{(M7)} + PE_{F6}P(4)_{(M5)} * H_{F6}P(4)_{(M5)} + \\ & PE_{F6}P(4)_{(M6)} * H_{F6}P(4)_{(M6)} + PE_{F6}P(4)_{(M7)} * H_{F6}P(4)_{(M7)} + \\ & PE_{F6}P(5)_{(M5)} * H_{F6}P(5)_{(M5)} + PE_{F6}P(5)_{(M6)} * H_{F6}P(5)_{(M6)} + \\ & PE_{F6}P(5)_{(M7)} * H_{F6}P(5)_{(M7)} + PE_{F6}P(6)_{(M5)} * H_{F6}P(6)_{(M5)} + \\ & PE_{F6}P(6)_{(M6)} * H_{F6}P(6)_{(M6)} + PE_{F6}P(6)_{(M7)} * H_{F6}P(6)_{(M7)} \end{aligned}$$

g) Transporte. (Fase 7: F7).

$$\begin{aligned} \text{➤ } CE(F7) = & PE_{F7}P(1) * H_{F7}P(1) + PE_{F7}P(2) * H_{F7}P(2) + PE_{F7}P(3) * H_{F7}P(3) + \\ & PE_{F7}P(4) * H_{F7}P(4) + PE_{F7}P(5) * H_{F7}P(5) + PE_{F7}P(6) * H_{F7}P(6) \end{aligned}$$

h) Empaquetado. (Fase 8: F8).

$$\begin{aligned} \text{➤ } CE(F8) = & PE_{F8}P(1) * H_{F8}P(1) + PE_{F8}P(2) * H_{F8}P(2) + PE_{F8}P(3) * H_{F8}P(3) + \\ & PE_{F8}P(4) * H_{F8}P(4) + PE_{F8}P(5) * H_{F8}P(5) + PE_{F8}P(6) * H_{F8}P(6). \end{aligned}$$

i) Servicios auxiliares. Oficinas y demás servicios indirectos a la producción. (Fase 9: F9).

$$\begin{aligned} \text{➤ } CE(F9) = & PE_{F9}P(1) * H_{F9}P(1) + PE_{F9}P(2) * H_{F9}P(2) + PE_{F9}P(3) * H_{F9}P(3) + \\ & PE_{F9}P(4) * H_{F7}P(4) + PE_{F9}P(5) * H_{F9}P(5) + PE_{F9}P(6) * H_{F9}P(6). \end{aligned}$$

Para optimizar -reducir- el consumo eléctrico de cada una de las 9 fases del proceso, se utilizarán algoritmos genéticos. Al finalizar este apartado se expondrá como funcionarían los citados algoritmos.

4.5.2. Limitaciones de potencia para las tarifas de acceso.

Con objeto de impedir la posibilidad de sobrepasar las potencias contratadas para cada uno de los periodos se definen seis funciones que limitan esta posibilidad. La demanda de potencia (MW) en cada uno de los periodos de todos los equipos, nunca deberá sobrepasar la potencia contratada para ese periodo.

Por otro lado, el modelo intentará, planteando otras seis funciones algorítmicas, disminuir la potencia contratada por la fábrica para cada uno de los periodos de consumo eléctrico. Así si el consumo durante un periodo P_i fuese inferior en más de un % al máximo contratado y se estableciera en C' , se podría contratar menor potencia para disminuir el coste por la tarifa de acceso en ese periodo.

En total tendremos en cuenta un total de 12 funciones. Aplicaremos las limitaciones de potencias contratadas al ejemplo de la fábrica de cemento de Málaga; son las siguientes:

Potencia máxima en 66 KV	MW
Potencia máxima 2 transformadores	20+20
Potencia contratada en P1	14
Potencia contratada en P2	14
Potencia contratada en P3	17,2
Potencia contratada en P4	17,2
Potencia contratada en P5	17,2
Potencia contratada en P6	17,4

Para desarrollar las funciones relacionadas con las tarifas de acceso utilizaremos la siguiente nomenclatura:

$CE (P_Y)$. Consumo eléctrico en el periodo Y. Siendo $Y= 1, 2, \dots, 6$.

El consumo eléctrico de cada periodo será la suma de los consumos que se registren en cada una de las fases en las que hemos dividido el proceso de fabricación de cemento. Se trata de que con los consumos registrados, en cada momento puntual, nunca se supere la potencia máxima contratada para ese periodo.

El consumo de la fase 1 habrá de tener en cuenta que disponemos de dos trituradoras. De la misma manera en la fase 6, consideraremos los tres molinos de cemento que operan en la planta: molino 5, molino 6 y molino 7.

Período 1: Funciones limitación de la potencia eléctrica en P1:

- $CE(P_1) = CE_{F1}P(1) + CE_{F2}P(1) + CE_{F3}P(1) + CE_{F4}P(1) + CE_{F5}P(1) + CE_{F6}P(1) + CE_{F7}P(1) + CE_{F8}P(1) + CE_{F9}P(1) \leq 14 \text{ MW}$
- Si $0 \leq CE(P_1) \leq C' \text{ MW}$ (1 mes en condiciones normales³) —→ Posibilidad de bajar tarifa de acceso.

Período 2.: Funciones limitación del consumo energético en P2:

- $CE(P_2) = CE_{F1}P(2) + CE_{F2}P(2) + CE_{F3}P(2) + CE_{F4}P(2) + CE_{F5}P(2) + CE_{F6}P(2) + CE_{F7}P(2) + CE_{F8}P(2) + CE_{F9}P(2) \leq 14 \text{ MW}$
- Si $0 \leq CE(P_2) \leq C' \text{ MW}$ (1 mes en condiciones normales) —→ Posibilidad de bajar tarifa de acceso.

Período 3: Funciones limitación del consumo energético en P3:

- $CE(P_3) = CE_{F1}P(3) + CE_{F2}P(3) + CE_{F3}P(3) + CE_{F4}P(3) + CE_{F5}P(3) + CE_{F6}P(3) + CE_{F7}P(3) + CE_{F8}P(3) + CE_{F9}P(3) \leq 17,2 \text{ MW}$
- Si $0 \leq CE(P_3) \leq C' \text{ MW}$ (1 mes en condiciones normales) —→ Posibilidad de bajar tarifa de acceso.

Período 4: Funciones limitación del consumo energético en P4:

- $CE(P_4) = CE_{F1}P(4) + CE_{F2}P(4) + CE_{F3}P(4) + CE_{F4}P(4) + CE_{F5}P(4) + CE_{F6}P(4) + CE_{F7}P(4) + CE_{F8}P(4) + CE_{F9}P(4) \leq 17,2 \text{ MW}$.

³ Condiciones normales: Se refiere a que, para tomar la decisión de bajar la tarifa de acceso, debemos tener en cuenta un mes en el que no se hayan acometido labores de mantenimiento ni se hayan dado averías o situaciones excepcionales, que impidan considerar al mes como representativo.

- Si $0 \leq CE(P_4) \leq C'$ MW (1 mes en condiciones normales) → Posibilidad de bajar tarifa de acceso.

Período 5: Funciones limitación del consumo energético en P5:

- $CE(P_5) = CE_{F1}P(5) + CE_{F2}P(5) + CE_{F3}P(5) + CE_{F4}P(5) + CE_{F5}P(5) + CE_{F6}P(5) + CE_{F7}P(5) + CE_{F8}P(5) + CE_{F9}P(5) \leq 17,2$ MW
- Si $0 \leq CE(P_5) \leq C'$ MW (1 mes en condiciones normales) → Posibilidad de bajar tarifa de acceso.

Período 6: Funciones limitación del consumo energético en P6:

- $CE(P_6) = CE_{F1}P(6) + CE_{F2}P(6) + CE_{F3}P(6) + CE_{F4}P(6) + CE_{F5}P(6) + CE_{F6}P(6) + CE_{F7}P(6) + CE_{F8}P(6) + CE_{F9}P(6) \leq 17,4$ MW
- Si $0 \leq CE(P_6) \leq C'$ MW (1 mes en condiciones normales) → Posibilidad de bajar tarifa de acceso.

La fábrica de cemento de HeidelbergCement Group en Málaga cuenta con dos transformadores en paralelo de 20 MW. Desde el punto de vista energético la opción más eficiente es tener desconectado uno de los dos para eliminar las pérdidas. Dadas las potencias contratadas por la fábrica para cada uno de los periodos P_i , la instalación puede funcionar perfectamente con solo uno de los transformadores. El hecho de tener dos, garantiza el funcionamiento de la fábrica en el caso de que uno de ellos sufriera una avería. No obstante, como se ha afirmado anteriormente, el presente modelo sería perfectamente aplicable a cualquier otra fábrica de cemento de vía seca.

4.5.3. Restricciones de operación y ventas.

A continuación el modelo utilizará otras **9 funciones**, que se denominarán “Restricciones de Operación y Ventas”. Estas funciones reflejarán dos cuestiones que resultarán de suma importancia a tener en cuenta en nuestro modelo:

- La capacidad máxima de producción de cada fase del proceso de fabricación de cemento menos la capacidad máxima de la siguiente debe ser ≥ 0 y a su vez \leq que la capacidad de almacenamiento de la materia prima, combustible, subproducto o producto final en cada fase del proceso, respectivamente (7 funciones).

- Limitaciones horarias (2 funciones).

Para estas nuevas funciones tendremos en cuenta la siguiente nomenclatura y datos de la fábrica de cemento de Málaga, medidos en toneladas/hora (t/h):

- $CP_{F1(t1)}$: Capacidad máxima de producción a la hora, en la fase de extracción de materias primas- Trituradora 1: 300 t/h.
- $CP_{F1(t2)}$: Capacidad máxima de producción a la hora, en la fase de extracción de materias primas-Trituradora 2: 520 t/h.
- CAMp: Capacidad máxima de almacenamiento de materias primas trituradas.
- CP_{F2} : Capacidad máxima de producción a la hora, en la fase de Homogeneización:320 t/h.
- CAMpH: Capacidad máxima de almacenamiento de materia prima homogeneizada.
- CP_{F3} : Capacidad máxima de producción a la hora, en la fase de molienda de crudo: 550t/h.
- CACr: Capacidad máxima de almacenamiento de crudo.
- CP_{F4} : Capacidad máxima de producción a la hora, en la fase de fabricación de clínker / horno. Para el crudo: 240 t/h. Para el clínker: 154 t/h.
- CACk: Capacidad máxima de almacenamiento de Clínker.
- CP_{F5} : Capacidad máxima de producción a la hora, en la fase de molienda de carbón:17,1 t/h.
- CACb: Capacidad máxima de almacenamiento de Carbón.

- CC: Consumo de carbón del horno, medido en t/h.
- CP_{F6} : Capacidad máxima de producción a la hora, en la fase molienda de cemento.
 - $CP_{F6(M5)}$ -Molino cemento 5: 29,2 t/h.
 - $CP_{F6(M6)}$ -Molino cemento 6: 78 t/h.
 - $CP_{F6(M7)}$ -Molino cemento 7: 34,3 t/h.
- CP_{F7} : Capacidad máxima de producción a la hora, en la fase de transporte.
- $CASL_CEM(Z)$: Capacidad máxima de almacenamiento de cemento en el silo de cemento Z.
- CP_{F8} : Capacidad máxima de producción a la hora, en la fase de empaquetado.

Hay dos líneas de empaquetado con las siguientes capacidades:

- Línea 1: 67 t/h (2.700 sacos).
- Línea 2: 55 t/h (2.200 sacos).
- CAEns: capacidad máxima de almacenamiento en el almacén de ensacado.
- CP_{F9} : Capacidad máxima de producción a la hora, en la fase de servicios auxiliares.
- $VE_{CEM(Z)}$: Ventas de cemento tipo Z ensacado, siendo $Z= 1, \dots, n$.
- $VG_{CEM(Z)}$: Ventas de cemento tipo Z a granel, siendo $Z= 1, \dots, n$.

➤ Capacidad máxima de las trituradoras 1 y 2. Fase 1. Extracción de materias primas.

La capacidad de triturado de la trituradora 1 es de 300 t/h, mientras que la de la trituradora 2 asciende a 500 t/h. De esta manera la trituradora 2 no resultará ningún cuello de botella ni será una restricción para la trituradora 1. De esta manera una restricción en la fase de trituración será la siguiente:

- $CAM_p \geq CP_{F1(t2)} * [H_{F1P}(1)_{(t2)} + H_{F1P}(2)_{(t2)} + H_{F1P}(3)_{(t2)} + H_{F1P}(4)_{(t2)} + H_{F1P}(5)_{(t2)} + H_{F1P}(6)_{(t2)}] - CP_{F2} * [H_{F2}(1) + H_{F2P}(2) + H_{F2P}(3) + H_{F2P}(4) + H_{F2P}(5) + H_{F2P}(6)] \geq 0$.

- Función limitación horaria: Las trituradoras 1 y 2 deben funcionar solo entre las 7 y las 23 horas.

$$H_{F1P(1)(t1)}, H_{F1P(2)(t1)}, H_{F1P(3)(t1)}, H_{F1P(4)(t1)}, H_{F1P(5)(t1)}, H_{F1P(6)(t1)},$$

$$H_{F1P(1)(t2)}, H_{F1P(2)(t2)}, H_{F1P(3)(t2)}, H_{F1P(4)(t2)}, H_{F1P(5)(t2)}, H_{F1P(6)(t2)} \in 7-23 \text{ horas.}$$

➤ Capacidad máxima de la fase de homogeneización.

$$- C_{AMpH} \geq CP_{F2} * [H_{F2P(1)} + H_{F2P(2)} + H_{F2P(3)} + H_{F2P(4)} + H_{F2P(5)} + H_{F2P(6)}] - CP_{F3} * [H_{F3P(1)} + H_{F3P(2)} + H_{F3P(3)} + H_{F3P(4)} + H_{F3P(5)} + H_{F3P(6)}] \geq 0$$

- Sin limitación horaria.

➤ Capacidad máxima del molino de materia prima (crudo).

$$- C_{ACr} \geq CP_{F3} * [H_{F3P(1)} + H_{F3P(2)} + H_{F3P(3)} + H_{F3P(4)} + H_{F3P(5)} + H_{F3P(6)}] - CP_{F4} * [H_{F4P(1)} + H_{F4P(2)} + H_{F4P(3)} + H_{F4P(4)} + H_{F4P(5)} + H_{F4P(6)}] \geq 0$$

- Sin limitación horaria.

➤ Capacidad máxima de fabricación de clínker (horno).

$$- C_{ACk} \geq CP_{F4} * [H_{F4P(1)} + H_{F4P(2)} + H_{F4P(3)} + H_{F4P(4)} + H_{F4P(5)} + H_{F4P(6)}] - CP_{F6} * [H_{F6P(1)} + H_{F6P(2)} + H_{F6P(3)} + H_{F6P(4)} + H_{F6P(5)} + H_{F6P(6)}] \geq 0$$

- Sin limitación horaria.

➤ Capacidad máxima del molino de carbón.

$$- C_{ACb} \geq CP_{F5} * [H_{F5P(1)} + H_{F5P(2)} + H_{F5P(3)} + H_{F5P(4)} + H_{F5P(5)} + H_{F5P(6)}] - CC * [H_{F4P(1)} + H_{F4P(2)} + H_{F4P(3)} + H_{F4P(4)} + H_{F4P(5)} + H_{F4P(6)}] \geq 0$$

- Sin limitación horaria.

➤ Capacidad máxima del molino de cemento / capacidad máxima de transporte.

Tendremos una función por cada uno de los Z tipos de cemento fabricados en la fábrica, siendo $Z = 1, 2, \dots, n$.

- $CASL_CEM(Z) \geq CP_{F6(M5)} * [H_{F6P(1)}(M5) + H_{F6P(2)}(M5) + H_{F6P(3)}(M5) + H_{F6P(4)}(M5) + H_{F6P(5)}(M5) + H_{F6P(6)}(M5)] + CP_{F6(M6)} * [H_{F6P(1)}(M6) + H_{F6P(2)}(M6) + H_{F6P(3)}(M6) + H_{F6P(4)}(M6) + H_{F6P(5)}(M6) + H_{F6P(6)}(M6)] + CP_{F6(M7)} * [H_{F6P(1)}(M7) + H_{F6P(2)}(M7) + H_{F6P(3)}(M7) + H_{F6P(4)}(M7) + H_{F6P(5)}(M7) + H_{F6P(6)}(M7)] - CP_{F7} [H_{F7P(1)} + H_{F7P(2)} + H_{F7P(3)} + H_{F7P(4)} + H_{F7P(5)} + H_{F7P(6)}] - VG_{CEM(Z)} \geq 0$
- Sin limitación horaria.

➤ Capacidad máxima de ensacado.

Tendremos una función por cada uno de los Z tipos de cemento fabricados en la fábrica, siendo $Z = 1, 2, \dots, n$.

- $CAEns \geq CP_{F6(M5)} * [H_{F6P(1)}(M5) + H_{F6P(2)}(M5) + H_{F6P(3)}(M5) + H_{F6P(4)}(M5) + H_{F6P(5)}(M5) + H_{F6P(6)}(M5)] + CP_{F6(M6)} * [H_{F6P(1)}(M6) + H_{F6P(2)}(M6) + H_{F6P(3)}(M6) + H_{F6P(4)}(M6) + H_{F6P(5)}(M6) + H_{F6P(6)}(M6)] + CP_{F6(M7)} * [H_{F6P(1)}(M7) + H_{F6P(2)}(M7) + H_{F6P(3)}(M7) + H_{F6P(4)}(M7) + H_{F6P(5)}(M7) + H_{F6P(6)}(M7)] - CASL_CEM(Z) - VE_{CEM(Z)} - VG_{CEM(Z)} \geq 0$.

$VE_{CEM(Z)}$: Ventas de cemento tipo Z empaquetado siendo $Z = 1, \dots, n$.

- Limitaciones horarias: La ensacadora debe funcionar entre las 7 y las 23 horas
 $H_{F8P(1)}, H_{F8P(2)}, H_{F8P(3)}, H_{F8P(4)}, H_{F8P(5)}, H_{F8P(6)} \in 7-23$ horas.

➤ Capacidad máxima servicios auxiliares.

- En esta fase no habría ninguna restricción de este tipo.

Teniendo en cuenta la demanda de clínker, los distintos tipos de cementos, las funciones de consumo eléctrico, las restricciones de tarifas de acceso y de los transformadores disponibles y las restricciones de operación y venta, conseguiremos, mediante la utilización de algoritmos genéticos y de manera inteligente, que el sistema

sugiera al responsable de la fábrica, los cambios que debe realizar en cada momento para desplazar la producción a periodos de menor coste (P6, P5, P4, etc.).

Dado que las potencias eléctricas de cada una de las fases del proceso en cada periodo $-PE_{FXP}(Y)-$ son términos fijos de las ecuaciones, los algoritmos genéticos operarán sobre las horas durante las cuales los equipos están consumiendo electricidad, que son los términos variables $-H_{FXP}(Y)-$. Los algoritmos genéticos operan aplicando de manera continua mecanismos de selección, recombinación y mutación de cromosomas, como se explicó anteriormente en el análisis de las herramientas de IA. En nuestro caso estos mecanismos consistirán en recombinar los $H_{FXP}(Y)$ de manera que se utilicen siempre en un orden descendente (P6, P5, ..., P1). Es decir, los algoritmos genéticos operaran de cara a que primero se utilicen las horas de funcionamiento de los equipos en P(6), después en P(5), (...), y finalmente en P(1). Como se indicó anteriormente el objetivo será trasladar el consumo eléctrico a aquellos períodos de menor coste. Este ciclo evolutivo de recombinación de la ecuación continuará hasta que se da un criterio de parada o criterio de convergencia (Quinlan *et al.*, 2008). En nuestro caso el criterio será un determinado porcentaje de reducción del consumo eléctrico.

CAPÍTULO 5. OPTIMIZACIÓN DEL COSTE ELÉCTRICO OPERANDO SOBRE EL PRECIO ELÉCTRICO DEL MERCADO.

5.1. Introducción.

El objetivo que se abordará en el capítulo 5 será reducir los costes eléctricos de una fábrica de cemento optimizando la compra de la energía en el mercado. Para ello se utilizarán técnicas de minería de datos (*Data Mining*), dentro de procesos de *Conocimiento de bases de datos (Knowledge Discovery in Data Bases o KDD)*. La IA nos ayudará a predecir precios de la electricidad para optimizar su compra. Se pretende influir sobre el coste del consumo específico eléctrico de la planta. Se utilizarán técnicas ANN para predecir precios de compra (Bramer, M., 2007 y Lara, J., 2014).

5.2. Revisión de la literatura.

Tras un análisis detallado de los artículos científicos seleccionados mediante la revisión de la literatura pudimos obtener las siguientes conclusiones:

- De los trabajos analizados, tan solo cuatro hacen referencia al sector cementero, siendo la mayoría intersectoriales (consultar Tabla 2).
- Los modelos de ANN multicapa de perceptrón, el algoritmo de entrenamiento Backpropagation y el de optimización Descenso del Gradiente, resultan de gran utilidad para predecir los precios futuros diarios de la electricidad. En los trabajos previos analizados en los que se hace uso de estas herramientas para la predicción de precios eléctricos (Khotanzad, 2018; Wesley, 2011; Hurtado *et al.*, 2014; Zhang y Cheng, 2008; Georgilakis, 2007; Sreekumar *et al.*, 2020; Théate *et al.*, 2020) no se profundiza al nivel que se hace en nuestra investigación, por lo que tenemos información parcial.
- La meteorología (aspectos como la temperatura, el viento y la lluvia), juega un papel fundamental para predecir precios futuros (Khotanzad, 2018; Zhang y Cheng, 2008).
- El porfolio de generación eléctrica supone otra importante variable que afecta al precio diario de la electricidad (Hurtado, 2014). La escasa información y detalle en la

literatura previa ha sido resuelta a través de un análisis mucho más detallado y profundo de cada una de las fuentes de generación eléctrica (<http://www.energiaysociedad.es/manenergia/manual-de-la-energia/> (ver apartado 5.4.).

- Además de las ANN, pueden utilizarse otras herramientas, como algoritmos genéticos (Azadeh *et al.*, 2015) y lógica difusa (Hurtado, L., 2014), para predecir los precios futuros diarios de la electricidad. No obstante, la herramienta más adecuada y utilizada mayoritariamente eran las ANN con el algoritmo *Backpropagation* y el método *Mean Squared Error* (MSE) (Théate *et al.*, 2020).

Tal y como ya se ha indicado, el estudio de la literatura previa nos ha proporcionado un número muy reducido de artículos, y con información limitada, relacionados con el tema objeto de nuestra investigación. Algunos artículos abordan la problemática de la optimización energética/ eléctrica en fábricas de cemento (Castañón *et al.*, 2014; Swanepoel *et al.*, 2013; Swanepoel, 2013; Shaohog *et al.*, 2012). Sin embargo, en ningún caso se abordaba el análisis del coste eléctrico siguiendo una metodología completa que incluya el análisis detallado de un número relevante de factores que incidan en la formación del precio eléctrico (ver detalle en Figura 28) y, sobre todo, no se habían integrado en un mismo modelo los tres aspectos que se han abordado en nuestra investigación. Por ejemplo, Castañón *et al.* (2014), se centran, fundamentalmente, en el empleo de herramientas estadísticas para analizar empíricamente la correlación entre distintos parámetros. Swanepoel *et al.* (2013) se orientan a dos cuestiones fundamentalmente: trasladar la producción a periodos de consumo con costes eléctricos más bajos y aprovechar la capacidad de almacenamiento y la eficiencia de los equipos. Swanepoel (2013) y Shaohog *et al.* (2012) abordan la optimización eléctrica y energética, respectivamente, basándose en sistemas de gestión del proceso productivo.

5.3. Consultas a expertos.

Las consultas a expertos que completarán la información obtenida de la literatura previa, aportan un aspecto novedoso a nuestra investigación frente a las previas, pues, en ninguno de los artículos analizados relacionados con la problemática abordada, se ha llevado a cabo un proceso de consultas a expertos.

El panel de expertos ha aportado información relevante para diseñar la metodología para optimizar el coste eléctrico haciendo uso de IA. 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 IA basadas en ANN (según el 80% de expertos consultados). Y en algoritmos genéticos (según el 20% de expertos consultados). Servirán como variables de entrada de estas técnicas, entre otras, los precios eléctricos, los datos meteorológicos y el mix energético. El 100% de los expertos coincidieron en la validez de estas variables como entradas del sistema.

Por otro lado, los expertos han señalado como factores que influyen en la composición del precio de la electricidad los que se indican a continuación. Estos coinciden en gran medida con lo que se concluye del análisis sistemático de la literatura (IpsomManager, 2019; Energía y Sociedad, 2021). Los factores serían:

- a) Derechos de emisión de CO₂. El incremento del precio de los derechos de emisión de CO₂ de las centrales de generación durante 2019, ha supuesto el aumento de unos 14 € por tonelada de CO₂ emitida por estas centrales, aproximadamente.

- b) Precio del gas, el cual está referenciado en parte al precio del petróleo.

- c) El aumento de la demanda de energía eléctrica. Le afectan fundamentalmente tres factores: la meteorología, la laboralidad y la época del año.

- d) Climatología. Las condiciones climatológicas extremas (ola de calor), presentes en los meses de julio y agosto, provocan habitualmente que la demanda de electricidad durante los mismos sea superior a la del resto de meses. Los datos de temperaturas, precipitaciones y vientos resultaran de gran utilidad para incorporarlos al modelo de IA de predicción de precios de energía. (AEMET, 2019).

- e) Mix energético/dependencia energética. La energía eléctrica es generada a partir de distintas fuentes: renovables, hidráulica, combustibles fósiles o energía nuclear. Es de esperar que el precio del kilovatio hora difiera según el origen de

la energía. Para analizar la evolución de precios eléctricos y la formación del precio marginal, es necesario tener en cuenta la estructura de generación eléctrica. Esta información ayudará al sistema predictivo de IA, empleando machine learning, a llevar a cabo una predicción válida del precio de la energía. En la figura 22 puede observarse, a modo de ejemplo, la estructura de generación mensual peninsular en octubre de 2019, en función a las tecnologías utilizadas (REE, 2019).

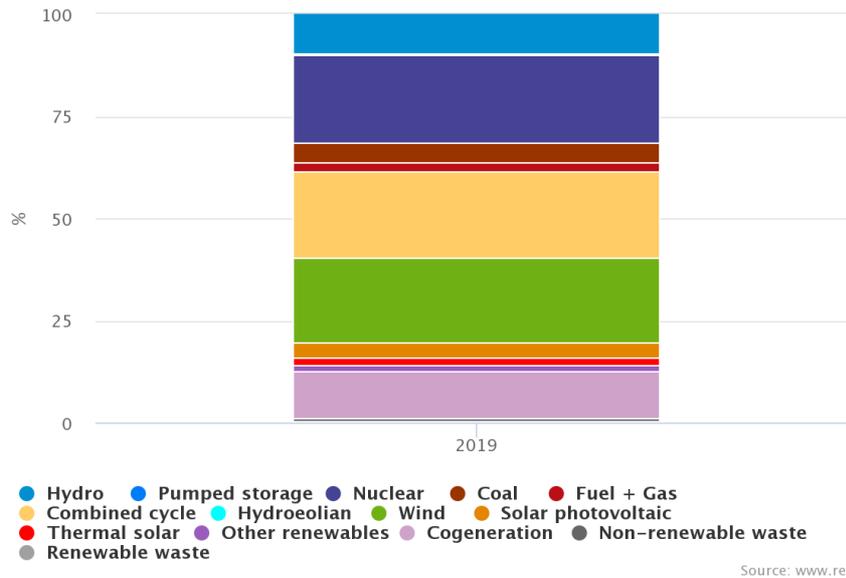


Figura 22. Estructura de generación mensual peninsular. Octubre 2019. Fuente REE.

f) Mercado de futuros eléctricos. La evolución de los precios de los futuros eléctricos, en combinación con el mix energético de generación de cada momento, resulta un factor indispensable para predecir los precios.

5.4. Metodología para la optimización eléctrica operando sobre el precio eléctrico del mercado.

No resulta en absoluto sencillo, según Khotanzad, (2018), predecir los precios de la electricidad, debido fundamentalmente a la alta volatilidad de los mismos. Algunos autores han hecho uso de técnicas de reducción de la dimensionalidad, es decir, han simplificado las variables aleatorias, o bien han combinado pronósticos de varios modelos para predecir precios eléctricos (Alonso *et al.*, 2016).

En la literatura existen métodos cuantitativos que se centran en el pronóstico de precios a corto plazo, abordando los precios por hora y por día en los mercados diarios e intradiarios, que son ricos en datos y, por lo tanto, proporcionan una base adecuada para dicho análisis (Aggarwal, 2009; Carpio *et al.*, 2014; Cerjan *et al.*, 2014; Cheng *et al.*, 2016; Conejo *et al.*, 2005; Contreras *et al.*, 2003; Cuaresma *et al.*, 2004; González *et al.*, 2012; Huang *et al.*, 2012; Jakaša *et al.*, 2011; Keles *et al.*, 2016; Kian y Keyhani, 2001; Nogales *et al.*, 2002; Papadimitriou *et al.*, 2014; Pezzutto *et al.*, 2018; Robinson, 2000; Rubin y Babcock., 2013; Ruibal y Mazumdar, 2008; Shrivastava, *et al.*, 2015; Sreekumar *et al.*, 2020; Tan *et al.*, 2010; Wood y Wollenberg, 1996; Xie *et al.*, 2013; Zhang y Tan, 2013 y Zhao *et al.*, 2007).

Pronosticar las tendencias de precios a medio y largo plazo resulta significativamente más desafiante debido al mayor número de factores que pueden influir: ciclos económicos; condiciones climáticas, como la temperatura, vientos, lluvias, etc.; eventos geopolíticos; nivel de actividad humana y laboralidad; época del año; avances tecnológicos; demografía; precio de los combustibles fósiles; etc. (Bello *et al.*, 2016; Hurtado *et al.*, 2014; Khotanzad, 2018; Lijesen, 2007; Marinero y Pavlova, 2003; Pezzutto *et al.*, 2018; Rubin y Babcock, 2013; Sreekumar *et al.*, 2020; Torghaban *et al.*, 2012; Yan y Chowdhury, 2014; Yan y Chowdhury, 2013 y Zhang y Cheng, 2008).

Otros métodos incluyen el aprendizaje automático y la IA más específicamente; concretamente Catalão *et al.*, (2007) utilizan como herramienta básica las ANN. Esta investigación se basará en esta metodología. El objetivo será aportar una arquitectura de red neuronal artificial, basada en la bibliografía analizada y en la información aportada por los expertos en relación, principalmente, a las variables significativas seleccionadas como base para el aprendizaje y la aportación de resultados de la red neuronal. La misma utilizará el algoritmo de aprendizaje Backpropagation y el método Mean Squared Error (MSE) para reducir el error de la red. El algoritmo de optimización utilizado será el descenso del gradiente. En este trabajo no se analizarán los resultados generados por la arquitectura de red neuronal propuesta; no son objeto de esta investigación los resultados del entrenamiento y el ajuste de la misma a partir de datos reales de funcionamiento de plantas de cemento, pues esta arquitectura de red será entrenada y ajustada en una fábrica de cemento española en una fase posterior de la investigación.

El mercado de la electricidad en España se organiza en una secuencia de mercados en los que la generación y demanda intercambian energía y reservas para distintos plazos (Tabla 11). Así aparecen distintos tipos de mercados -el de contratos bilaterales, el del día anterior y el intradiario-, así como distintos gestores -OMIP/OTC, y OMIE-.

TIEMPO	MERCADO	GESTOR	
Antes del despacho (antes D-1)	Contratos bilaterales	Organizado (OMIP)/ No organizado (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

Tabla 11: Secuencia de mercados en el mercado ibérico de electricidad (MIBEL). Fuente: Elaboración propia.

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). Existen dos tipos de mercados a plazo:

- El mercado organizado de futuros eléctricos gestionado por OMIP.
- El mercado no organizado de contratos bilaterales, conocido como OTC⁴.

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 (Energía y Sociedad, 2021).

En el mercado diario (precio spot), que como se ha indicado se celebra el día anterior al de la entrega de la energía, 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 esas 24 horas.

⁴ Mercado Over the Counter.

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 de la electricidad para cada hora del día siguiente (Figura 23).

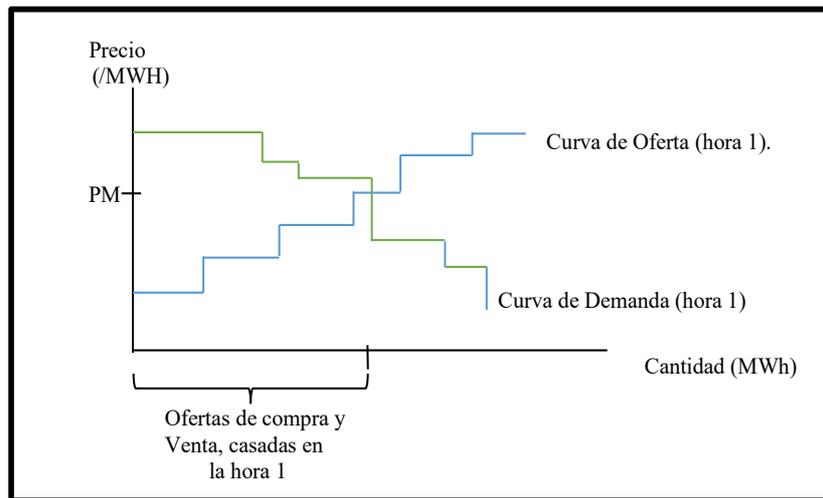


Figura 23. Curvas Oferta y Demanda de la electricidad del Mercado. Fuente: Elaboración propia.

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 cómo se van agregando las distintas ofertas de venta.

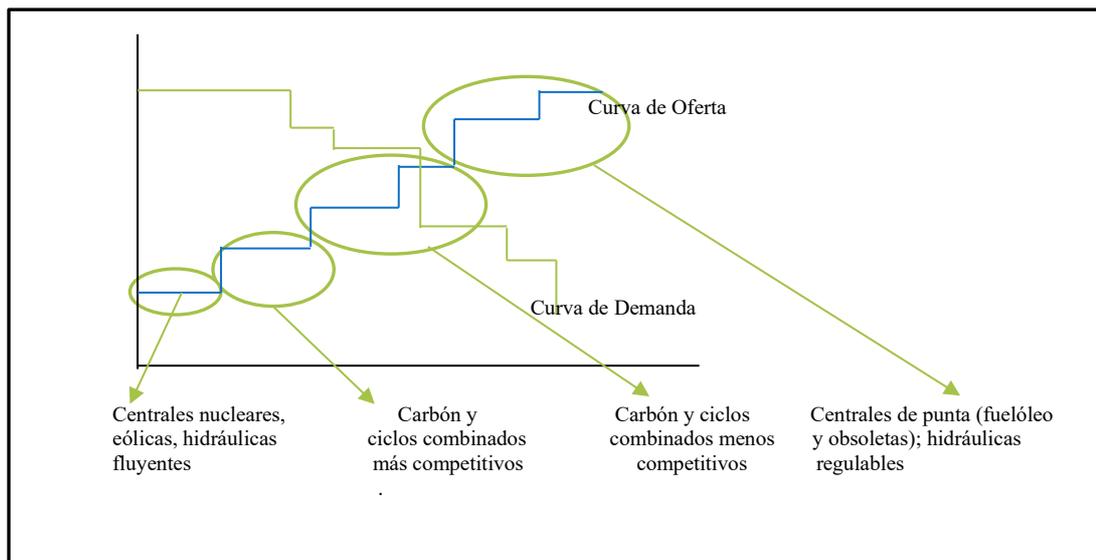


Figura 24. Curva de Oferta de la electricidad del mercado. Fuente: Elaboración propia.

Como aparece en la figura 24, 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 refleja 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 (Energía y Sociedad, 2021).

El funcionamiento de la demanda de electricidad es similar al de la oferta. Los consumidores finales se clasifican en dos 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, las condiciones meteorológicas y las ambientales. La curva de demanda de electricidad tendrá varios tramos (Figura 25).

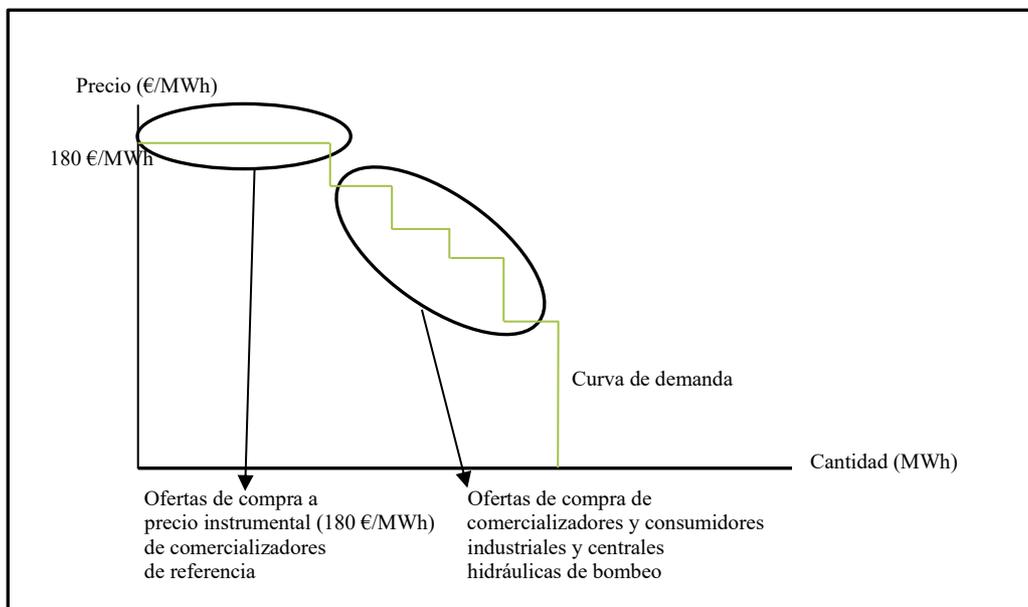


Figura 25: Curva de demanda de electricidad del mercado. Fuente: Elaboración Propia.

Hasta hace muy poco, los comercializadores de referencia solían ofertar al precio instrumental (precio máximo permitido) a 180 €/MWh, de manera que se aseguran de que

los consumidores -sus clientes-, dispondrán de la energía que demanden. Sin embargo, a partir del 6 de julio de 2021, ha entrado en vigor una medida tomada por la Comisión Nacional de los Mercados y la Competencia, en concordancia con la legislación europea, por la que el precio máximo queda fijado en 3.000 € y el mínimo en -500 €. Esto no quiere decir que finalmente se pague este precio, pues como se ha indicado, el mercado eléctrico es un mercado de precio marginalista, pero evidentemente deja el techo mucho más libre que en la situación anterior.

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 (Energía y Sociedad, 2021).

En el mercado a plazos se intercambia la energía para distintos periodos 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). Se trata de un mercado paralelo no organizado 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 y conocido 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 objetivo de esta investigación será intentar predecir, mediante el uso de redes neuronales artificiales, el comportamiento del precio spot de la electricidad, el cual desconocemos; es decir el precio del día D-1 para utilizarla el día D. Por otro lado, dado que el precio al que puedo adquirir hoy la energía, para utilizarla el día “D” a futuro, es conocido de antemano, se estará en disposición de decidir, en función de los precios spot obtenidos con las predicciones, a qué precio adquirir la energía.

Veamos el planteamiento con un ejemplo:

Fecha de hoy: 1 de octubre de 2020.

Necesito comprar electricidad para usarla el 1 de octubre de 2021 (D).

Se me presentan 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 Cal-2021. Este sería el precio al que puedo adquirir la electricidad hoy, para consumirla el 1 de octubre de 2021. Se trata de un precio a futuro conocido a fecha de hoy.

Como es lógico nos decidiremos por la opción que presente un precio menor.

A continuación, según se recoge en Energía y Sociedad, 2021, se analizará como se forma el precio spot del mercado diario de la electricidad:

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, a continuación 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. En términos puramente económicos, el precio esperado en el mercado diario (spot) constituye el coste de oportunidad del mercado a plazo (cal).

- Así, dado el coste de oportunidad del mercado futuro a plazo, será el precio esperado en el mercado diario (spot).

Por lo tanto, en la formación del precio de la electricidad, tanto a plazo como spot (día D-1), se han identificado distintos factores (Energía y Sociedad, 2021; Hurtado *et al.*, 2014; Khotanzad, 2018; Pezzutto *et al.*, 2018 y Zhang y Cheng, 2008), que pasaremos a analizar.

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 generar electricidad obligatoriamente (centrales hidroeléctricas que estén descargando), o bien 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 un precio alto, 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 y que más influyen en la formación 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 generan gases contaminantes a la atmósfera, pero sí residuos que deben ser depositados en vertederos especiales de manera controlada durante largos periodos de tiempo.

Presenta costes fijos bastante altos, pero sus costes variables son muy bajos, lo cual la hace muy competitiva. La introducción del EU Emission Trading System, para regular los derechos de emisión de CO₂, ha hecho que esta tecnología -que no emite CO₂- sea aun más competitiva. Sin embargo, a través de los Reales Decreto-ley 3/2006 y 11/2007 se eliminó, en gran medida, dicha mejora de competitividad. El precio depende, entre otros factores, de la meteorología.

3.2. Energía eólica. Se produce electricidad a través de la energía cinética del viento. Además de no emitir contaminantes no necesita de la compra de la energía primaria al aprovechar un recurso natural disponible. Uno de los mayores inconvenientes de la energía eólica 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.

La energía solar fotovoltaica es una fuente de energía renovable y limpia que utiliza la radiación solar para producir electricidad. Se basa en el llamado efecto fotoeléctrico, por el cual determinados materiales son capaces de absorber fotones (partículas lumínicas) y liberar electrones, generando una corriente eléctrica. Para ello, se emplea un dispositivo semiconductor denominado celda o célula fotovoltaica, que puede ser de silicio monocristalino, policristalino o amorfo, o bien otros materiales semiconductores de capa fina.

La energía termoeléctrica se basa en el aprovechamiento de la energía del sol para la obtención de energía eléctrica, mediante el calentamiento de un fluido y producción de vapor que impulsa una turbina en la que se genera la electricidad.

3.4. Cogeneración. Se trata de instalaciones que producen de manera simultánea energía eléctrica y térmica -vapor, agua caliente sanitaria, etc.-. Cuando además produce frío -aire o agua fría, hielo, etc.- recibe el nombre de trigeneración.

El método convencional de producción de energía en las centrales térmicas a partir de fuentes no renovables no es nada eficiente. En este tipo de procesos se utiliza un combustible fósil —petróleo, gas natural o carbón— como energía primaria, que se quema produciendo energía térmica. El calor generado se emplea para calentar agua y producir vapor que pone en marcha una turbina. Esta activa el generador dando así lugar a energía eléctrica.

En todo este proceso, una buena parte del calor empleado para hervir el agua, crear vapor y mover la turbina se pierde sin ningún uso más, por lo que el desperdicio de energía es significativo.

Una central de generación de electricidad convencional sólo aprovecha el 30-40% del total de la energía primaria que consume, mientras que una central de cogeneración aprovecha alrededor del 85-90% de toda la energía primaria empleada al generar calor y electricidad simultáneamente.

La cogeneración, por tanto, es un proceso eficiente que permite aprovechar el calor resultante del proceso de producir energía junto con la electricidad. Además, al producir la electricidad cerca del punto de consumo, se evitan cambios de tensión y transporte a larga distancia, que representan habitualmente una pérdida notable de energía. Se trata de una tecnología con costes bajos.

La energía primaria utilizada comúnmente para hacer funcionar las plantas de cogeneración es el gas natural, una fuente no renovable. Sin embargo, en la actualidad también pueden emplearse energías alternativas como la biomasa.

Como inconveniente podemos señalar su elevado coste de implementación debido a la complejidad de su tecnología.

Explicado el funcionamiento de las plantas de cogeneración, analizaremos a continuación las centrales hidráulicas. Estas, en general, aprovechan energía de una masa de agua situada en el cauce de un río o retenida en un embalse, convirtiéndola en energía eléctrica a través de un generador acoplado a una turbina. Se pueden distinguir tres tipos como veremos a continuación:

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, si 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, también 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. 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 (carbón, gas natural y fuelóleo). Como se explicó anteriormente, son tecnologías que se basa en generar vapor quemando un combustible fósil (carbón, gas o fuelóleo). El vapor generado mueve una turbina produciendo energía eléctrica. Estas centrales presentan un gran 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 que utilicen, costes variables altos o bajos. Cuando se usa carbón importado -que suele tener 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 (índice europeo API 2), paridad entre el € y el \$ y precio del CO₂ (hasta un 32 %).

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 CO₂ (hasta un 16% aproximadamente).

Esta tecnología tiene una alta eficiencia y además cuenta con la ventaja de ser poco contaminante. Se trata de una tecnología muy fiable, pero tiene como principal

inconveniente la dependencia de un combustible que proviene en gran parte de países con poca estabilidad política.

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, energía del mar, energía geotérmica, 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 resulta eficiente que en un mismo instante se pueda estar generando electricidad proveniente de distintas tecnologías.

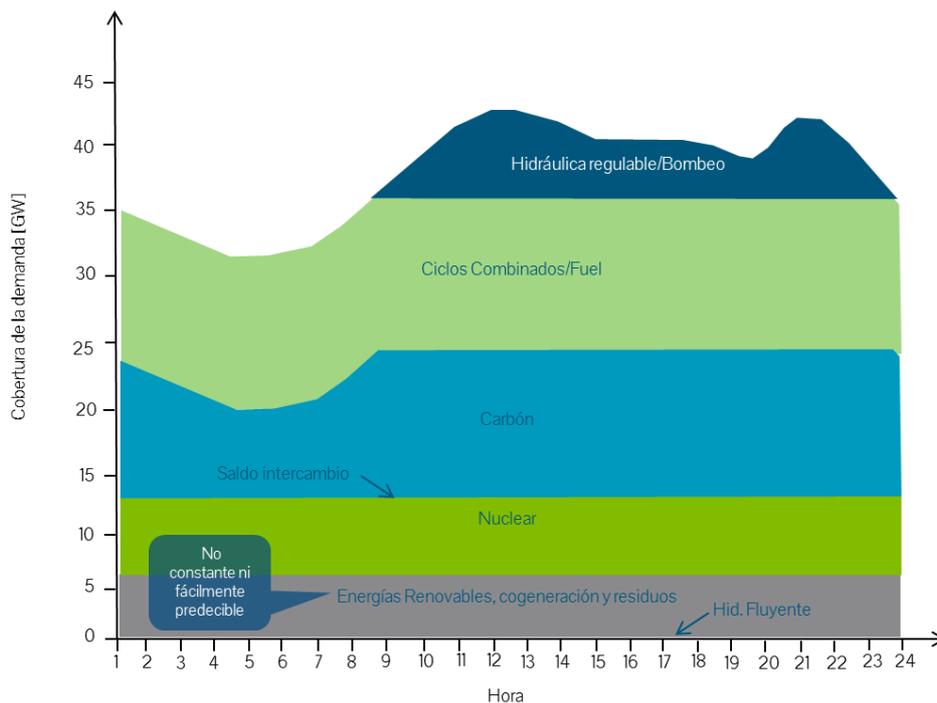


Figura 26: Cobertura de la curva de demanda horaria en un cierto día por las distintas tecnologías. Fuente: REE y Manual de la Energía (Energía y Sociedad).

En la figura 26 se observa cómo se podría ordenar la generación eléctrica de las distintas tecnologías, obviando la volatilidad de oferta y demanda, dado que la producción de renovables no es constante ni fácilmente predecible. Esta figura podría verse alterada

con la evolución que tenga en el futuro el mercado EU ETS. 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-, y ciclos combinados.
- Tecnologías intermedias. Presentan costes fijos y variables intermedios. Algunas centrales de carbón y ciclos combinados.
- Tecnologías punta. Tiene costes fijos bajos y variables altos. Encontramos las centrales de fuelóleo y centrales hidráulicas por bombeo.

En la figura 27 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 intermedia. Por último, para unas horas de funcionamiento esperadas al año mayores que B, la tecnología óptima es la de la base.

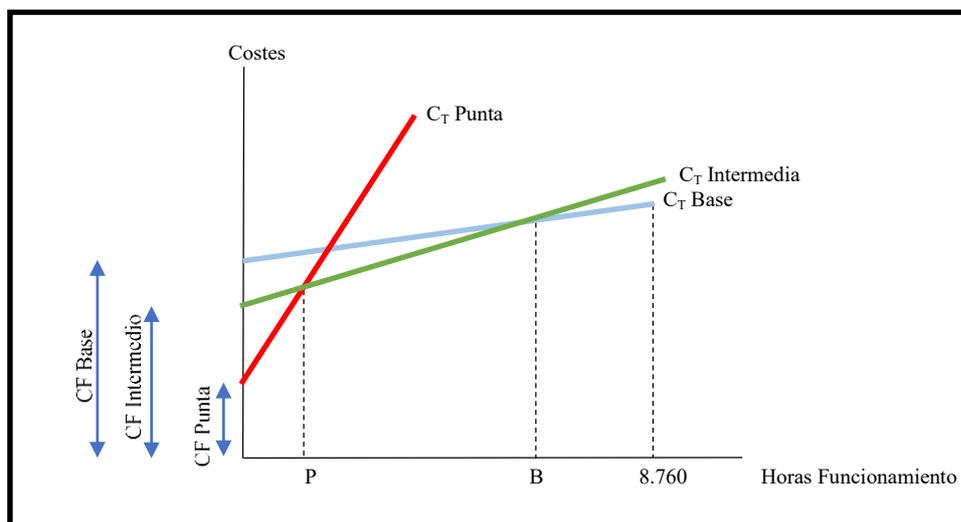


Figura 27: Uso óptimo de cada grupo de tecnologías en la generación eléctrica.

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.

La 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.

La utilización de la potencia instalada en centrales térmicas convencionales (carbón y fuelóleo) y ciclos combinados, depende de la producción de tecnologías renovables, nuclear e hidráulicas con embalses y de bombeo. La parte que no se cubre con las tecnologías renovables no gestionables y con la nuclear ha de ser cubierta mediante térmicas y ciclos combinados y recibe el nombre de “hueco térmico”. Estas tecnologías cierran los últimos precios. El coste de la electricidad generada por ellas 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 agosto principalmente-, la electricidad suele ser más cara.

7. Hay otro aspecto que incorporaremos al modelo y que afecta a la predicción del precio spot que se dará en el día D. Se trata de la relación entre los precios diarios máximo y mínimo de hoy (P1 y P6).

Para considerar la influencia del precio diario de hoy en la formación del precio spot, debemos tener en cuenta que para la industria electro intensiva existen los 6 precios

diferentes ya descritos (P1, P2, P3, P4, P5 y P6) que van teniendo valores decrecientes desde P1 a P6. Para nuestro modelo consideraremos el cociente entre el precio más alto (P1) y el más bajo (P6) en cada momento, es decir P1/P6 como referencia de la situación de los precios en cada momento.

A tal efecto se preparará una tabla (tabla 12) para la recogida de datos con los P1 y P6 de cada una de las 8760 horas del año. Incluiremos una fila más que relacionará el P1 (precio más alto del día), con el P6 (precio más bajo del día), a través del cociente P1/P6.

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
Pr1	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
Pr6	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
Pr1/Pr6	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

Tabla 12: Precios diarios para el mes de enero del año “N” y cociente P1/ P6. Fuente: Elaboración propia.

En nuestro modelo utilizaremos una función de base para la red neuronal, con objeto de evaluar el precio spot y el efecto que en el mismo tienen el precio diario (P1 y P6) de cada hora del año (tabla 12), combinado con el precio a futuro y con el resto de las variables analizadas anteriormente: mix energético, variables de entrada (entre ellas las meteorológicas), laboralidad y estacionalidad (Parejo *et al.*, 2021).

$$\text{Precio Spot} = F(\text{P1/P6}, \text{Precio Cal-X}, \text{mix energético}, \text{variables de entrada}, \text{laboralidad}, \text{estacionalidad}) * \omega_{is}$$

Donde “ ω_{is} ” son los distintos pesos de los 14 factores que afectan al Precio Spot (S), siendo $i=1, \dots, 14$. $\sum \omega_{is}=1$.

En la figura 28 se plantea la arquitectura de Red Neuronal Artificial que servirá para alcanzar nuestro objetivo, que será analizar y predecir la formación del precio spot. Para ello seguiremos los siguientes pasos:

- a. Determinar como afecta el mix energético (neuronas color verde), la laboralidad (neurona roja) y la estacionalidad (neurona amarilla), al precio futuro (neurona morada). 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 ω_{ij} que afectan a estas variables. Hemos de tener en cuenta en esta ocasión que $\sum \omega_{iF}=1. \quad \forall i= 1, \dots, 12.$

b. Determinar como afecta el mix energético (neuronas color verde), la laboralidad (neurona roja) y la estacionalidad (neurona amarilla), el cociente P1/P6 (neurona azul) y el precio futuro (neurona morada) 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 ω_{ij} que afectan a estas variables. Hemos de tener en cuenta en esta ocasión que $\sum \omega_{iS}=1. \quad \forall i= 1, \dots, 14.$

Una vez que el sistema conozca como afecta cada una de las 21 variables (7 neuronas blancas, 10 verdes, 1 roja, 1 amarilla, 1 morada y 1 azul) al Precio Spot, mediante aprendizaje -Deep learning-, estaremos en disposición de realizar predicciones sobre el comportamiento de los precios, que nos permitirán decidir si deberíamos comprar la electricidad a precio spot (más adelante, justo el día anterior a su uso) o futuro en el día de hoy. Si la red neuronal predijera que el precio Spot del día D-1 será mayor que el precio futuro que se da hoy, se adquirirá hoy la electricidad en el mercado de futuros.

Tras el entrenamiento de la red obtendremos un modelo fiable de predicción de precios.

Para seleccionar como herramientas de IA más idóneas la ANN -*Multilayer Perceptron*- y el algoritmo Backpropagation, así como las distintas variables que se han utilizado para alimentar la red, tal y como aparece en la figura 26, se ha tenido en cuenta la información recabada en el análisis sistemático de la literatura llevado a cabo. Los artículos consultados hacen referencia expresa a variables tales como la meteorología, la laboralidad y el mix energético, entre otros. Por otro lado, 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 (Parejo *et al.*, 2021).

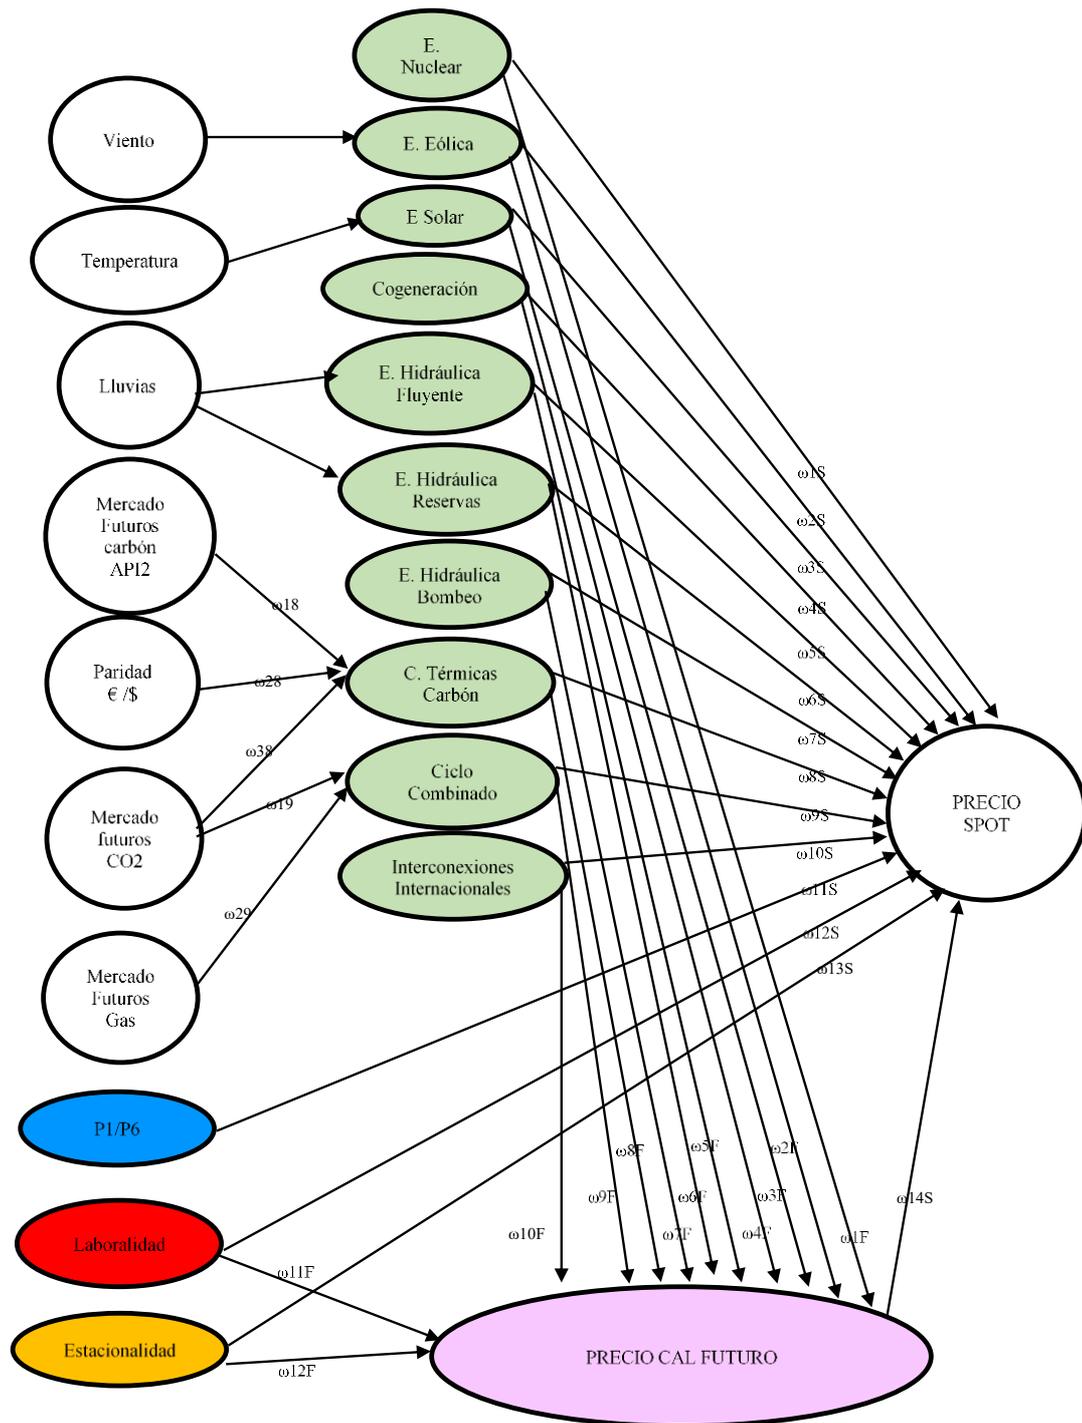


Figura 28. Red Neuronal para determinar el precio eléctrico spot y futuro. Fuente: Elaboración Propia.

Capítulo 6. CONCLUSIONES, DISCUSIÓN DE RESULTADOS Y LÍNEAS FUTURAS DE INVESTIGACIÓN.

6.1. Introducción.

Tras el desarrollo del modelo de optimización de costes eléctricos diseñado en los capítulos 4 y 5, se ofrecen en este apartado las conclusiones más importantes a las que se ha llegado tras el proceso de investigación.

A continuación, se abordarán las implicaciones más importantes de la investigación, tanto para la práctica empresarial como para el ámbito académico.

En este sexto capítulo también se analizará la innovación que aportará el modelo desarrollado, así como las posibilidades que se abren de cara a futuras de investigaciones. Por último, se expondrán aquellos cambios normativos que han tenido lugar recientemente y que podrían incidir, de una u otra manera, en nuestro modelo.

6.2. Conclusiones.

De la investigación realizada se pueden extraer las siguientes conclusiones:

1.-Con el modelo desarrollado se puede optimizar el consumo eléctrico de las fábricas de cemento, y con ello el coste, influyendo sobre determinadas variables del proceso productivo, pero incurriendo en inversiones y/o costes nulos o muy bajos. Para ello hemos hecho uso de una arquitectura de ANN que nos ayudará a obtener la combinación óptima de estas variables que minimizan el consumo eléctrico del proceso productivo. En este caso estamos incidiendo sobre la eficiencia eléctrica.

2.- También es posible reducir el coste eléctrico optimizando los costes eléctricos regulados, es decir, trasladando el uso de los equipos de fábrica con mayor consumo eléctrico, a periodos con costes eléctricos regulados más bajos. Para ello se ha planteado un sistema de ecuaciones de consumo eléctrico para cada fase crítica del proceso productivo de fabricación de cemento, que tendrá en cuenta cada uno de los periodos P_i . A su vez, se ha de considerar que el sistema debería tener en cuenta todo tipo de restricciones: de producción, almacenamiento, ventas, existencia de materias primas, etc.

Mediante el uso de algoritmos genéticos de optimización, que tengan en cuenta todas las cuestiones antes indicadas, se trasladará el consumo eléctrico de estas fases críticas a los Pi de menos coste, optimizando así el coste eléctrico del proceso.

3.- Es posible reducir 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 IA tales como las ANN. Dado que conocemos el precio a futuro al que podemos adquirir hoy la electricidad para utilizarla el día D, nuestro objetivo será apoyarnos en las redes neuronales para intentar predecir el precio Spot (día D-1) de la electricidad. De esta manera estaríamos en disposición de decidir la mejor opción desde el punto de vista económico: comprar hoy a futuro o bien esperar al precio spot (desconocido) el día D-1.

4.- Considerando estos tres aspectos, se ha desarrollado un modelo basado en IA, que podría contribuir de manera global a mejorar los niveles de ahorro en el coste eléctrico, al combinar simultáneamente los tres aspectos expuestos en las conclusiones (1, 2 y 3). De esta manera se contribuiría de manera decidida, a mejorar la situación pérdida de competitividad por la que pasa la industria cementera en un país como España.

5.- El modelo que resulta de este proceso de investigación es aplicable a cualquier fábrica de cemento del mundo (de vía seca); además, modificando los parámetros iniciales, podía también aplicarse a otras industrias de transformación electro intensivas. Se trata por lo tanto de un modelo que cuenta con gran versatilidad.

6.3. Implicaciones de la investigación para la práctica empresarial.

En este apartado se argumentan las implicaciones que nuestra investigación tendrá para la práctica empresarial. Para ello analizaremos tanto las implicaciones que tienen origen en la revisión sistemática de la literatura, como las implicaciones y resultados obtenidos mediante las consultas a los expertos sectoriales.

A) Revisión Sistemática de la Literatura. Los resultados del análisis de contenidos se exponen a continuación:

1. Se han determinado los algoritmos y herramientas de IA disponibles para la optimización del consumo eléctrico en cementeras (Georgilakis, 2007; Azadeh *et al.*,

2015; Hurtado *et al.*, 2014 y Zhan, y Cheng, 2008). Estas herramientas han sido tratadas con mayor grado de detalle en los apartados 2.5. y 2.6.

Los modelos de ANN multicapa de perceptrón resultan de gran utilidad para predecir los precios futuros diarios de la electricidad. Además de las ANN, en nuestro modelo haremos uso de los algoritmos genéticos a la hora de optimizar los costes eléctricos regulados.

De esta manera se da cumplimiento al subobjetivo 3 planteado en el apartado 1.4. de esta tesis doctoral.

2. Se han establecido los factores que podrían contribuir de forma más relevante en la composición del precio de la energía (Castillo, 1997 e IpsomManager, 2019). Este aspecto será clave para avanzar en la investigación pues será un input fundamental para cualquier modelo de IA de predicción de precios (Khotanzad, 2018; Zhang y Cheng, 2008 y Hurtado *et al.*, 2014). En el capítulo 5, dedicado a la optimización del coste eléctrico del mercado, se hizo uso de esta información.

Así, la meteorología juega un papel fundamental para predecir precios futuros. Igualmente, el porfolio de generación eléctrica supone otra importante variable que afecta al precio diario de la electricidad.

Se da cumplimiento al subobjetivo 4 planteado en el apartado 1.4.

3. La bibliografía previa señala que se puede reducir la factura eléctrica operando sobre las variables de proceso de dos maneras fundamentalmente:

- Controlando los distintos factores que influyen en la molienda y de aquellas otras fases de mayor consumo, sin incurrir en grandes costes e inversiones, es decir, actuando sobre la eficiencia eléctrica (subobjetivo 5 del apartado 1.4.).

- Reduciendo el consumo de electricidad durante los periodos más caros, trasladándolo a los momentos diarios más económicos. Es decir, se estaría actuando sobre la gestión eléctrica.

4. Se ha llevado a cabo una comparativa del precio eléctrico de la industria electrointensiva española (20.000-150.000 MWh) con la europea, con datos extraídos de la Oficina Europea de Estadística -Eurostat, concluyendo que España presenta uno de los costes eléctricos más altos de la UE.

B) Consultas a expertos sectoriales: En este apartado analizaremos los resultados y las implicaciones para la práctica empresarial que se han obtenido de las consultas realizadas a los expertos:

1. Se ha concluido (capítulo 3) que las fábricas españolas son más eficientes que la media europea en términos de kWh por tonelada de cemento producida. Como ya se indicó, en Europa se consumen de media 126 kWh por tonelada de cemento producida (datos de 2016, 2017 y 2018) (GCCA Association, 2020), mientras que en España, según datos aportados por OFICEMEN, se consumen 119,9 kWh por tonelada de cemento producida

2. Se ha desarrollado una metodología para el cálculo del precio eléctrico de la industria cementera, que se detalla en el capítulo 4.3, en la que se contemplan los costes eléctricos regulados del sector. La información utilizada se ha recogido a través de encuestas y cuestionarios realizados a los responsables de las empresas cementeras que operan en España; también se han tenido en cuenta los precios de la electricidad en España que aporta OMIE.

3. Como se expone en el apartado 4.3., se han obtenido datos sobre el porcentaje de uso de la potencia eléctrica contratada en los distintos periodos de coste de la electricidad (información cuantitativa). Esta información, de gran utilidad a la hora de analizar los costes eléctricos regulados, ha sido proporcionada mediante las encuestas a expertos.

4. Los expertos también han aportado datos eléctricos de modulación del consumo para 2018 (información cuantitativa). Al igual que en el apartado anterior, se han tenido en cuenta como parámetros los 6 periodos distintos de consumo eléctrico que operan en España (P1, ...P6). Esta información resultará de utilidad para nuestra tesis doctoral, a la hora de desplazar el consumo eléctrico a los periodos más económicos. Esta cuestión ha sido objeto de estudio en el capítulo 4.3.

5. Los expertos han contribuido a determinar las variables del proceso más críticas y significativas, sobre las que se puede incidir de manera sencilla y sin incurrir en altos costes ni montantes de inversión, para conseguir reducciones en el consumo eléctrico de los equipos. La herramienta de IA más adecuada para ello son las ANN. Este aspecto ha sido abordado en el capítulo 4.

6. Para reducir el coste eléctrico, desplazando el consumo a días y horas en los que el precio sea inferior (P_6 , P_5 , etc.), se pueden utilizar herramientas de optimización de IA, tipo algoritmos genéticos. Estos parten de una población inicial de individuos que se codifica mediante una representación genética formada por cromosomas. Esta población va evolucionando y solo van sobreviviendo las soluciones que más se acercan a la óptima (Michalewicz, 1999). Esta cuestión se aborda en el capítulo 4.

7. El panel de expertos también nos ha proporcionado información acerca de aquellos factores que más influyen en el consumo eléctrico en cada fase del proceso de fabricación de cemento, tal y como quedó recogido en el apartado 4.2.

8. Los expertos concluyen que es posible reducir los costes eléctricos de una fábrica de cemento optimizando la compra de la energía. Para ello se pueden utilizar técnicas de IA, basadas en algoritmos de entrenamiento especiales y ANN. Estas resultan muy útiles a la hora de predecir precios de compra de la electricidad. Este aspecto ha sido abordado en el capítulo 5.

9. Los precios diarios de electricidad y los precios del mercado de futuros son variables de entrada que resultan útiles para predecir los precios eléctricos en el mercado. Para ello pueden emplearse modelos de ANN. Esta cuestión del modelo de optimización ha sido analizada en el apartado 5.2.

10. Existen otros factores, como la meteorología y el mix energético, que afectan igualmente al precio de la electricidad. Este aspecto también ha sido abordado en el apartado 5.4.

11. En cuanto al análisis de las herramientas de IA para optimizar el consumo eléctrico optimizando la compra de electricidad, con el panel de expertos se ha llegado a la misma conclusión que con el análisis sistemático de la literatura. Las ANN multicapa perceptrón resultan de interés a la hora de predecir los precios diarios de la electricidad. Para ello resulta fundamental elegir adecuadamente los factores que tendrán mayor influencia en la formación del precio de la electricidad (Pérez, 2007).

6.4. Implicaciones de la Investigación para el ámbito académico.

En este apartado analizaremos las implicaciones que nuestra investigación tendrá en el ámbito académico. Para ello, al igual que en el apartado anterior, analizaremos tanto las implicaciones que tienen origen en la revisión sistemática de la literatura, como las implicaciones y resultados obtenidos mediante las consultas a los expertos sectoriales.

A) Revisión sistemática de la literatura. La mayoría de las implicaciones y conclusiones, son aspectos bibliométricos que podrían resultar de utilidad para futuras consultas de otras investigaciones académicas. Han sido las siguientes:

1. El 28,57 % de los artículos analizados trataban el tema del ahorro energético de manera global, es decir, que se referían no sólo a la energía eléctrica, sino también a la energía térmica de los hornos de las cementeras.

2. El 7,14 % de los artículos analizados abordaban la optimización del coste eléctrico mediante el uso de la IA.

3. El 42,85 % de los artículos analizados abordaban la predicción del coste eléctrico mediante el uso de la IA.

4. Todos los artículos analizados se publicaron entre 2001 y 2020.

5. La mayor parte de estos artículos son firmados por un único autor y se enfocan a la mejora u optimización de procesos.

6. Las universidades o instituciones donde se llevan a cabo las distintas investigaciones recogidas en los artículos están repartidas por todo el mundo: Europa, Asia, América del Norte, América del Sur, África y Australia.

7. Las revistas de publicación de los artículos seleccionados son muy variadas: hasta un total de 13.

8. En la mayor parte de los casos (en el 79% de ellos), se lleva a cabo un tipo de investigación empírica.

9. Esta investigación ha sido pionera a la hora de combinar en un mismo modelo de IA, la minimización del coste eléctrico operando sobre variables de proceso con la gestión de compra de electricidad. Este hecho no se da en ninguno de los trabajos previos analizados.

B) Consultas a expertos sectoriales. Procedemos a analizar los resultados y las implicaciones de carácter académico que se han obtenido de las consultas realizadas a los expertos. Cabe indicar que se trata de dos resultados que ya se han expuesto en el

apartado de “Implicaciones para la práctica empresarial con origen en las consultas a expertos”. No obstante, volvemos a traerlos a este apartado, dadas sus implicaciones y utilidad desde el punto de vista académico.

1. Metodología para el cálculo del coste eléctrico de la industria cementera. Esta metodología, tanto desde un punto de vista cuantitativo, como cualitativo, resultará de utilidad para futuras investigaciones de tipo académico que aborden este tipo de cuestiones.

2. Comparativa del precio eléctrico de la industria electro intensiva española (20.000-150.000 MW) con la europea, concluyendo que España presenta uno de los costes eléctricos más altos de la UE. Las conclusiones extraídas de esta comparativa resultarán de interés para consultas que pudieran llevar a cabo otros investigadores, que analicen la situación del precio eléctrico de la industria electro intensiva.

6.5. Innovación introducida y líneas futuras de investigación.

La innovación más importante que se introduce con esta investigación es el hecho de conjugar dentro de nuestro modelo los tres aspectos expuestos en los capítulos 4 y 5, a la hora de atajar el problema planteado de “optimizar el coste eléctrico de una fábrica de cemento” utilizando AI. Se han encontrado algunos artículos en los que se abordan estas 3 cuestiones, pero siempre de manera parcial y aislada y nunca de manera integrada. El hecho de incidir de manera simultánea en estas tres cuestiones contribuye a proporcionarnos el resultado más importante de este proceso de investigación. Adicionando los ahorros eléctricos correspondientes a cada uno de los tres aspectos abordados, se pueden alcanzar reducciones de costes más importantes que las alcanzadas con otras investigaciones anteriores que abordan el problema de manera parcial.

Además de esto, con el modelo podemos obtener información cualitativa, acerca de la contribución de cada uno de los tres aspectos analizados al ahorro eléctrico en la planta.

Por otro lado, nuestro proceso de investigación se ha basado en un análisis profundo de dos fuentes de información complementarias que han aportado gran solvencia. El análisis sistemático de la literatura ha sido complementado con consultas a expertos (tanto cuestionarios para obtener información cuantitativa, como un panel de

expertos orientado fundamentalmente a obtener información cualitativa). No se han encontrado en la literatura previa analizada, otras investigaciones sobre esta materia en las que la bibliografía se haya complementado con consultas a expertos, lo cual resulta completamente innovador.

También resulta innovador el hecho de que la metodología obtenida tras el proceso de investigación resulte de utilidad de cara a la optimización del coste eléctrico en cualquier fábrica de cemento del mundo (de vía seca), pues el proceso productivo es el mismo que el seguido en la fábrica de Málaga. Además, introduciendo ciertas modificaciones en los parámetros iniciales, el modelo sería perfectamente aplicable a otras industrias de transformación electro intensivas.

Por otro lado, también cabe destacar que el estudio cuantitativo de los parámetros/componentes que intervienen en la formación del precio eléctrico regulado de la industria cementera española, referido al 100% de las plantas de fabricación de cemento de España y que se ha presentado en este trabajo, también resulta totalmente innovador y novedoso. Según se indica desde la Agrupación de Fabricantes de cemento de España, -OFICEMEN- no se había publicado con anterioridad ningún estudio de este tipo.

En cuanto a las futuras líneas de investigación, cabe destacar que la fase siguiente de este trabajo vendrá marcada por el entrenamiento y ajuste de las distintas herramientas propuestas -arquitecturas de redes neuronales y algoritmos genéticos- a partir de datos reales de funcionamiento en una fábrica de cemento. En este sentido, se está llevando a cabo la planificación de un proyecto piloto experimental en una planta cementera situada en Andalucía y perteneciente a una empresa multinacional asociada a OFICEMEN. Este proyecto requerirá de presencia de personal propio de la empresa en planta -de manera discontinua-, así como de seguimiento remoto VPN. Se calcula que la duración de esta fase experimental en planta será de entre 6 y 12 meses, desde el comienzo de la misma. De forma resumida, se puede indicar que las fases del proceso implicaran: (a) Aproximación al proceso: caso base de partida; (b) Definición y codificación de la algoritmia; (c) Implantación en el servidor; (d) Verificación y readaptación del modelo y entrenamiento inicial; (e) Seguimiento y validación de resultados; (f) Estimación de ahorros del coste eléctrico.

Por otro lado, los resultados presentados en este documento serán de utilidad para futuros investigadores, dado que el modelo es perfectamente reproducible en otro tipo de industrias electro intensivas. Se abre así una interesante línea de investigación con la aplicación a otros sectores y la comparación intersectorial.

6.6. Consideraciones finales: cambios normativos.

Durante el desarrollo de esta tesis doctoral, han tenido lugar ciertos cambios normativos relativos al mercado eléctrico, que merecen ser señalados, pues afectan en cierta medida a aspectos que han sido abordados en el desarrollo de nuestro modelo y a otros componentes del coste eléctrico de la industria electro intensiva. En concreto:

A. Estatuto de Electointensivos.

Se recoge en el RD 1106/2020 de 15 de diciembre. El objetivo del mismo es mejorar la competitividad de la gran industria y favorecer a su vez la inversión industrial. Esta norma supone el primer paso para corregir la desventaja competitiva de España frente a otros países de la UE. Existen ciertos requisitos para poderse acoger al mismo. Destacan, entre otros:

- Solo pueden acogerse ciertos CNAEs que indica la norma: acero, aluminio, papel, química, cemento, etc.
- Hay que certificar un consumo de al menos 1 GW, dos de los 3 años anteriores a su solicitud.
- El consumo en horas valle debe ser al menos el 50 % del total.

Además de esto hay que cumplir ciertos compromisos, en materia de:

- I+D+i.
- Sustitución de fuentes contaminantes.
- Mantenimiento del empleo y de la actividad productiva (al menos 3 años).
- Gestión de la energía y eficiencia energética.

Entre los mecanismos de apoyo del Estatuto de Electrointensivos, destinados a reducir los costes energéticos figuran los siguientes:

- Compensación de ciertos cargos repercutidos en los costes eléctricos.

Se pueden llegar a compensar hasta el 85 % de los costes relacionados con energías renovables, cogeneración de alta eficiencia y el extra coste correspondiente a los territorios no peninsulares (TNP) y que hayan sido repercutidos al precio.

- Fondo Español de Reserva para la Garantía de entidades Electrointensivas (FERGEI).

Se trata de un mecanismo de cobertura, que funciona a través de Agencia Española del Crédito a la Exportación (CESCE), para la obtención de riesgos derivados de la adquisición de electricidad a M/P y L/P.

- Compensación de Costes indirectos por emisión de GEIs.

B. Reserva Estratégica para la Respuesta Rápida.

En julio de 2020, el servicio de interrumpibilidad de la industria electro intensiva se sustituyó por este mecanismo de “Reserva Estratégica para la Respuesta Rápida”, que en estos momentos se encuentra en desarrollo. Este cambio resulta fundamental para el futuro del coste eléctrico de todas las industrias electro intensivas, pues afecta al mismo de manera directa, por lo que habrá que estar muy atentos a su desarrollo.

El objetivo del mismo es resolver con la máxima eficacia los desvíos entre la generación y el consumo que tengan lugar una vez cerrado el mercado intradiario.

La asignación de bloques tiene lugar mediante subasta. En las mismas, los bloques mínimos de participación se han bajado desde los 5 MW a 1 MW.

C. Fondo Nacional para la Sostenibilidad del Sistema.

Actualmente (junio de 2021), se encuentra en fase de consulta en el consejo de estado. Su finalidad es crear un fondo para financiar políticas de fomento de energías renovables, cogeneración y valorización de residuos. Este tipo de actuaciones,

encaminadas a fomentar ciertas energías, podrían influir en un futuro en el mix energético y, por tanto, en el modelo de trabajo desarrollado en esta tesis.

V. Referencias Bibliográficas

AEMET, (2019). Recuperada de: <https://datosclima.es/index.htm>

Aggarwal, S.K; Saini, L.M y Kumar, A, (2009). Electricity price forecasting in deregulated markets: A review and evaluation. *International Journal of Electrical Power & Energy Systems*. 31 (1), pp.13-22.

AleaSoft Energy Forecasting. Mercados Eléctricos Europeos (2021). Resolución de 6 de mayo de 2021, de la Comisión Nacional de los Mercados y la Competencia, por la que se aprueban las reglas de funcionamiento de los mercados diario e intradiario de energía eléctrica para su adaptación de los límites de oferta a los límites de casación europeos. <https://aleasoft.com/es/octubre-2021-mes-precios-mas-altos-historia-mercados-electricos-europeos/>

Alfalla-Luque, R., Medina-Lopez, C y Dey, P.K., (2013) Supply chain integration framework using literature review, *Production Planning & Control: The Management of Operations*, 24, pp. 8-9, 800-817, DOI: 10.1080/09537287.2012.666870.

Ali, U., Buccella, C. y Cecati, C., (2016). Households Electricity Consumption Analysis with Data Mining Techniques, *IEEE IECON*, pp. 3966 - 3971.

Alonso, A.M., Bastos, G. y García-Martos, C., (2016). Electricity price forecasting by averaging dynamic factor models. 9 (600). (ISSN: 19961073).

Andrés, C. y Maheut, J., (2020). Secuenciación con almacenes limitados. Una revisión de la literatura]. *Dirección y Organización*, 64, pp. 5-35.

Andrew, N., (2017) Artificial Intelligence is the New Electricity. *Newstex Global Business Blogs*.

Andrew, Ng. y Zhang, T., (2017). The Optimistic Promise of Artificial Intelligence; how AI is going to be like electricity, transforming every industry. *Wall Street Journal online*-Junio 2017 (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* 78 (9-12), pp. 1691-1703 (ISSN: 1443-3015).

Barbosa, M., y Grayson, D., (2009). Site visits: Assessing and improving the climate for women in physics. In Harline, B. K., Horton, K. R., y Kaicher, C. M. (Eds.), *AIP conference proceedings*. 1119, pp. 14–15. American Institute of Physics doi:10.1063/1.3137748.

Barlow, M., (2015). *Learning to Love Data Science. Exploring Predictive Analytics, Machine Learning, Digital Manufacturing and Supply Chain Optimization*. United States of America.

Bello, A., Renses, J. y Muñoz, A., (2016). Previsión probabilística a medio plazo de precios extremadamente bajos en los mercados de la electricidad: aplicación al caso español. *Energies*, 9 (3), 193.

Bramer, M., (2007). *Principles of Data Mining*, London: Springer, (Marzo, 2007).

Bulter, L. y McAllister, I., (2011). Evaluating university research performance using metrics. *European Political Science*, 10 (1), pp. 44–58.

Carmona, E., (2014). “Tutorial sobre Máquinas de Vectores Soporte (SVM),” Universidad Nacional de Educación a Distancia (UNED), Madrid, 2014.

Carpio, J., Juan, J y López, D., (2014). Modelo de factor dinámico y suavizado exponencial multivariante aplicado al análisis de precios de electricidad por hora. *Technometrics* 2014, 56, pp. 494–503.

Castañón, A.M., García-Granda, S., Guerrero, A., Lorenzo, M.P. y Angulo, S., (2014). Energy and environmental savings via optimisation of the production process at a Spanish cement Factory, *Journal of Cleaner Production Elsevier*, 98, pp. 47-52. (ISSN: 0959-6526).

Castillo, E., Gutiérrez, J.M. y Hedy, A.S., (1997). *Sistemas Expertos y Modelos de Redes Probabilísticas*. Academia de Ingeniería.

Catalão, J. P. S., Mariano, S. J. P. S., Mendes, V. M. F. y Ferreira, L. A. F. M., (2007). Previsión de precios de electricidad a corto plazo en un mercado competitivo: un enfoque de red neuronal. *Electr. Power Syst. Res*, 77, pp. 1297–1304.

Cerjan, M., Matijaš, M. y Delimar, M., (2014). Modelo híbrido dinámico para pronósticos de precios de electricidad a corto plazo. *Energies*, 7, pp. 3304–3318.

Cheng, C., Luo, B.; Miao, S. y Wu, X., (2016). Mid-term electricity market clearing price forecasting with sparse data: A case in newly-reformed Yunnan electricity market. *Energies*, 9 (10), 804.

Chicco, G., Napoli, R., Piglion, F. y otros, (2016). Comparisons Among Clustering Techniques for Electricity Customer Classification, *IEEE Transactions on Power Systems*, 21, (2), pp. 933-940.

Comisión Nacional de los Mercados y la Competencia (2021). Resolución de 6 de mayo de 2021, de la Comisión Nacional de los Mercados y la Competencia, por la que se aprueban las reglas de funcionamiento de los mercados diario e intradiario de energía eléctrica para su adaptación de los límites de oferta a los límites de casación europeos.

Committee on Science, Engineering and Public Policy, National Academy of Sciences, National Academy of Engineering, Institute of Medicine Policy and Global Affairs, (2001). *Implementing the government performance and results act for research: A status report*. Washington, DC: National Academy Press. Retrieved from the National Academies Press website: <http://www.nap.edu/catalog/10106.html>.

Conejo, A.J., Plazas, M.A., Espínola, R. y Molina, A.B., (2005). Previsión de precios de la electricidad para el día con los modelos Wavelet Transform y ARIMA. *IEEE Trans. Power Syst.*, 20, pp. 1035-1042.

Consejo de Reguladores del MIBEL, (2019). Estudio comparativo de los precios MIBEL (contado y plazo) con otros mercados europeos y su relación con el mercado único.

Contreras, J., Espínola, R., Nogales, F.J y Conejo, A.J., (2003). Modelos AJ ARIMA para predecir los precios de la electricidad al día siguiente. *IEEE Trans. Power Syst.* 18, pp. 1014-1020.

Coryn, C. L. C. y Scriven, M., (2008). Vol. Eds. Reforming the evaluation of research. New directions for evaluation, 118, pp. 89-105. California: Jossey-Bass.

Cronin, P., Ryan, F., y Coughlan, M., (2008). Undertaking a literature review: A step-by-step approach. *British Journal of Nursing*, 17 (1), pp. 38–43.

Cuaresma, J.C, Hlouskova, J., Kossmeier, S. y Obersteiner, M., (2004). Pronóstico de precios spot de electricidad utilizando modelos lineales univariados de series temporales. *Appl. Energy* 77, pp. 87-106.

Curbelo, A. D., Municio, Á.M.G. y 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.

Elo, S. y Kyngas, H. (2007). The qualitative content analysis process. *Journal of Advanced Nursing*, 62 (1), pp. 107–115. doi:10.1111/j.1365-2648.2007 .04569.

Energía y Sociedad, (2021). <http://www.energiaysociedad.es/manenergia/manual-de-la-energia/>

European Union, (2020), https://ec.europa.eu/clima/policies/ets_es .

Eurostat, (2019). Estadísticas de precios eléctricos de Eurostat. <https://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do>).

Eurostat (2021). Estadísticas de precios eléctricos de Eurostat. https://ec.europa.eu/eurostat/databrowser/view/NRG_PC_205__custom_1489539/default/table?lang=en

Fabbe-Costes, N., Jahre, M., y Roussat, C., (2009). Supply chain integration: the role of logistics service providers. *International Journal of Productivity and Performance Management*, 58 (1), pp. 71-91.

Filho, J.R., Gontijo, E.M., Delaiba, A.C., Mazina, E., Cabral, J.E. y Pinto, J.O.P., (2004). Fraud identification in electricity company customers using Decision Tree, *IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583)*, 2004, (4) pp. 3730-3734, doi: 10.1109/ICSMC.2004.1400924.

Frishammar, J., Kurkkio, M., Abrahamsson, L., y Lichtenthaler, U., (2012). Antecedents and consequences of firms' process innovation capability: A literature review and a conceptual framework. *IEEE Transactions on Engineering Management*, 59 (4), pp. 519-529.

Fundación CEMA, (2020). Documento sobre Valorización. <https://www.fundacioncema.org/valorizacion/> (2020).

Fundación Laboral Andaluza del Cemento y el Medio Ambiente (FLACEMA), (2018). Memoria de Sostenibilidad del Sector Cementero Andaluz (2016-17). http://www.flacema.org/images/stories/memorias/MEMORIA_FLACEMA_2017_WEB.pdf

García, S., Luengo, J. y Herrera, F., (2015). *Data Preprocessing in Data Mining*. Berlín, Alemania, 2015

García, S., Ramírez-Gallego, S., Luengo, J. y Herrera, F., (2016). *Big Data Reprocesamiento y Calidad de Datos*. España. Big Data Monografía, 2016.

GCCA Association, (2020). <https://gccassociation.org/>

Georgilakis, P. S., (2007). Artificial intelligence solution to electricity price forecasting problem. *Applied Artificial Intelligence*. 21 (8), pp. 707-727. (ISSN 0883-9514).

Gilvonio, L. R. y Inche, J. L., (2005). *El Ahorro de Energía en la Industria Cementera como Estrategia de la Excelencia Operativa* (Tesis doctoral). Universidad Mayor de San Marcos, Lima, Perú.

Goiner, (2021). [https://www.goiner.com/nuevas-tarifas-electricas-para-empresas__trashed/tarifas-6-xtd/-](https://www.goiner.com/nuevas-tarifas-electricas-para-empresas__trashed/tarifas-6-xtd/)

González, V., Contreras, J. y Bunn, D.W., (2012). Pronosticando precios de energía usando un modelo híbrido Fundamental-Económico *IEEE Trans. Power Syst.*, 27, pp. 363–372.

Haben, S., Singleton, C. y Grindrod, P., (2016). “Analysis and Clustering of Residential Customers Energy Behavioral Demand Using Smart Meter Data,” *IEEE Transactions on Smart Grid*, 7, (1), pp. 136-144, Enero, 2016.

Han, J., Kamber, M y Pei, J., (2011). Data Mining: Concepts and Techniques. 3rd. Edition. Burlintong, MA, USA. Morgan Kaufmann Publishers Inc.

Hemingway, P. y Brereton, N., (2009). What is a systematic review? Series (2nd Ed.). Newmarket, UK: Hayward Medical Communications

Hernández, J., Ramírez, M. J. y Ferri, C., (2004). Introducción a la minería de datos, Madrid: Pearson Educación.

Huang, D., Zareipour, H., Rosehartet, W.D. y Amjady, N., (2012). Minería de datos para la clasificación de precios de electricidad y la aplicación a la gestión del lado de la demanda. IEEE Trans. Smart Grid, 3, pp. 808–817.

Hurtado, L., Quintero, O.L. y García, J. J., (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, 18, pp. 54-87 (ISSN: 1886-516X).

IpsomManager, (2018). – www.ipsom.com. <https://www.ipsom.com/2019/01/resumen-2018-precio-de-la-electricidad-en-espana/>

IpsomManager, (2019). Recuperada de: <https://www.ipsom.com/2019/07/es-mas-cara-en-espana-la-energia-que-en-el-resto-de-€pa/>

Jakaša, T., Andročec, I. y Sprčić, P., (2011). Previsión de precios de electricidad: enfoque del modelo ARIMA. En Actas de la 8ª Conferencia Internacional sobre el Mercado Energético Europeo (EEM), Zagreb, Croacia, 25–27 de mayo; pp. 222–225.

Keles, D., Scelle, J., Paraschiv, F. y Fichtner, W., (2016). Métodos de pronóstico extendido para los precios spot de la electricidad con aplicación diaria de redes neuronales artificiales. Appl. Energy, 2016, 162, pp. 218–230.

Khotanzad, A.I., (2018). Using artificial intelligence to develop electricity load forecasts. Power Magazine, Jun.2018, 62, (6), pp. 1-1. (ISSN 032-5929).

Kian, A. y Keyhani, A., (2001). Modelación de precios estocástica de la electricidad en mercados energéticos desregulados. En Actas de la 34ª Conferencia Internacional Anual de Hawái sobre Ciencias del Sistema, Maui, HI, EE. UU., 6 de enero, pp. 1-7.

Lane, J., Wade, J., Down, L., Bonnington, S., Holding, P., y Lennon, T., (2011). A peer review intervention for monitoring and evaluating sites (PRIME) that improved randomized controlled trial conduct and performance. *Journal of Clinical Epidemiology*, 64 (6), pp. 628–636.

Lara, J., (2014). *Minería de datos*. Madrid: Centro de Estudios Financieros.

Lawrenz, F., Thao, M. y Johnson, K., (2012). Expert panel reviews of research centers: The site visit process. *Evaluation and Program Planning* 35, pp. 390–397.

Lijesen, M.G., (2007). La elasticidad precio de la electricidad en tiempo real. *Economía y Energía*, 29, pp. 249–258.

Marinero, D.J. y Pavlova, A., (2003). Saturación del mercado de aire acondicionado y respuesta a largo plazo de la demanda de energía de refrigeración residencial al cambio climático. *Energy*, 28, pp. 941–951.

Medina-López, C., Marín-García, J. A., y Alfalla-Luque, R. (2010). Una propuesta metodológica para la realización de búsquedas sistemáticas de bibliografía (A methodological proposal for the systematic literature review). *WPOM-Working Papers on Operations Management*, 1 (2), pp. 13–30. doi:10.4995/wpom.v1i2.786. ISSN: 1989-9068.

Michalewicz, Z., (1999). *Genetic Algorithms + Data Structures = Evolution Programs..* Ed. Springer.

Mok, K. Y., Shen, O. y Yang, J. (2015). Stakeholder management studies in mega construction projects: A review and future directions. *International Journal of Project Management*, 33 (2), pp. 446–457. doi:10.1016/j.ijproman.2014 .08.007.

Mora, F.A. y Minchala, I., (2015). Modelización de Sistema de Molienda de Cemento, con orientación al diseño de un Optimizador Energético de la Operación en Estado Estable. Caso de Estudio UCEM Planta Guapán. Universidad Politécnica Salesiana de Ecuador.

Nagi, J., Yap, K.S., Tiong, S.K., Ahmed, S.K. y Mohamad, M., (2008). Non-Technical Loss Analysis for Detection of Electricity Theft using Support Vector Machines, IEEE International Conference on Power and Energy, pp. 907-912.

Nagi, J., Yap, K.S., Nagi, F., Koh, S.K. y Ahmed, S.K., (2010). "NTL Detection of Electricity Theft and Abnormalities for Large Power Consumers In TNB Malaysia" IEEE SCORED, pp. 13-14, 2010.

Nagi, J., Yap, K.S., Tiong, S.K., Ahmed, S.K. y Mohamad, M., (2010). "Nontechnical Loss Detection for Metered Customers in Power Utility Using Support Vector Machines", IEEE Transactions on Power Delivery, 25, (2), pp. 1162-1171, abril 2010.

Nogales, F.J., Contreras, J., Conejo, A.J. y Espínola, R., (2002). Pronóstico de precios de electricidad al día siguiente por modelos de series de tiempo. IEEE Trans. Power Syst., 17, pp. 342–348.

Oakley, A., (2003). Research evidence: Knowledge management and educational practice: early lessons from a systematic approach. London Review of Education, 1 (1), pp. 21–33.

OMIE, (2019). Estadísticas de precios mínimos, medios y máximos. Recuperada de: http://www.omie.es/reports/index.php?report_id=231#

OMIE, (2019). Recuperada de: http://www.omie.es/reports/index.php?report_id=411

OMIP, (2021) - <https://www.omip.pt/es>.

Pacheco, E.A., Rodríguez, M.V. y 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.

Parejo, M., Navarrete, B, Mora, P. y Alfalla-Luque, R., 2021. Desarrollo Metodológico para la optimización del coste eléctrico en fábricas de cemento, mediante inteligencia artificial, operando sobre el coste eléctrico del mercado. Dirección y Organización. Julio, 74, pp. 5-19

Parejo, M., Navarrete, B, Mora, P. y Alfalla-Luque, R., 2021. Methodological Development for the optimization of electricity cost in cement factories: the use of Artificial Intelligence in Process Variables. *Electrical Engineering*.

Papadimitriou, T., Gogas, P. y Stathakis, E., (2014). Pronósticos de los mercados de energía utilizando máquinas de vectores de soporte. *Energy Econ.* 2014, 44, pp. 135–142.

Pereira, L., Afonso, L., Papa, J.P., Vale, Z.A., Ramos, C., Gastaldello, D.S. y Souza, A.N., (2013). Multilayer Perceptron Neural Networks Training Through Charged System Search and its Application for Non-Technical Losses Detection. Conference: IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America 2013).

Pérez, C., (2007). *Minería de datos técnicas y herramientas*, Madrid: Thomson.

Pérez, C., (2014). *Técnicas de minería de datos e inteligencia de negocios*, España: Garceta.

Pezzutto, S., Grilli, G., Zambotti, S. y Dunjic, S., (2018). Forecasting Electricity Market Price for End Users in EU28 until 2020—Main Factors of Influence. *Energies* 11 (6), 1460. (ISSN: 19961073).

Quinlan, K. M., Kane, M., y 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: Reforming the evaluation of research*, 118, pp. 61–72.

REE, (2019). Recuperada de: <https://www.ree.es/es/datos/publicaciones/boletines-mensuales>

Robinson, T.A., (2000). Precios del pool de electricidad: un estudio de caso en modelos de series temporales no lineales. *Appl. Econ.*, 32, pp. 527–532.

Rons, N., DeBruyn, A., y Cornelis, J., (2011). Research evaluation per discipline: A peer review method and its outcomes. *Research Evaluation*, 17 (1), pp. 45–57.

Rubin, O.D. y Babcock, B.A., (2013). El impacto de la expansión de la capacidad de energía eólica y los métodos de fijación de precios en la eficiencia de los mercados de electricidad desregulados. *Energy*, 59, pp. 676–688.

Ruibal, C.M. y Mazumdar, M., (2008). Pronosticando la media y la varianza de los precios de la electricidad en los mercados desregulados. *IEEE Trans. Power Syst.*, 23, pp. 25–32.

Sánchez Cazorla, A., Alfalla-Luque, R. e Irimia-Diéguez, A.I., (2016). Risk Identification in Megaprojects as a Crucial Phase of Risk Management: A Literature Review. *Project Management Journal*, 47, (6), pp. 75–93.

Shaohog J., Wemeng X. y Xiaohong W., (2012). Research on the Key Technology of Energy Management and Optimization in Cement Enterprises. *Advanced Materials Research*. 433-440, pp. 1910-1914. (ISSN 1662-8985).

Shrivastava, N.A., Khosravi, A., y Panigrahi, B.K., (2015). Estimación del intervalo de predicción de los precios de la electricidad utilizando máquinas de vectores de soporte sintonizados por PSO. *IEEE Trans. Ind. Inf.*, 11, pp. 322–331.

Solano, M.A., (1994). “Modelo Matemático para Programación de la Producción buscando optimizar el uso de la Energía Eléctrica en una Industria Cementera”. Universidad Autónoma de Nuevo León, Monterrey, México.

Sreekumar, S., Bhakary, R., Chawda, S., Jain, Y. y Prakashz, V., (2020). One Day Ahead Indian Electricity Price Forecasting Using Intelligently Tuned SVR. Conference: 2020 IEEE International Power and Renewable Energy Conference. At: Karunagappally, India. DOI: 10.1109

Swanepoel, J.A., (2013). Modeling for Integrated Energy Optimization In Cement Production. Conference on the Industrial and Commercial Use of Energy, ICUE. Article number: 6761634 (ISSN: 0196-8904).

Swanepoel, J.A., Mathews, E. H., Vosloo, J. y Liebenberg, L., (2013). Integrated energy optimisation for the cement industry: A case study perspective. *Energy Conversion and Management*, 78, pp. 765-775. (ISSN: 0196-8904).

Tan, Z.F., Zhang, J.L., Wang, J.H. y Xu, J., (2010). Predicción del precio de la electricidad para el día anterior mediante la transformación de wavelet combinada con los modelos ARIMA y GARCH *Appl. Energy*, 87, pp. 3606–3610.

Théate, T., Mathieu, S. y Ernst, D., (2020). An Artificial Intelligence Solution for Electricity Procurement in Forward Markets. *Energies*, 13 (23), 6435; DOI: 10.3390/en13236435

Torghaban, S.S., Motamedi, A., Zareipour, H. y Tuan, L.A., (2012). 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, pp. 1-8.

Tranfield, D., Denyer, D., y Smart, P., (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British Journal of Management*, 14 (3), pp. 207–222.

Weber, R. P., (1990). *Basic content analysis* (2nd Ed.). Newbury Park, CA: Sage Publications, Inc.

Wellesley, M., (2001) EnvaPower's New Artificial Intelligence Software Makes Managing Electricity a No-Brainer. *PR Newswire*, NY.

Wood, A.J. y Wollenberg, B.F., (1996). *Generación, operación y control de energía*; Wiley: Nueva York, NY, EE. UU.

Xie, M., Sandels, C. y Zhu, K., (2013). Un modelo estacional de ARIMA con variables exógenas para los precios de electricidad de El spot en Suecia. En *Actas de la 10ª Conferencia Internacional sobre el Mercado Energético Europeo (EEM)*, Estocolmo, Suecia, 1–4 de mayo de 2013; pp. 27–31.

Yan, X. y Chowdhury, N.A., (2013). Previsión de precios de compensación del mercado de electricidad a medio plazo: un enfoque híbrido LSSVM y ARMAX. En *t. J. Electr. Power Energy Syst.*, 53, pp. 20–26.

Yan, X. y Chowdhury, N.A., (2014). Previsión de precios de compensación del mercado de electricidad a medio plazo: un enfoque de SVM múltiple. *Int. J. Electr. Power Energy Syst.*, 58, pp. 206–214.

Zhang, J. y Cheng, Ch., (2008). Day-ahead electricity price forecasting using artificial intelligence. *IEEE Canada Electric Power Conference*. INSPEC Accession Number: 10459652.

Zhang, J. y Tan, Z., (2013). Previsión de precios de la electricidad para el día con WT, CLSSVM y modelo EGARCH. *Electr. Power Energy Syst.*, 45, pp. 362–368.

Zhao, J.H., Dong, Z., Li, X. y Wong, K., (2007). Un marco para el análisis de aumento de precios de la electricidad con métodos avanzados de minería de datos. *IEEE Trans. Power Syst.*, 22, pp. 376–385.

VI. Índice de tablas y figuras

TABLAS.

- 1.- **Tabla 1.** Resultados de las búsquedas del análisis sistemático de la literatura. Fuente: Elaboración Propia. Pág. 29.
- 2.- **Tabla 2.** Temática de los artículos analizados. Pág. 30.
- 3.- **Tabla 3.** Relación de artículos seleccionados (títulos y autores) y revistas en las que se publicaron. Fuente: Elaboración Propia. Pág. 31
- 4.- **Tabla 4.** Período estudio. Fuente: Elaboración Propia. Pág. 32.
- 5.- **Tabla 5.** Año publicación. Fuente: Elaboración Propia. Pág. 32.
- 6.- **Tabla 6.** Universidades investigadoras. Fuente: Elaboración Propia. Pág. 33.
- 7.- **Tabla 7.** Revista de publicación. Fuente: Elaboración Propia. Pág. 34.
- 8.- **Tabla 8.** Precio kWh para la industria electro intensiva (Bands IE 20.000-70.000 MWh e IF:70.000-150.000 MWh). Fuente: Estadísticas Eurostat, 2019. Pág. 53.
- 9.- **Tabla 9.** Precio mínimo, medio y máximo. Septiembre 2019. Fuente OMIE.. Pág. 57.
- 10.- **Tabla 10.** Costes eléctricos regulados sector cementero español. Fuente: Elaboración propia a partir de datos facilitados por empresas cementeras y OFICEMEN. Pág. 70.
- 11.- **Tabla 11:** Secuencia de mercados en el mercado ibérico de electricidad (MIBEL). Fuente: Elaboración propia. Pág. 106.
- 12.- **Tabla 12:** Precios diarios para el mes de enero del año “N” y cociente P1/ P6. Fuente: Elaboración propia. Pág. 120.

FIGURAS:

- 1.- **Figura 1.** Número de autores. Fuente: Elaboración Propia. Pág. 33.
- 2.- **Figura 2.** Área geográfica. Fuente: Elaboración Propia. Pág. 34.
- 3.- **Figura 3.** Proceso de KDD. Fuente: Elaboración Propia. Pág. 41.
- 4.- **Figura 4:** Neurona artificial. Fuente: Elaboración Propia. Pág. 45.
- 5.- **Figura 5.** Funcionamiento de la Red Neuronal con algoritmo Backpropagation. Fuente: Elaboración Propia. Pág. 46.
- 6.- **Figura 6.** Ejemplo de K Vecinos más cercanos. Fuente: Elaboración Propia. Pág. 50.
- 7.- **Figura 7.** Coste eléctrico de la industria electro intensiva española vs EU (28) (20.000-150.000 MWh) por semestres, entre 2007 y 2018. Expresado en €/ kWh. Elaboración propia a partir de datos de Eurostat, 2019. Pág. 55.
- 8.- **Figura 8.** Precio mínimo, medio y máximo. Septiembre 2019. Fuente OMIE: Pág. 56.
- 9.- **Figura 9:** Mix energético de cobertura de la demanda eléctrica peninsular, 2020. Fuente: REE. Pág. 59.
- 10.- **Figura 10:** Evolución dependencia energética española vs EU. Fuente: APPA. Pág. 59.
- 11.- **Figura 11:** Comparativa mensual del Mercado FWD. Fuente: Indicadores de energía –IpsomManager –www.ipsom.com. Pág. 60.
- 12.- **Figura 12:** Comparativa anual mercado SPOT/FWD entre 2012 y 2018. Fuente: Indicadores de energía – IpsomManager – www.ipsom.com. Pág. 61.
- 13.- **Figura 13.** Precio de la electricidad en España (€/MWh). Fuente: Elaboración propia a partir de datos de OMIE y OMIP (OMIE, 2019; OMIP, 2021). Pág. 71
- 14.- **Figura 14.** Coste eléctrico total industria cementera española (€/MWh). Fuente: Elaboración propia a partir de datos facilitados por las empresas cementeras, OFICEMEN y OMIE (OMIE, 2019). Pág. 71.

- 15.- **Figura 15.** % de uso de la potencia contratada en España (2009-2018). Fuente OFICEMEN. Pág. 73.
- 16.- **Figura 16.** % de uso de la potencia contratada en España, según tarifas de tensión contratada (2009-2018). Fuente OFICEMEN. Pág. 74.
- 17.- **Figura 17.** Modulación del consumo eléctrico de las fábricas españolas durante 2018. Fuente OFICEMEN. Pág. 75.
- 18.- **Figura 18** Modulación del consumo eléctrico de las fábricas españolas durante 2018, según tarifas de tensión contratada. Fuente OFICEMEN. Pág. 76.
- 19.- **Figura 19.** Diagrama de flujo. Consumo energético en fábricas de cemento. (Referido a t. de materiales). Fuente: Elaboración propia. Pág. 79.
- 20.- **Figura 20.** Funcionamiento de la Red Neuronal con el algoritmo Backpropagation. Fuente: Elaboración propia. Pág. 88.
- 21.- **Figura 21.** Calendarios Energéticos. Distribución de Periodos Aplicables a las Tarifas Eléctricas. Fuente: Circular de la CNMC 3/2020 de 15 de enero de la CNMC por la que se establece la metodología para el cálculo de los peajes de transporte y distribución de la electricidad. GOIENER, (2021). Pág. 89.
- 22.- **Figura 22.** Estructura de generación mensual peninsular. Octubre 2019. Fuente: REE. Pág. 104.
- 23.-**Figura 23.** Curvas Oferta y Demanda de la electricidad del Mercado. Fuente: Elaboración propia. Pág. 107.
- 24.- **Figura 24.** Curva de Oferta de la electricidad del mercado. Fuente Elaboración propia. Pág. 108.
- 25.- **Figura 25:** Curva de demanda de electricidad del mercado. Fuente: Elaboración Propia. Pág. 109.
- 26.- **Figura 26:** Cobertura de la curva de demanda horaria en un cierto día por las distintas tecnologías. Fuente: REE y Manual de la Energía (Energía y Sociedad). Pág. 117.

27.- **Figura 27:** Uso óptimo de cada grupo de tecnologías en la generación eléctrica.
Fuente: Elaboración propia. Pág. 118.

28.- **Figura 28.** Red Neuronal para determinar el precio eléctrico spot y futuro. Fuente:
Elaboración Propia. Pág. 122.

VII. Anexos.

A. Artículos científicos.

Artículo 1. Revista Dirección y Organización

(ISSN Print: 1132-175X / ISSN On-line: 2171-6323)

METHODOLOGICAL DEVELOPMENT FOR ELECTRICAL COST OPTIMIZATION IN CEMENT FACTORIES USING ARTIFICIAL INTELLIGENCE TRADING ON THE MARKET ELECTRICAL COST.

DESARROLLO METODOLÓGICO PARA LA OPTIMIZACIÓN DEL COSTE ELÉCTRICO EN FÁBRICAS DE CEMENTO MEDIANTE INTELIGENCIA ARTIFICIAL OPERANDO SOBRE COSTE ELÉCTRICO DEL MERCADO

Parejo Guzmán, Manuel ⁽¹⁾ ⁽²⁾ (ORCID: 0000-0001-5701-9827), Alfalla-Luque, Rafaela ⁽¹⁾ (ORCID: 0000-0002-9110-8273), Navarrete, Benito ⁽¹⁾ (ORCID: 0000-0003-0742-7878), and Mora, P. ⁽³⁾ (ORCID: 0000-0002-6913-2832).

(1) Universidad de Sevilla, Spain.

(2) Universidad Pablo de Olavide, Spain.

(3) Escuela Técnica Superior de Ingenieros de Minas de Madrid, Spain

Revista Q3 en Scopus, presentando: CiteScore (2020): 0,8; rank 245/336 27th (Engineering / Industrial and Manufacturing Engineering); 160/218 26th (Business, Management and Accounting / General Business, Management and Accounting); SNIP: 0.358. SJR (2020): 0.175; rank 305/593 (Engineering / Industrial and Manufacturing Engineering); 244/359 (Business, Management and Accounting / General Business, Management and Accounting).

Revista Q4 JCR en la categoría de Management (327/384) con un Journal Citation Indicator (JCI) en 2020 de 0,19. También está indexada en índices tales como Dialnet, DICE, REBIB, In-RECS; Latindex, Redalyc y Rebiun

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.v0i74.597>

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 80,6%. 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 clínker, 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 Neuronal 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.

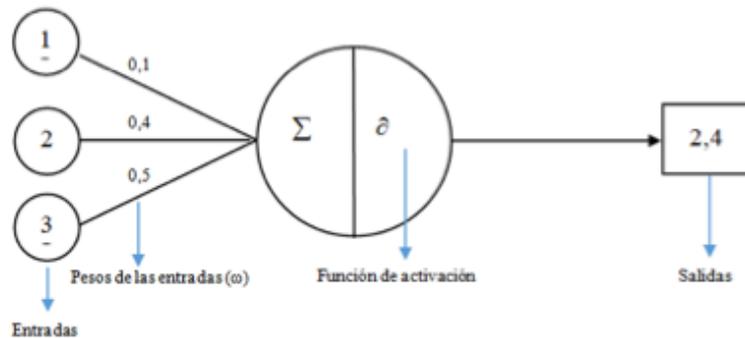
3. Propuesta metodológica para optimizar la compra de electricidad: aplicación de herramientas específicas de AI

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.

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".

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

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.

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

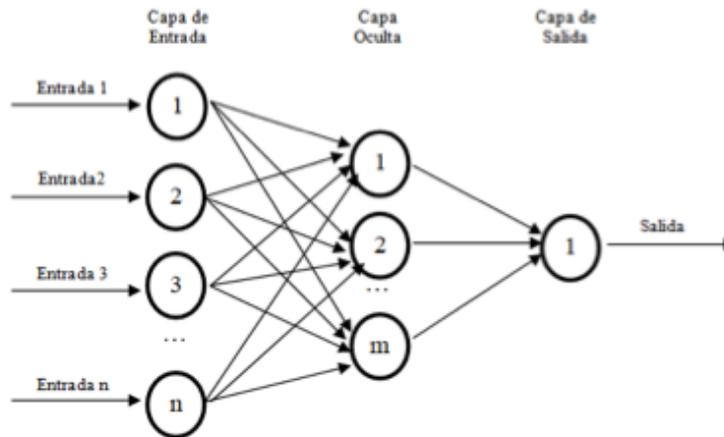
o negativo. Además se multiplicará por 1/2, para simplificar el cuadrado cuando calculemos la derivada. La derivada servirá para obtener la variación del error respecto a la variación de los pesos.

$$E = 1/2 (y-S)^2 \rightarrow \partial E/\partial \omega \quad [2]$$

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*

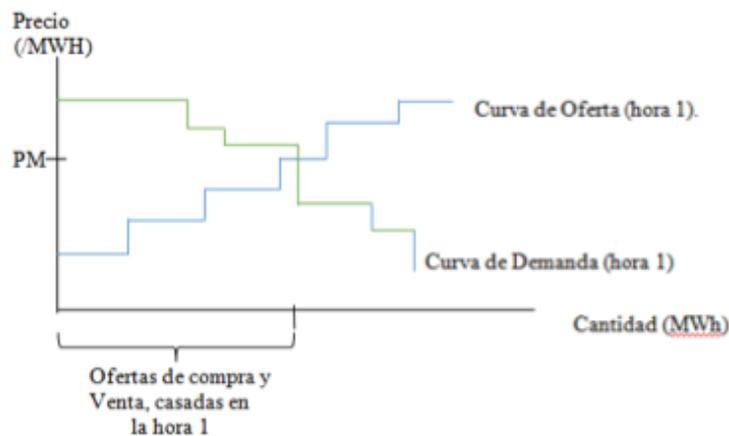
TIEMPO	MERCADO	GESTOR	
Antes del despacho (antes D-1)	Contratos bilaterales	OMIP /OTC	Mercado a plazo
Día anterior al despacho (D-1)	Mercados día anterior	OMIE	Mercado diario
Día del despacho (D)	Mercado intradiario	OMIE	Mercado a C/P

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*

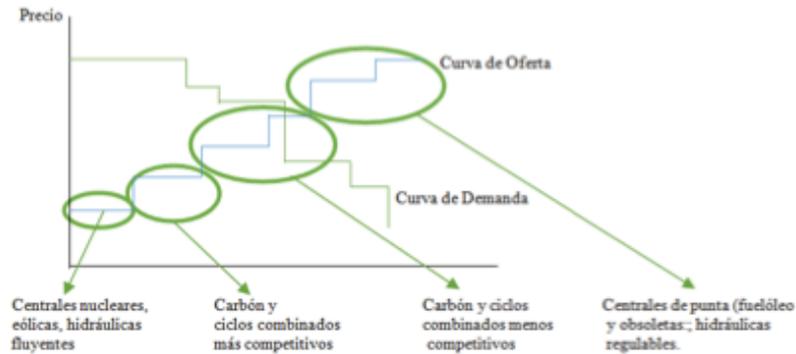


El mercado diario es un mercado marginalista, es decir, que todos los generadores reciben un mismo precio que se determina por el cruce de oferta y demanda. A continuación se verá como se van agregando las distintas ofertas de venta.

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.

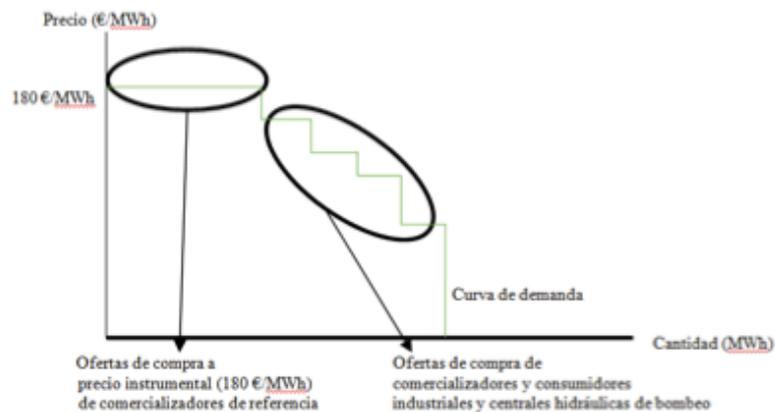
Figura 4 Curva de Oferta de la electricidad del Mercado.
 Fuente: *Elaboración propia*



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 esta 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 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 CO₂ (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 CO₂ (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.

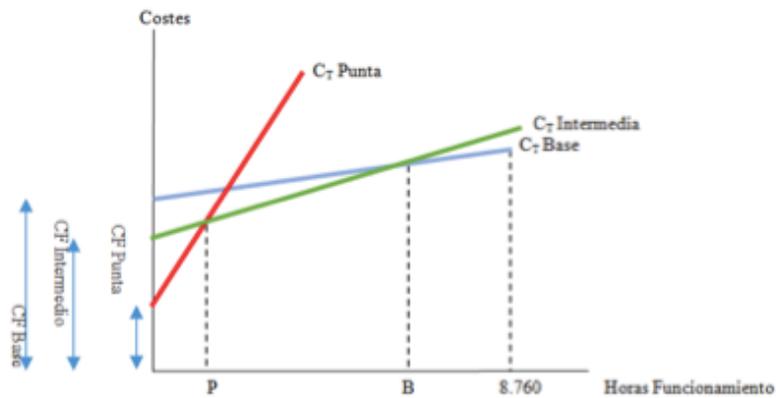
Como se ha visto, cada tecnología tiene distintas estructuras de costes fijos y variables; además, la flexibilidad para adaptarse a las variaciones de la demanda no es igual en todos los casos. En función de estos condicionantes, en un mismo instante se podría estar generando electricidad proveniente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

La 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 "hueco 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_t) 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_t) 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_t	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	46	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	1,18	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]:

$$\text{Precio Spot} = F(\text{Pr}_t/\text{Pr}_0, \text{Precio Call } X, \text{ mix energético, meteorología, laboralidad, estacionalidad}) * \omega_F \quad [3]$$

Para cada una de las 8.760 horas del año obtendremos a partir de los precios diarios de hoy (Pr_t) 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 ω_{ij} , teniendo presente que debe cumplirse que $\sum \omega_{ij} = 1 / i = 1, 2, 3. \quad // \quad \sum \omega_{ij} = 1 / i = 1, 2.$

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 $\sum \omega_{ij}$ que afectan a estas variables. Hemos de tener en cuenta en esta ocasión que $\sum \omega_{ij} = 1. \quad // \quad i = 1, \dots, 14.$

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.

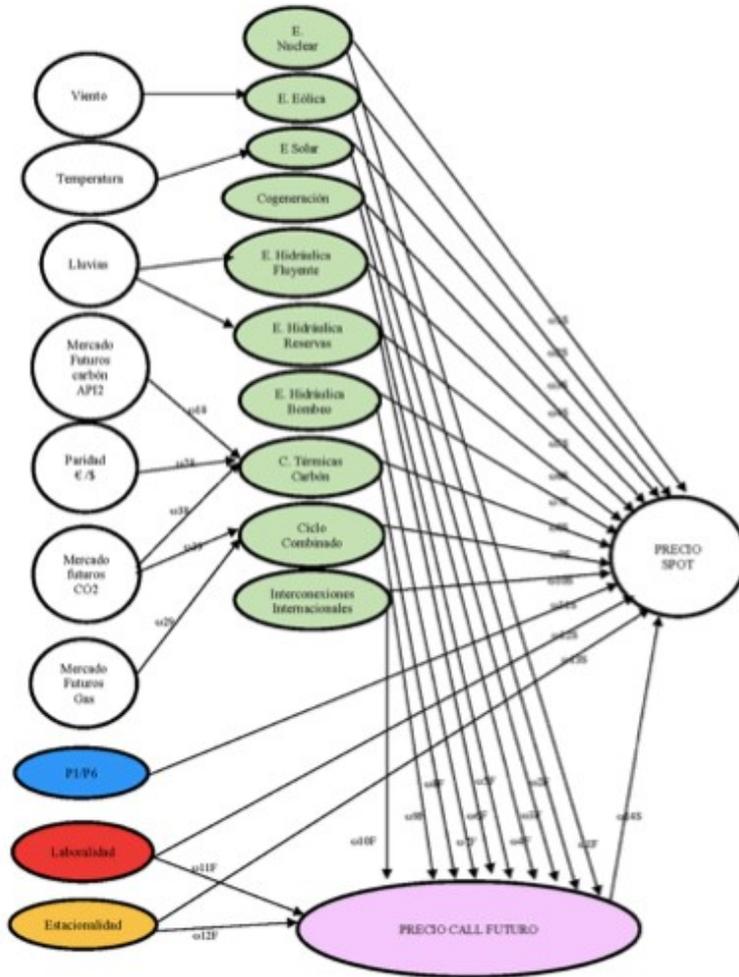
Si la red neuronal predijera que el precio Spot del día "D-1" será mayor que el Precio Call que se da hoy, se adquiriría hoy la electricidad en el mercado de futuros al precio call. Si predijera un menor precio, se compraría la electricidad en el mercado diario spot el día "D".

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 ω_{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 ω_{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: Spriger, 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., Muncio, 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.epa.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, n° 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*.

Artículo 2. Revista: Electrical Engineering

(ISSN On-line: 0948-7921 ISSN Print 1432-048).

METHODOLOGICAL DEVELOPMENT FOR THE OPTIMISATION OF ELECTRICITY COST IN CEMENT FACTORIES: THE USE OF ARTIFICIAL INTELLIGENCE IN PROCESS VARIABLES

Manuel Parejo-Guzmán ⁽¹⁾⁽²⁾, Benito Navarrete Rubia ⁽¹⁾, Pedro Mora Peris ⁽³⁾ y
Rafaela Alfalla-Luque ⁽¹⁾

(2) *Universidad de Sevilla, Spain*

(3) *Universidad Pablo de Olavide, Spain.*

(4) *Universidad Politécnica de Madrid, Spain.*

- Revista Q2 Scopus. Citescore (2020): 3,2; rank 140/548 74th (Mathematics: Applied Mathematics); 293/693 57th (Engineering: Electrical and Electronic Engineering). SJR (2020): 0,350; rank 372/2032 (Engineering: Electrical and Electronic Engineering). SNIP (2020): 0,981.
- Revista Q3 JCR. JIF (2020): 1,836; Five year impact factor (2020): 1,781; rank 180/273 (Engineering, Electrical & Electronic).



Methodological development for the optimisation of electricity cost in cement factories: the use of artificial intelligence in process variables

Manuel Parejo Guzmán^{1,2} · Benito Navarrete Rubia¹ · Pedro Mora Peris³ · Rafaela Alfalla-Luque¹

Received: 31 December 2020 / Accepted: 25 September 2021
© The Author(s) 2021

Abstract

Cement factories require large amounts of energy. 70% of the variable cost goes to energy—33% to kiln thermal energy and 37% to electrical energy. This paper represents the second stage of a broader research study which aims at optimising electricity cost in a cement factory by means of using artificial intelligence. After an analysis of the different tools that could be highly useful for the optimisation of electricity cost, for which a systematic review of the literature and surveys and an expert panel of 42 professionals in the cement sector were carried out, a methodology was developed in order to reduce electricity cost by optimising not only different variables of the production process, but also regulated electricity costs and electricity market costs. Artificial neural networks and genetic algorithms will be the tools to be used in this methodology, which can be applied to any cement plant in the world, and, by extension, to any electro-intensive consumer. The innovation of this research work is based on the use of a methodology that not only combines two different variables at the same time—process variables and regulated prices—but also makes use of artificial intelligence tools techniques.

Keywords Cement · Electricity cost · Optimisation · Artificial intelligence · Artificial neural networks and genetic algorithms

1 Introduction: problem identification

Cement manufacturing process consists of finely grinding a series of minerals (limestone, marl and clay) and heating them at about 1450°C in a cement kiln to obtain an intermediate product called clinker. The clinker is blended with gypsum (a cement setting regulator) and other additives and then ground again into a fine powder to form cement. The process consists of 9 stages which are shown in Fig. 1.

The Spanish cement sector faced a very severe crisis which brought about a drastic reduction in consumption. From 2006 up to 2014 cement consumption decreased from 55.9 million t. to 10.8 million t, which represented a decrease of 80.67%. Spanish cement companies were forced to change their strategy and started then exporting large quantities of cement and clinker to different countries in the world.

The loss of competitiveness of cement companies in recent years has led to a drastic reduction in Spanish exports. Dur-

ing 2018, Spanish plants exported a total of 8,103,947 t. of cement and clinker. This amount was reduced to 6,232,043 t. in 2019—a reduction of 23.1%. [26].

The energy consumption of a cement plant has a very important weight in the income statement. Energy comprises up to 70% of variable cost in a cement factory: 33% for thermal energy (Kiln) and 37% for electrical energy [17]. Therefore, the cost of electricity consumption in cement production is a fundamental competitive factor.

Electricity costs in Spanish electro-intensive industry, according to Eurostat data, can be sometimes up to 30% higher than they are in other European countries [11]. Energy price in Spain is higher than that in most direct competitor countries. Based on a consumption between 20,000 MWh and 150,000 MWh, which is the range within which 100% of Spanish cement companies were located in 2018—excluding taxes and levies—comparative data for the cost of electricity in electro-intensive industry in the 28 EU countries reveal that Spanish industry has one of the highest electricity costs, being only surpassed by Ireland, Malta and the UK.

While the EU-28 average electricity price for non-household consumers with a consumption between 20,000 and 150,000 MWh was 61,3 €/MWh in 2018, it reached 78,8 €/MWh in Spain.

✉ Manuel Parejo Guzmán
mparejo@me.com

¹ Universidad de Sevilla, Sevilla, Spain

² Universidad Pablo de Olavide, Sevilla, Spain

³ Universidad Politécnica de Madrid, Madrid, Spain

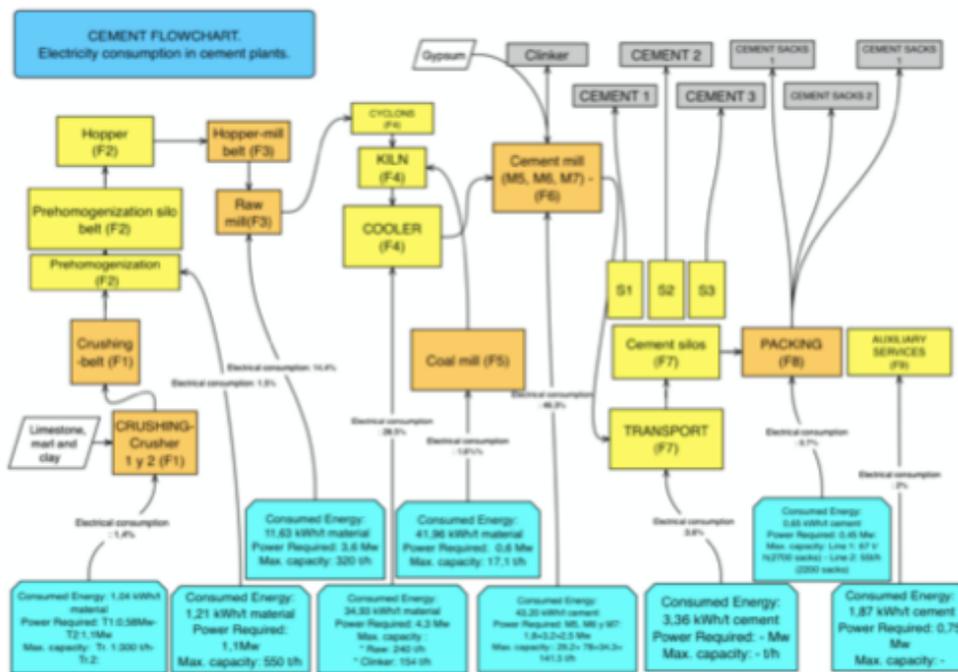


Fig. 1 Cement manufacturing process (% of electricity consumption referred to tons of cement)

Hence, it is essential to investigate how to optimise the cost of electricity in cement factories in order to make them more competitive.

2 Objective of the paper

The problem of the loss of competitiveness of cement industry due to its high electricity costs is a common issue in multiple countries. In the last few months (Spring/Summer 2021), the matter has acquired great relevance in countries such as Spain. Specifically, our research pursues the development of a methodology to optimise the cost of electricity in a cement plant by means of influencing internal variables of the plant: process variables and regulated electricity cost.

By reducing costs, the plant may become more competitive. The methodology developed is perfectly valid for any cement factory in the world. In addition, it is worth mentioning that by modifying the initial parameters of the model, it could be applied to other electro-intensive industries, such as extractive mining—copper and other mineral production, automotive industry, aeronautical industry and agroindustry.

To apply it in other countries, it would only be necessary to analyse the regulated electricity costs to be taken into account, as well as the different factors that affect price formation in the electricity markets.

Using artificial intelligence (AI) for the optimisation of the cost of electricity in cement plants is the objective of a broader research study within which this article is framed. Our research study also includes a methodology aimed at reducing the cost of electricity by applying AI techniques to optimise the purchase of electricity [27].

3 Methodology

The tools that prove to be useful when applying AI to minimise electricity cost in the cement sector match those that could potentially be applied in other industrial sectors. They are mainly the following:

1. Internet of things (IoT): set of devices, objects and computers connected to the internet and communicated with each other, which help to collect information.

2. Data mining: it is used to extract information contained in historical or real time received data, to assist in decision making [7, 31].
3. Machine learning: it is a branch of AI based on the design of algorithms, which allow machines and computers to learn from data without the need for constant human intervention. Its strong point is that the learning process is automated and improved as it consumes more data without requiring human intervention [6, 33].

Although in the present paper these tools are tackled, we will delve into machine learning techniques in particular in order to apply them in the model proposed.

3.1 Main machine learning algorithms and techniques

There are machine learning techniques and algorithms which are extremely useful for solving the kind of problem we face in our research: the optimisation of the cost of electricity in an industrial plant. These include decision tree algorithms, support vector machines, Bayesian networks, fuzzy logic, nearest neighbours, K-means, artificial neural networks (ANN) and genetic algorithms. Attention will be focussed on the last two, since they are the most recommended ones considering the systematic study of the literature and the expert panel.

3.1.1 Artificial neural networks (ANN)

They are mathematical models which are based on the biological behaviour of brain neurons [8, 29, 30]. They are connected in a specific way. They are organised into layers and their goal is to learn by automatically tuning themselves, so that they can accomplish complex tasks that could not be performed by classical programming.

Figure 2 shows the graphical representation of an artificial neuron. The sum of the inputs multiplied by their associated weights determines the nerve impulse that the neuron receives. This value is processed inside the neuron by an activation function that returns the new value which will be sent as the output value of the neuron.

Mimicking human brain, ANN receive a series of input values, each of which reaches a node called neuron. The first step, which is crucial for the application of the model, is the proper selection of the input data. It is essential that they be relevant data, that is, that they really affect the final result that we try to predict [15].

Neurons in the network are grouped into layers. There are three types of layers [15]:

- Input layer. It is the one that gets the information from the outside world.

- Hidden layers. They process the information internally.
- Output layer. It is the one that gets the response from the network and transfers it to the outside world.

Each of the neurons in the network has a weight, a numerical value (ω), which modifies the received input. The new values obtained leave the neurons and continue on their way through the network. The value obtained in each neuron would be a linear regression model to which a bias—“b”—would be added: $Y = X_1 * \omega_1 + X_2 * \omega_2 + X_3 * \omega_3 + b$. It is not unusual that the results obtained by the neural network (Y) initially do not coincide with the real result. It is due to the fact that the network should receive some training and learn how to perform its function correctly. Therefore, such training is carried out by modifying the weights of the neurons so that they get as close as possible to the desired results. Thus, one of the most widespread networks, which is known as *multilayer perceptron-MLP* [19], arises.

In this model, training data are entered in the network. If the result obtained with the initial weights was erroneous, weights should be adjusted until the output error is minimised or eliminated. This training algorithmic method that will be used in our research is called *backpropagation*. By means of derivatives, errors will be calculated by the network as the variation between the result obtained and the expected correct result for each group of weights. The goal of the backpropagation algorithm will be to minimise the error (E) as much as possible. The error will be expressed as the difference between the output value and the expected correct result, and it will be squared, since it is not relevant that the error has a positive or negative value. It will also be multiplied by 1/2 to simplify the square when calculating the derivative. The derivative will provide the error variation with respect to weights variation.

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

E : Error.

y : Correct value.

S : Neural network output.

Once the end of the neural network is reached with a null or near-zero error, the network is considered to be sufficiently trained (Fig. 3).

3.1.2 Genetic algorithms

It is a method to generate the optimum solution to an optimisation problem. It starts with an initial population of individuals with a certain genetic coding. Population evolves so that only the best chromosomes will be selected to be part of the new population. To do this, mechanisms for the selec-

Fig. 2 Artificial neuron. Source: own elaboration

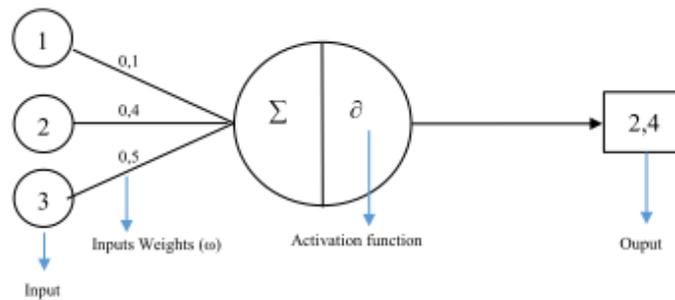
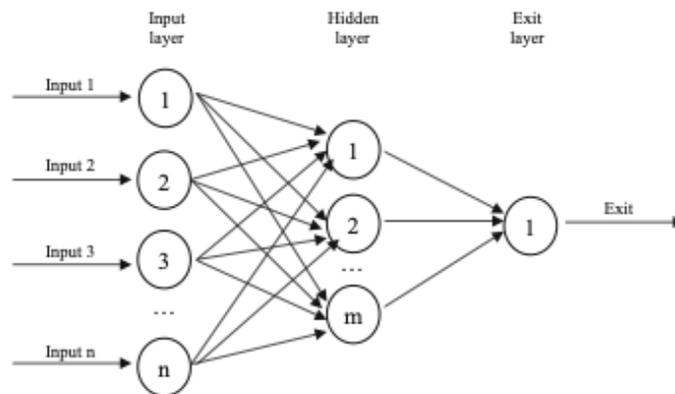


Fig. 3 How does backpropagation in artificial neural networks work? Own elaboration



tion, crossover and mutation of chromosomes are applied until a certain stopping criterion is met. An example of a stopping criterion could be a certain number of generations or cycles, until a specific convergence criterion is reached [22]. This method can be used in combination with other algorithms such as ANN and support vector machines, with the aim of increasing performance and providing the model with a more robust solution [20, 22–24].

3.2 Selecting specific tools to solve the problem

The model introduced in this article was developed using the most appropriate tools to solve the problem raised and with the aim of reducing electricity cost in cement factories. Our approach followed the steps below.

3.2.1 A systematic literature review

In scientific literature, there are two types of literature reviews [10]: the traditional or narrative review and the systematic review of literature [21, 22]. In a systematic review of literature, achieved findings can be replicated [14]. The systematic

review is defined as a process of "systematic, transparent and reproducible synthesis of research, with the dual objective of improving the knowledge base and the formulation and practice of policies" [38]. Due to its structured approach, the systematic review of literature has been widely accepted in a variety of scientific fields, such as social sciences, education and supply chain management [1, 12, 25, 34].

The field of study of our research is focussed on the optimisation of electricity cost in cement companies by using AI. Therefore, a search was conducted by introducing keywords (electricity, optimisation, cement, artificial intelligence, industry and energy). The sources of information selected were Scopus, Web of Science and ABI Inform Collection databases. The search period run until May 2021.

After an initial selection of the articles related to the subject that were found in the databases, a total of 12 articles were selected [2–4, 9, 16, 17, 28, 35–37, 39, 40]. The study of the previous literature provided quite a reduced number of articles dealing with the issue of our research and which contained very limited information. Only four of those articles considered the cement sector [9, 35–37]. The rest of them were either intersectoral articles [3, 16, 17, 28, 39, 40]

or general-industry oriented articles [2, 4]. After a detailed analysis of them, the following conclusions were reached:

- (a) Although all the articles dealt with issues related to the one that is object of our analysis, only four of them [9, 35–37] were specifically focussed on the cement sector and on the aspects addressed in this paper. Particularly,
- + Article [9] approached the process of optimising thermal energy consumption in La Robla cement factory in Tudela Veguñ, Spain, by means of using statistical tools (AI was not applied). The initial planning, along with several initial methodological aspects of this study, served as a reference for our study.
 - + Article [37] approached a simulation model conducted in four cement plants in South Africa, which enabled as much as 7.1% energy savings (electricity savings and thermal energy savings). To reach those savings, a managing methodology, which considered the crude mill, the kiln, the coal mill, crushers, cement mills and other auxiliary machinery, was carried out. Hence, a model was developed to distribute the load among the different days of the week and seasons of the year and always searching for the off-peak energy times. Although it also addressed thermal energy cost, the analysis of this methodology was extremely useful for the present research when shifting electricity consumption to the most economical off-peak periods.
 - + Article [36] approached the problem of the cement market in South Africa, where a remarkable increase in electricity costs took place, which brought about an important pressure on international producers. An energy management system (EMS) was implemented in order to cut the electricity bill. This system, apart from controlling the periods of highest consumption, shifted electricity demand to the most economical daily off-peak times.
 - + Article [35] focussed on managing and controlling thermal energy. Some of the factors detailed in this article were quite useful for our research, although they did not refer to electricity consumption.
- (b) Six of the articles [4, 16, 17, 28, 39, 40] focussed on the study of different questions related to the optimisation of electricity purchase in the markets. Although those questions were of interest for our research as a whole, they did not tackle specific aspects that are addressed in this paper.
- (c) Although two of the articles [2, 3] provided a generic reference to AI and/or to industry in general, they did not address in depth any of the aspects analysed in the

present research. Therefore, they were used for general matters.

In addition to these articles, a doctoral thesis was analysed [13]. It studied thermal energy savings in a clinker kiln, as well as electricity savings in cement grinding by introducing certain modifications to different variables.

Due to the scarce contributions of the previous existing literature, the consultations with experts that are detailed in the following session were considered to be fundamental and extremely interesting. They complemented the information obtained from the literature and specified it with information collected from highly specialised sources in order to develop a proposal which was adapted to real and current needs of the sector.

3.2.2 Surveys and expert panel

Following the systematic review of literature, a study based on surveys and an expert panel was conducted thanks to the involvement of a total of 42 managers.

The expert panel has proved to be an effective method for improving the development of a research study, as well as for providing additional information on its quality [5, 18]. Surveys and the expert panel provided us with relevant information to design the methodology that will enable us to optimise the cost of electricity by using AI.

Quinlan et al. [32] state that when bringing together a group of experts it is fundamental not only to count on experts in the specific field under evaluation, but also on reviewers with an interdisciplinary experience. The experts that were chosen for our research met this requirement. In all cases, they were professionals with between 22 and 41 years of experience in different posts in the sector. Economists, civil engineers, industrial engineers, mine engineers and chemists, among others, were consulted.

In addition, it may be stated that all cement companies that operate in Spain were considered when selecting the group of experts. The involvement of the experts brought great added value to our research thanks to their high experience and knowledge of the sector.

Surveys, mainly used to obtain quantitative data, were conducted among a total of 11 managers. This information was extremely useful for arriving at another of the results of our research. A quite utterly novel quantitative study about the composition of regulated electricity cost in Spanish cement industry was carried out. It was of great use for the optimisation of regulated electricity costs in our research.

A total of 31 experts participated in the expert panel, and they provided qualitative data on electricity prices behaviour, operational costs of production machinery, the process variables that affect electricity consumption, flexibility in start/stop conditions of production machinery and

on operational routines. Five of the thirty-one experts that collaborated with qualitative data, those who were considered to be experts in AI, were asked to fill in a questionnaire in order to evaluate the adequate tools to be used for the development of our model.

For qualitative data collection from the panel of experts, two questionnaires and a phone survey were carried out:

- (1) A questionnaire to analyse regulated costs along with the major or minor influence of the different process variables. The variables that were selected by the experts were the ones that applied in the ANN architecture, which is represented schematically in Fig. 4.
- (2) A questionnaire to evaluate the most adequate tools to solve the problem raised in this article. As it has already been mentioned, five of the experts were specialists in AI. The use of ANN along with the backpropagation and genetic algorithms turned out to be the techniques selected by 80% of the experts consulted, which happened to be in line with the majorly used tools in the articles of the previous literature studied. [16, 17, 27, 38, 39].
- (3) Finally, to avoid group answers conditioning, phone surveys were carried out with each of the experts consulted. They aimed at deepening the answers that were given in the questionnaires.

Thanks to all the information gathered through the systematic review of literature, surveys and the expert panel in the cement sector, the most suitable AI tools for the optimisation of electricity consumption were selected and the model to be applied was developed.

3.3 Development of the working methodology: application of specific tools

The information used to assess electricity consumption was provided by Malaga cement factory (Spain), which belongs to FYM HeidelbergCement Group. The case of this factory is completely analogous to the rest of cement plants. Therefore, the results obtained will apply to any cement manufacturing plant.

The development of the methodology for the fulfilment of our objective has two different levels:

3.3.1 A methodology for operational electricity optimisation

The purpose is to reduce electricity consumption in a cement factory by modifying certain variables of the production process. To do this, power consumption and the variables on which it depends will be analysed in detail at each of the stages of the process [37].

There are 5 stages in the cement manufacturing process which are critical to electricity consumption (crushing, raw material grinding, clinker manufacturing, coal grinding and cement grinding). For each of those stages, the variables that affect electricity consumption and which could be easily influenced to optimise electricity consumption—without incurring large costs or investments—were identified. Then, 5 consumption functions were obtained, one for each stage, for which we will use the following nomenclature:

- $CE_{(i)}$: electricity consumption/crusher electricity power (kW).
- $CE_{(M)}$: electricity consumption/the raw mill electricity power (kW).
- $CE_{(H)}$: electricity consumption/kiln electricity power (kW).
- $CE_{(MC)}$: electricity consumption/coal mill electricity power (kW).
- $CE_{(MCEM)}$: electricity consumption/cement mill electricity power (kW).
- $CE(Fx)$: stage X net electricity consumption (kWh).
- $V(n)_{FX}$: “ n ” variable with impact on electricity consumption in stage X , being $n = 1, 2, \dots, X = 1, 3, 4, 5$ y 6 .
- ω_{nX} : variable “ n ” weight in stage X .
- u : the value obtained in each of the neurons in the network will be a linear regression model to which a bias (u) should be added.

The selection of the variables that impact on electricity consumption, which was made for each stage of the cement manufacturing process, will be described below.

1. Raw materials extraction /crushing (Stage 1: $F1$).

The two variables that can influence electricity consumption and which were included in the data collection process are:

- Size of crusher 1 output product (primary crusher): $V(1)_{F1(i)}$.
- Size of crusher 2 output product (secondary crusher): $V(2)_{F1(i)}$.

For each data pair (a–b, c–d, etc.), we will get an energy consumption result (X, Z, Y, \dots) (Table 1). The objective will be to minimise that energy consumption, that is, to determine the pair of $V(1)_{F1(i)}$ and $V(2)_{F1(i)}$ values which reduce $F1$ energy consumption to a minimum.

Electricity consumption will be calculated according to the following expressions:

$$CE(F1)_{(r)} = CE_{(r)}F[V(1)_{F1(i)}, * \omega 11 + V(2)_{F1(i)} * \omega 21 + u_1] * H_{(r)}$$

Fig. 4 Artificial neural network operation with backpropagation algorithm. Source. Own elaboration

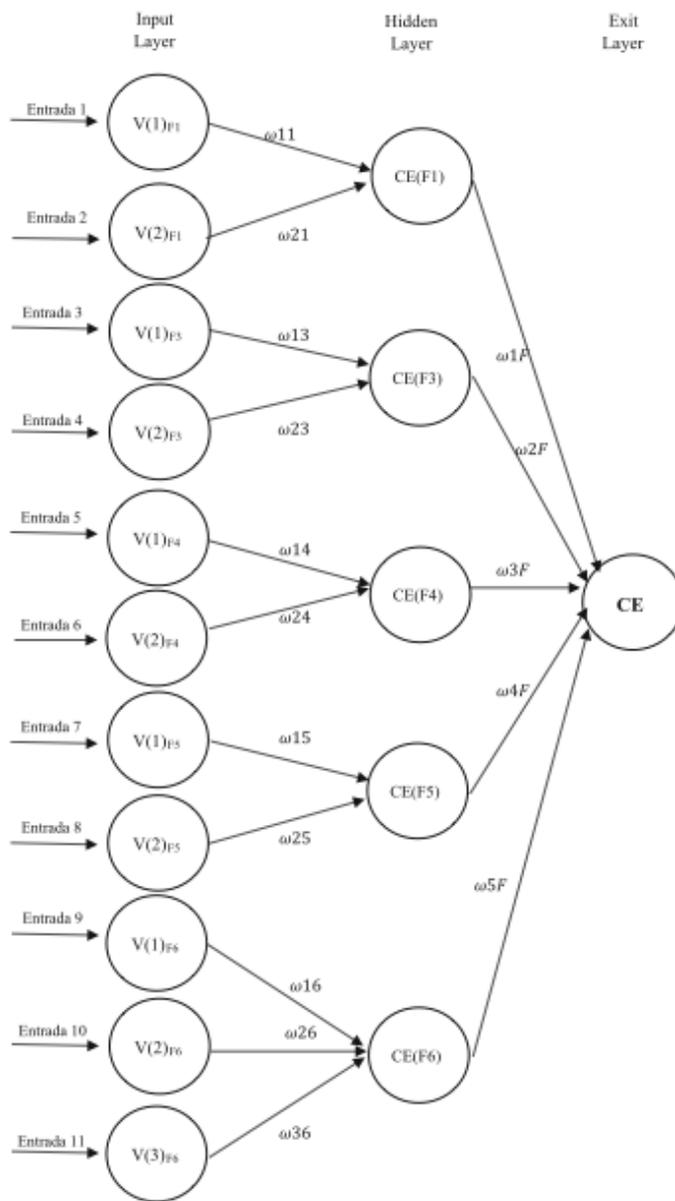


Table 1 Energy consumption result for each data pair (own elaboration)

$V(1)_{F1(r1)}$	$V(2)_{F1(r1)}$	$CE(F1)_{(r1)}$
a	b	X
c	d	Z
e	f	Y

$CE_{(r1)}$: Primary crusher electricity consumption.
 $H_{(r1)}$: Primary crusher operating hours.
 u_1 : Bias.

Each of the two variables— $V(1)$ and $V(2)$ —will affect the net energy consumption at this first stage ($CE(F1)_{(r1)}$) with a weight that will be represented" by " ω ".

For the secondary crusher, the consumption function would be similar:

$$CE(F1)_{(r2)} = CE_{(r2)}F[V(1)_{F1(r2)} * \omega 11 + V(2)_{F1(r2)} * \omega 21 + u_1] * H_{(r2)}$$

$CE_{(r2)}$: Secondary crusher electricity consumption.
 $H_{(r2)}$: Secondary crusher operating hours.
 u_2 : Bias.

The function that would integrate the two crushers would be:

$$CE(F1)_{(r1,r2)} = CE_{(r1)}F[V(1)_{F1(r1)} * \omega 11 + V(2)_{F1(r1)} * \omega 21 + u_1] * H_{(r1)} + CE_{(r2)}F[V(1)_{F1(r2)} * \omega 11 + V(2)_{F1(r2)} * \omega 21 + u_1] * H_{(r2)}$$

2. Raw mill (Stage 3: F3).

Since it is a ball mill, the four variables which most influence electricity consumption at this stage are:

- Input raw material size: $V(1)_{F3}$.
- Mill rotational speed: $V(2)_{F3}$.
- Mill filling level: $V(3)_{F3}$.
- Balls diameter: $V(4)_{F3}$.

Acting in the same way we did in the previous stage, we would get:

$$CE(F3) = CE_{(M)}F[V(1)_{F3} * \omega 13 + V(2)_{F3} * \omega 23 + u_3 + V(3)_{F3} * \omega 33 + V(4)_{F3} * \omega 43 + u_3] * H_{(M)}$$

$CE_{(M)}$: Raw mill power consumption.
 $H_{(M)}$: Raw mill operating hours.
 u_3 : Bias.

3. Clinker manufacturing (Stage 4: F4).

The two variables that were identified as the ones that most influence electricity consumption at this stage are:

- False air entering cyclones: $V(1)_{F4}$
- Clinker granulometry: $V(2)_{F4}$

Operating in the same way we did in the previous stage, we would get:

$$CE(F4) = CE_{(H)}F[V(1)_{F4} * \omega 14 + V(2)_{F4} * \omega 24 + u_4] * H_{(H)}$$

$CE_{(H)}$: Kiln electricity consumption.
 $H_{(H)}$: Kiln operating hours.
 u_4 : Bias.

4. Coal grinding (Stage 5: F5).

The following two variables were selected as the ones that may most influence electricity consumption at this stage:

- Carbon size/granulometry: $V(1)_{F5}$.
- Mill rotational speed: $V(2)_{F5}$.

Operating in the same way we did in the previous stage, we would get:

$$CE(F5) = CE_{(MC)}F[V(1)_{F5} * \omega 15 + V(2)_{F5} * \omega 25 + u_5] * H_{(MC)}$$

$CE_{(MC)}$: Coal mill electricity consumption.
 $H_{(H)}$: coal mill operating hours.
 u_5 : Bias.

5. Cement mill (Stage 6: F6).

In FYM Heidelberg Cement Group Malaga Factory, there are 3 cement mills: 5, 6 and 7.

A collection of data related to the four variables which can influence electricity consumption at this stage was carried out:

- Clinker size: $V(1)_{F6(M5,M6,M7)}$.
- Plaster size: $V(2)_{F6(M5,M6,M7)}$.
- Other additions size: $V(3)_{F6(M5,M6,M7)}$.
- Mill rotational speed: $V(4)_{F6(M5,M6,M7)}$.

Operating in the same way we did in the previous stage, we would get (Table 2).

$$CE(F6) = CE_{(MCEM)}F[V(1)_{F6} * \omega 16 + V(2)_{F6} * \omega 26 + u_6 + V(3)_{F6} * \omega 36 + V(4)_{F6} * \omega 46 + u_6] * H_{(MCEM)}$$

$CE_{(MCEM)}$: Cement mill electricity consumption.
 $H_{(H)}$: Cement mill operating hours.
 μ_6 : bias.

The aim will be to minimise electricity consumption at these 5 stages taking into consideration the above-mentioned 14 variables, so that if changes are required in the installation or the operational process in order to minimise electricity consumption, these neither imply a significant expense nor a high investment. It is simply a matter of finding the optimal combination of variables $V(n)F_x$ which minimise electricity consumption in the factory.

To optimise the 14 variables— $V(n)F_x$ —we will use the artificial neuronal network structure with the backpropagation algorithm that is shown in Fig. 4. It is in effect recommended by the analysed literature and experts contacted as the most effective tool. The 14 variables are present in the input layer. Each of them will affect electricity consumption at a different "i" stage ($CE F_i$). Such stages are included in the second layer of the neural network. Each variable will affect the consumption of the stage with a different weight. The weights are represented as ω_{ij} .

i: Number of the variable.
 j: Stage it affects.

In addition, the following will be made come true for each stage:

$$\omega_{11} + \omega_{21} = 1 // \omega_{13} + \omega_{23} = 1 // \omega_{14} + \omega_{24} = 1 //$$

$$\omega_{15} + \omega_{25} = 1 // \omega_{16} + \omega_{26} + \omega_{36} = 1.$$

The neural network will need to be trained. To do this, different combinations of actual values of the 14 variables— $V(n)F_i$ —which will be taken from the information collected in the historical database of the plant, will be introduced into the model. For each combination of variables, the factory will get a CE value of the real electricity consumption observed (y). The neural network will perform a series of calculations with random weights (ω_{ij}) for each variable, and different output values (s) will be obtained. The goal of the neural network will be to minimise the error (E) between the value actually obtained in the factory (y) and the output value obtained with the neural network (s).

$$E = \frac{1}{2}(E)^2$$

The error will be minimised by trying to make the differences between "y" and "s" as small as possible (hence, by minimising partial derivatives of electricity consumption depending on the weight). To simplify the result of the derivative, the error will be squared and multiplied by 1/2. Squaring

will eliminate the sign of the error, since it is not relevant for our aim whether it be positive or negative. Once the error is considered acceptable, we will be able to understand that the artificial neural network is sufficiently trained and that it offers acceptable values for ω_{ij} .

After the neural network is trained, the next step will be to introduce different combinations of variables $V(n)F_i$ into it so that it calculates the predicted electricity consumptions—CE—by using the weights that were regarded as valid. The ultimate goal of training our artificial neural network is to reduce electricity consumption to a minimum. In order for the model to have acceptable reliability, we will give each of the 14 variables different values.

The model will provide us with the combination of values of the variables that reduces electricity consumption to a minimum. The structure of the neural network with the backpropagation algorithm would be as follows.

3.3.2 A methodology for the optimisation of regulated electricity prices

It is possible to improve electricity efficiency cost in a cement factory by shifting electricity consumption to the most economical off-peak periods [35].

In Spain, high voltage tariffs (with a contracted power exceeding 450 kW in one of the periods, that is 6X access tariffs) offer 6 periods of time (P1, ..., P6) which range from the highest to the lowest cost. This tariff has different energy rates depending on the period of time in which it is consumed, so that the bill will reflect the energy consumed in each of the periods and the corresponding rate for each period, with P1 being the most expensive period and P6 the cheapest one. Periods are distributed through the year according to the following table (Fig. 5).

The objective will be to optimise the cost of energy by focussing on the €/kWh, that is always taking the different periods (P1, P2, ..., P6) into consideration in order to use the cheapest possible kWh.

In this section, possible decreases in contracted power will also be determined, when possible, in order to reduce fixed cost in the electricity bill. In both cases genetic algorithms will be used.

The steps to be followed in this methodological development are as follows:

Step (B1): The electricity consumption function for each stage of the cement manufacturing process (9 functions) will be determined for each of the 6 periods (P1, ..., P6). The cement manufacturing process can be seen in Fig. 1. We will use the following nomenclature:

- $CE(FX)$. Total electricity consumption in stage X. It will be measured in kWh.

Table 2 Energy consumption result for each data pair (own elaboration)

$V(1)_{F6(M5, M6, M7)}$	$V(2)_{F6(M5, M6, M7)}$	$V(3)_{F6(M5, M6, M7)}$	$V(4)_{F6(M5, M6, M7)}$	$CE(F6)_{(M5, M6, M7)}$
a	B	c	d	X
e	F	g	h	Z
i	J	k	l	Y

Energy calendars in Iberian Peninsula

6.1.-A taiff in working days

HOURS	0-1	1-2	2-3	3-4	4-5	5-6	6-7	7-8	8-9	9-10	10-11	11-12	12-03	13-06	14-5	15-16	16-17	17-08	18-19	19-20	20-21	21-22	22-23	23-24
January	P6	P2	P2	P1	P1	P1	P2	P2	P2	P2	P2	P1	P1	P1	P2	P2	P2							
February	P6	P2	P2	P1	P1	P1	P2	P2	P2	P2	P2	P1	P1	P1	P2	P2	P2							
March	P6	P4	P4	P4	P4	P4	P4	P4	P4	P3	P3	P3	P3	P3	P3	P4	P4							
April	P6	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5							
May	P6	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5							
1-15 June	P6	P4	P3	P3	P3	P3	P3	P3	P4	P4	P4	P4	P4	P4	P4	P4	P4	P4						
16-30 June	P6	P2	P2	P2	P1	P1	P1	P1	P1	P1	P1	P1	P1	P2	P2	P2	P2	P2						
July	P6	P2	P2	P2	P1	P1	P1	P1	P1	P1	P1	P1	P1	P2	P2	P2	P2	P2						
August	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6	P6									
September	P6	P4	P3	P3	P3	P3	P3	P3	P4	P4	P4	P4	P4	P4	P4	P4	P4	P4						
October	P6	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5	P5						
November	P6	P4	P4	P4	P4	P4	P4	P4	P4	P4	P3	P3	P3	P3	P3	P3	P4	P4						
December	P6	P2	P2	P1	P1	P1	P2	P2	P2	P2	P2	P2	P1	P1	P1	P2	P2	P2						



Fig. 5 Energy calendars in Iberian Peninsula. Distribution of time periods for electricity tariffs. (UCS ENERGÍA. <http://ucsennergia.com/calendarios-energeticos/>—RD. 11/64 2001)

- $CE_{FX} P(Y)$. Hourly electricity consumption in stage X during Y period. It will be measured in kw.
- $H_{FX} P(Y)$. Working hours in stage X during period Y . It will be measured in h.

Being $X = 1, \dots, 9$ and $Y = 1, \dots, 6$.

Electricity consumption functions would be:

1.1. Extraction of raw materials/crushing It includes electricity consumption from the extraction of raw materials from the quarry to the entrance to the pre-homogenisation park (Stage 1: F1).

In the case of FYM HeidelbergCement Group factory in Malaga, there are two crushers. The function would be:

-

$$CE_{F1}(1)_{(t1,t2)} = CE_{F1} P(1)_{(t1)} * H_{F1} P(1)_{(t1)} + CE_{F1} P(1)_{(t2)} * H_{F1} P(1)_{(t2)} + CE_{F1} P(2)_{(t1)} * H_{F1} P(2)_{(t1)} + CE_{F1} P(2)_{(t2)} * H_{F1} P(2)_{(t2)} + CE_{F1} P(3)_{(t1)} * H_{F1} P(3)_{(t1)} + CE_{F1} P(3)_{(t2)} * H_{F1} P(3)_{(t2)} + CE_{F1} P(4)_{(t1)} * H_{F1} P(4)_{(t1)} + CE_{F1} P(4)_{(t2)} * H_{F1} P(4)_{(t2)} + CE_{F1} P(5)_{(t1)} * H_{F1} P(5)_{(t1)} + CE_{F1} P(5)_{(t2)} * H_{F1} P(5)_{(t2)} + CE_{F1} P(6)_{(t1)} * H_{F1} P(6)_{(t1)} + CE_{F1} P(6)_{(t2)} * H_{F1} P(6)_{(t2)}$$

1.2. Homogenisation It includes transportation to the raw mill on crushing belts (Stage 2: F2).

$$CE_{F2} = CE_{F2} P(1) * H_{F2} P(1) + CE_{F2} P(2) * H_{F2} P(2) + CE_{F2} P(3) * H_{F2} P(3) + CE_{F2} P(4) * H_{F2} P(4) + CE_{F2} P(5) * H_{F2} P(5) + CE_{F2} P(6) * H_{F2} P(6)$$

1.3. *Raw mill* Electricity consumption of the mill and transportation of the elevators to the cyclone tower entrance (Stage: F3).

$$\bullet CE(F3) = CE_{F3}P(1)*H_{F3}P(1) + CE_{F3}P(2)*H_{F3}P(2) + CE_{F3}P(3)*H_{F3}P(3) + CE_{F3}P(4)*H_{F3}P(4) + CE_{F3}P(5)*H_{F3}P(5) + CE_{F3}P(6)*H_{F3}P(6)$$

1.4. *Clinker manufacturing* Cyclones electricity consumption, clinker kiln, cooling fans, etc. (Stage 4: F4).

$$\bullet CE(F4) = CE_{F4}P(1)*H_{F4}P(1) + CE_{F4}P(2)*H_{F4}P(2) + CE_{F4}P(3)*H_{F4}P(3) + CE_{F4}P(4)*H_{F4}P(4) + CE_{F4}P(5)*H_{F4}P(5) + CE_{F4}P(6)*H_{F4}P(6)$$

1.5. *Coal grinding* (Stage 5: F5).

$$\bullet CE(F4) = CE_{F5}P(1)*H_{F5}P(1) + CE_{F5}P(2)*H_{F5}P(2) + CE_{F5}P(3)*H_{F5}P(3) + CE_{F5}P(4)*H_{F5}P(4) + CE_{F5}P(5)*H_{F5}P(5) + CE_{F5}P(6)*H_{F5}P(6)$$

1.6. *Cement mill* (Stage 6: F6).

In FYM HeidelbergCement Group factory in Malaga, there are three cement mills: (5, 6 and 7). The function would be:

$$\bullet CE(F6)_{(M5,M6,M7)} = CE_{F6}P(1)_{(M5)}*H_{F6}P(1)_{(M5)} + CE_{F6}P(1)_{(M6)}*H_{F6}P(1)_{(M6)} + CE_{F6}P(1)_{(M7)}*H_{F6}P(1)_{(M7)} + CE_{F6}P(2)_{(M5)}*H_{F6}P(2)_{(M5)} + CE_{F6}P(2)_{(M6)}*H_{F6}P(2)_{(M6)} + CE_{F6}P(2)_{(M7)}*H_{F6}P(2)_{(M7)} + CE_{F6}P(3)_{(M5)}*H_{F6}P(3)_{(M5)} + CE_{F6}P(3)_{(M6)}*H_{F6}P(3)_{(M6)} + CE_{F6}P(3)_{(M7)}*H_{F6}P(3)_{(M7)} + CE_{F6}P(4)_{(M5)}*H_{F6}P(4)_{(M5)} + CE_{F6}P(4)_{(M6)}*H_{F6}P(4)_{(M6)} + CE_{F6}P(4)_{(M7)}*H_{F6}P(4)_{(M7)} + CE_{F6}P(5)_{(M5)}*H_{F6}P(5)_{(M5)} + CE_{F6}P(5)_{(M6)}*H_{F6}P(5)_{(M6)} + CE_{F6}P(5)_{(M7)}*H_{F6}P(5)_{(M7)} + CE_{F6}P(6)_{(M5)}*H_{F6}P(6)_{(M5)} + CE_{F6}P(6)_{(M6)}*H_{F6}P(6)_{(M6)} + CE_{F6}P(6)_{(M7)}*H_{F6}P(6)_{(M7)}$$

1.7. *Transportation* (Stage 7: F7).

$$\bullet CE(F7) = CE_{F7}P(1)*H_{F7}P(1) + CE_{F7}P(2)*H_{F7}P(2) + CE_{F7}P(3)*H_{F7}P(3) + CE_{F7}P(4)*H_{F7}P(4) + CE_{F7}P(5)*H_{F7}P(5) + CE_{F7}P(6)*H_{F7}P(6)$$

1.8. *Packaging* (Stage 8: F8).

$$\bullet CE(F8) = CE_{F8}P(1)*H_{F8}P(1) + CE_{F8}P(2)*H_{F8}P(2) + CE_{F8}P(3)*H_{F8}P(3) + CE_{F8}P(4)*H_{F8}P(4) + CE_{F8}P(5)*H_{F8}P(5) + CE_{F8}P(6)*H_{F8}P(6)$$

Table 3 Powers contracted by Malaga factory (own elaboration)

	Mw
MAXIMUM POWER—TWO TRANSFORMERS	20 + 20
CONTRACTED POWER IN P1	14
CONTRACTED POWER IN P2	14
CONTRACTED POWER IN P3	17.2
CONTRACTED POWER IN P4	17.2
CONTRACTED POWER IN P5	17.2
CONTRACTED POWER IN P6	17.4

1.9. *Auxiliary services* Offices and other services that are not directly related to production (Stage 9: F9).

$$\bullet CE(F9) = CE_{F9}P(1)*H_{F9}P(1) + CE_{F9}P(2)*H_{F9}P(2) + CE_{F9}P(3)*H_{F9}P(3) + CE_{F9}P(4)*H_{F9}P(4) + CE_{F9}P(5)*H_{F9}P(5) + CE_{F9}P(6)*H_{F9}P(6)$$

Genetic algorithms will be used to optimise—reduce—electricity consumption in each of the 9 stages of the process. Since $CE_{FX}P(Y)$ are fixed terms of the functions, genetic algorithms will operate on the variable terms $H_{FX}P(Y)$. These algorithms continuously apply mechanisms for the selection, recombination and mutation of chromosomes. In our case, the mechanisms will consist of recombining $H_{FX}P(Y)$, so that they are always used in descending order ($P6, P5, \dots, P1$); that is, operating hours of the equipment in $P(6)$ will be first used, then those in $P(5), P(4), (\dots)$, and finally the operating hours of the equipment in $P(1)$ will be used. This evolutive recombination cycle of the equation will continue until a stop or convergence criterion is met [32]. In our case, the criterion will be a certain % of reduction in electricity consumption.

STEP B2 On the one hand, in order to avoid exceeding access rate, six functions which limit this possibility were defined. Machinery power demand (Mw) for each of the periods should never exceed the contracted power for that period.

On the other hand, by formulating other 6 algorithmic functions, the model will attempt to reduce the factory contracted power for each of the periods. Hence, if consumption for a period P_i was lower than an established % of the maximum contracted and was set in C' , less power could be contracted to lower the cost of the access rate in that period.

A total of 12 functions would be applied.

The powers contracted by Malaga factory are as follows (Table 3).

To develop the functions related to access rates, the following nomenclature will be used:

$CE(P_Y)$: energy consumption in Y period. $Y = 1, 2, \dots, 6$.

Electricity consumption in each period will be the sum of the consumptions registered for each of the stages in which

we divided the cement manufacturing process. The maximum power limit for each established period can never be exceeded.

Consumption in stage 1 must take into consideration that two crushers are being used. In stage 6, three cement mills will be operating: 5, 6 and 7.

B2.1. Functions to limit energy consumption in P1:

- $CE(P_1) = CE_{F1}P(1) + CE_{F2}P(1) + CE_{F3}P(1) + CE_{F4}P(1) + CE_{F5}P(1) + CE_{F6}P(1) + CE_{F7}P(1) + CE_{F8}P(1) + CE_{F9}P(1) \leq 14 \text{ Mw}$
- If $0 < CE(P_1) \leq C'$ Mw (1 month under normal conditions) → Access rate may be reduced.

B2.2. Functions to limit energy consumption in P2:

- $CE(P_2) = CE_{F1}P(2) + CE_{F2}P(2) + CE_{F3}P(2) + CE_{F4}P(2) + CE_{F5}P(2) + CE_{F6}P(2) + CE_{F7}P(2) + CE_{F8}P(2) + CE_{F9}P(2) \leq 14 \text{ Mw}$.
- If $0 < CE(P_2) \leq C'$ Mw (1 month under normal conditions) → Access rate may be reduced.

B2.3. Functions to limit energy consumption in P3:

- $CE(P_3) = CE_{F1}P(3) + CE_{F2}P(3) + CE_{F3}P(3) + CE_{F4}P(3) + CE_{F5}P(3) + CE_{F6}P(3) + CE_{F7}P(3) + CE_{F8}P(3) + CE_{F9}P(3) \leq 17.2 \text{ Mw}$.
- If $0 \leq CE(P_3) \leq C'$ (1 month under normal conditions) → Access rate may be reduced.

B2.4. Functions to limit energy consumption in P4:

- $CE(P_4) = CE_{F1}P(4) + CE_{F2}P(4) + CE_{F3}P(4) + CE_{F4}P(4) + CE_{F5}P(4) + CE_{F6}P(4) + CE_{F7}P(4) + CE_{F8}P(4) + CE_{F9}P(4) \leq 17.2 \text{ Mw}$
- If $0 \leq CE(P_4) \leq C'$ (1 month under normal conditions) → Access rate may be reduced.

B2.5. Functions to limit energy consumption in P5:

- $CE(P_5) = CE_{F1}P(5) + CE_{F2}P(5) + CE_{F3}P(5) + CE_{F4}P(5) + CE_{F5}P(5) + CE_{F6}P(5) + CE_{F7}P(5) + CE_{F8}P(5) + CE_{F9}P(5) \leq 17.2 \text{ Mw}$.
- If $0 \leq CE(P_5) \leq C'$ (1 month under normal conditions) → Access rate may be reduced.

B2.6. Functions to limit energy consumption in P6:

- $CE(P_6) = CE_{F1}P(6) + CE_{F2}P(6) + CE_{F3}P(6) + CE_{F4}P(6) + CE_{F5}P(6) + CE_{F6}P(6) + CE_{F7}P(6) + CE_{F8}P(6) + CE_{F9}P(6) \leq 17.4 \text{ Mw}$

- If $0 \leq CE(P_5) \leq C'$ (1 month under normal conditions) → Access rate may be reduced.

B2.7. Limiting power by extension rights: the contracted power must be $< 20 \text{ Mw}$:

The factory in our case has two parallel redundant 20 Mw transformers. The energy consumption functions of the different periods should not exceed the 20 Mw limit.

STEP B3: "operation and sales restrictions" functions

The model will use another 9 functions that will be called "Operation and Sales Restriction Functions". They will represent the following:

- The maximum production capacity of each stage of the cement manufacturing process minus the maximum capacity of next stage should be > 0 , and at the same time \leq than the storage capacity of raw material, fuel, by-product or final product at each stage of the process (7 functions).
- Time constraints (2 functions).

For these new functions, we will take into consideration the following nomenclature and data measured in tons/hour (t/h) (Malaga factory):

- $CP_{F1(1)}$: maximum production capacity per hour, in the extraction of raw materials stage. 300 t/h.
- $CP_{F1(2)}$: maximum production capacity per hour, in the extraction of raw materials stage. 520 t/h.
- CAMp: maximum storage capacity for crushed raw materials.
- CP_{F2} : maximum production capacity per hour in the homogenisation stage. 320 t/h.
- CAMpH: maximum homogenised raw material capacity.
- CP_{F3} : maximum production capacity per hour in the crude grinding stage. 550 t/h.
- CACr: maximum crude oil storage capacity.
- CP_{F4} : maximum production capacity per hour in clinker manufacturing process/kiln. For raw materials: 240 t/h. For clinker: 154 t/h.
- CACK: maximum clinker storage capacity.
- CP_{F5} : maximum production capacity per hour in the coal grinding stage. 17.1 t/h.
- CACb: maximum coal storage capacity.
- CP_{F6} : maximum production capacity per hour in the cement grinding stage:
 - $CP_{F6(M5)}$ —Cement mill 5: 29.2 t/h.
 - $CP_{F6(M6)}$ —Cement mill 6: 78 t/h.
 - $CP_{F6(M7)}$ —cement mill 7: 34.3 t/h.
- CP_{F7} : maximum production capacity per hour in the transportation stage.

- CASL_CEM(Z): maximum cement storage capacity in silo Z.
- CP_{F8}: maximum production capacity per hour in the packing stage.

There are two packing lines with the following capacities:

- Line 1: 67 t/h (2700 sacks).
- Line 2: 55 t/h (2200 sacks).
- CAEns: maximum storage capacity in sacks storehouse.
- CP_{F9}: maximum production capacity per hour in the auxiliary services stage.
- VE_{CEM(Z)}: SALES of packaged cement type Z, being $Z = 1, \dots, n$.
- VG_{CEM(Z)}: sales of bulk cement type Z, being $Z = 1, \dots, n$.
- CC: consumption of coal, measured in t/h.

1. Crusher maximum capacity. Stage 1 Extraction of raw materials.

- CAMp \geq CP_{F1(1)}*[H_{F1P(1)}(1)₍₁₎ + H_{F1P(2)}(1)₍₁₎ + H_{F1P(3)}(1)₍₁₎ + H_{F1P(4)}(1)₍₁₎ + H_{F1P(5)}(1)₍₁₎ + H_{F1P(6)}(1)₍₁₎] + CP_{F1(2)}*[H_{F1P(1)}(1)₍₂₎ + H_{F1P(2)}(1)₍₂₎ + H_{F1P(3)}(1)₍₂₎ + H_{F1P(4)}(1)₍₂₎ + H_{F1P(5)}(1)₍₂₎ + H_{F1P(6)}(1)₍₂₎] - CP_{F2}*[H_{F1P(1)} + H_{F1P(2)} + H_{F1P(3)} + H_{F1P(4)} + H_{F1P(5)} + H_{F1P(6)}] \geq 0.

Time constraints function:

$$H_{F1P(1)}(1)_{(1)}, H_{F1P(2)}(1)_{(1)}, H_{F1P(3)}(1)_{(1)}, H_{F1P(4)}(1)_{(1)}, H_{F1P(5)}(1)_{(1)}, H_{F1P(6)}(1)_{(1)}, H_{F1P(1)}(1)_{(2)}, H_{F1P(2)}(1)_{(2)}, H_{F1P(3)}(1)_{(2)}, H_{F1P(4)}(1)_{(2)}, H_{F1P(5)}(1)_{(2)}, H_{F1P(6)}(1)_{(2)} \in 7-23 \text{ hours}$$

2. Homogenisation stage maximum capacity.

- CAMpH \geq CP_{F2}*[H_{F2P(1)} + H_{F2P(2)} + H_{F2P(3)} + H_{F2P(4)} + H_{F2P(5)} + H_{F2P(6)}] - CP_{F3}*[H_{F3P(1)} + H_{F3P(2)} + H_{F3P(3)} + H_{F3P(4)} + H_{F3P(5)} + H_{F3P(6)}] \geq 0

No time constraints.

3. Raw material mill maximum capacity.

- CACr \geq CP_{F3}*[H_{F3P(1)} + H_{F3P(2)} + H_{F3P(3)} + H_{F3P(4)} + H_{F3P(5)} + H_{F3P(6)}] - CP_{F4}*[H_{F4P(1)} + H_{F4P(2)} + H_{F4P(3)} + H_{F4P(4)} + H_{F4P(5)} + H_{F4P(6)}] \geq 0

No time constraints.

4. Clinker manufacturing maximum capacity (kiln).

- CACk \geq CP_{F4}*[H_{F4P(1)} + H_{F4P(2)} + H_{F4P(3)} + H_{F4P(4)} + H_{F4P(5)} + H_{F4P(6)}] - CP_{F6}*[H_{F6P(1)} + H_{F6P(2)} + H_{F6P(3)} + H_{F6P(4)} + H_{F6P(5)} + H_{F6P(6)}] \geq 0

No time constraints.

5. Coal mill maximum capacity.

- CACb \geq CP_{F5}*[H_{F5P(1)} + H_{F5P(2)} + H_{F5P(3)} + H_{F5P(4)} + H_{F5P(5)} + H_{F5P(6)}] - CC*[H_{F6P(1)} + H_{F6P(2)} + H_{F6P(3)} + H_{F6P(4)} + H_{F6P(5)} + H_{F6P(6)}] \geq 0

No time constraints.

6. Cement mill maximum capacity/maximum capacity for transportation.

We will have one function for each of the Z types of cement that is manufactured in the factory, being $Z = 1, 2, \dots, n$.

- CASL_CEM(Z) \geq CP_{F6(M5)}*[H_{F6P(1)}(M5) + H_{F6P(2)}(M5) + H_{F6P(3)}(M5) + H_{F6P(4)}(M5) + H_{F6P(5)}(M5) + H_{F6P(6)}(M5)] + CP_{F6(M6)}*[H_{F6P(1)}(M6) + H_{F6P(2)}(M6) + H_{F6P(3)}(M6) + H_{F6P(4)}(M6) + H_{F6P(5)}(M6) + H_{F6P(6)}(M6)] + CP_{F6(M7)}*[H_{F6P(1)}(M7) + H_{F6P(2)}(M7) + H_{F6P(3)}(M7) + H_{F6P(4)}(M7) + H_{F6P(5)}(M7) + H_{F6P(6)}(M7)] - CP_{F7}[H_{F7P(1)} + H_{F7P(2)} + H_{F7P(3)} + H_{F7P(4)} + H_{F7P(5)} + H_{F7P(6)}] - CP_{F8}*[H_{F8P(1)} + H_{F8P(2)} + H_{F8P(3)} + H_{F8P(4)} + H_{F8P(5)} + H_{F8P(6)}] - VG_{CEM(Z)} \geq 0

No time constraints.

7. Packing maximum capacity.

We will have a function for each of the Z types of cement that is manufactured in the factory, being $Z = 1, 2, \dots, n$.

- CAEns \geq CP_{F8}*[H_{F8P(1)} + H_{F8P(2)} + H_{F8P(3)} + H_{F8P(4)} + H_{F8P(5)} + H_{F8P(6)}] - VE_{CEM(Z)} \geq 0.

VE_{CEM(Z)}: sales of already packed type Z cement, being $Z = 1, \dots, n$.

Time constraints function:

$$H_{F8P(1)}, H_{F8P(2)}, H_{F8P(3)}, H_{F8P(4)}, H_{F8P(5)}, H_{F8P(6)} \in 7-23 \text{ h.}$$

8. Auxiliary services maximum capacity.

In this stage, there would be no such constraints.

Taking into consideration the demand for clinker and different types of cement, electricity consumption functions, restrictions on access rates and on available transformers, as well as operating and selling restrictions, the use of genetic algorithms will make the system suggest us the changes we should make to move production to lower cost periods (P6, P5, P4, etc.).

Genetic algorithms continuously apply mechanisms of selection, recombination and mutation of chromosomes, which in our case would be the different regulated prices, until an optimal value is reached.

4 Results: innovation brought by the model

First of all, the research major novelty is that the model that evolved was an absolutely innovative model, since it was developed by applying a series of basic algorithms which were based on AI techniques, though expressly addressed to the cement sector.

Thanks to the experts contributions and the studied bibliography, it was possible to include the variables that condition not only electricity consumption, but also the knowledge of machinery behaviour and operational processes in cement plants.

Secondly, the global research developed resulted in a model that integrates three complementary aspects, which enables a higher level of electricity cost optimisation than that obtained in previous researches, which focussed on one of the aspects in isolation. This question implies an innovation in the research, as well as in the resulting model.

The three aspects on which the model for electricity cost optimisation was focussed are described below. Only the first two are the object of this paper.

- (1) Process variables which incur zero or very low costs [36].
- (2) Regulated electricity costs. Machinery running is shifted to the most economical off-peak times [37].
- (3) Price of electricity in the market [16, 28, 39, 40].

Thirdly, due to the scarce previous literature, a panel of experts was held, which provided qualitative and quantitative information to approach the issue from a realistic, updated and complete business viewpoint. The experts enabled the gathering of information on all Spanish cement factories.

The use of the expert panel represents an innovative element in researches in this field, since none of them had previously made use of consultations with experts.

The panel of experts provided better results for the model, since their expertise made it possible to select more and better process variables to optimise the cost of electricity. Moreover, the experts were extremely useful when selecting the most appropriate AI tools.

Fourthly, quantitative data obtained from expert surveys provided another of the main results of the research. It is a quite utterly novel quantitative study about the composition of regulated electricity cost in Spanish cement industry. The study was of great use for the optimisation of regulated electricity costs in our research. It will also provide the basis for

other future researches about electrical aspects in Spanish cement sector.

Fifthly, we would like to remark that the model obtained for the optimisation of electricity cost can be applied to any of the cement factories that are distributed throughout the world, since the production process is the same as that followed by the factory considered. If it was chosen to be applied in other countries, only the composition of regulated electricity costs should be considered, along with the different factors that could affect electricity price formation in the market.

Furthermore, by introducing certain modifications to the initial parameters, the model could be applied to other electro-intensive processing industries.

Consequently, we would like to highlight that the results obtained can serve as a basis for future researches, since the model is perfectly able to be reproduced for other industrial sectors. Therefore, a remarkably interesting line of research for other sectors or even for intersectoral comparison is opened.

5 Conclusions

1. It is possible to optimise electricity cost in cement factories by means of influencing certain process variables and incurring zero or very low costs, as it is shown in [36, 37]. Through ANN we will obtain the optimal combination of these variables, which minimises electricity consumption in the production process.
2. We can reduce electricity cost by optimising regulated electricity prices, that is, by shifting the use of that machinery with a higher electricity consumption in the factory to periods with lower regulated electricity costs [36, 37]. By means of using genetic algorithms we will optimise the costs of regulated electricity prices.
3. The model resulting from this research process may be applied to any cement factory in the world. By modifying initial parameters, it could be applied to other electro-intensive processing industries. It is therefore a model that offers great versatility.
4. This model enhances products development—cement and other industrial products. The methodology brought forth contributes to influence and transform the way we live and work, since it makes industries more competitive. Competitiveness helps companies generate more activity, added value and employment [2, 3].
5. Owing to its complexity, this article has its limitation, since it only addresses a part of a broader research process which integrates three different approaches to the optimisation of electricity cost in cement factories. In particular, the present paper approaches certain variables in the cement manufacturing production process and the optimisation of regulated electricity costs.

Author's contribution Conceptualisation: The four authors worked in the ideas and evolution of the article. Methodology: All authors contributed to the development of the methodology during the whole process. Software: No software was used in this article. Validation: The reproducibility of results was carried out by Manuel Parejo, Pedro Mora and Benito Navarrete. Formal Analysis: Statistical and mathematical techniques to analyse and synthesise study data were applied by Manuel Parejo and Pedro Mora. Investigation: All authors worked in the research and investigation process, and data collection. Resources: The four authors provided study materials and analysis tools. Data Curation: The four authors participated in this matter. Writing original draft: Manuel Parejo wrote the original draft with the help of the other three authors. Writing—Reviews and Editing: The four authors reviewed the original article and worked in the definitive article. Visualisation: The four authors contributed to the presentation of the published work. Supervision: The four authors worked in this matter. Project Administration: All authors contributed to the coordination of the research activity planning. Funding Acquisition: There was no financial support for this project.

Funding Open Access funding provided thanks to the CRUE-CSIC agreement with Springer Nature. The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Declarations

Conflict of interest We have no conflicts of interest to disclose, but we do respectfully request that Dr. Salmerón.

Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. If material is not included in the article's Creative Commons licence and your intended use is not permitted by statutory regulation or exceeds the permitted use, you will need to obtain permission directly from the copyright holder. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0/>.

References

- Alfala-Luque R, Medina-Lopez CA, Dey PK (2013) Supply chain integration framework using literature review. *Prod Plan Control: Manag Oper* 24(8–9):800–817. <https://doi.org/10.1080/09537287.2012.666870>
- Andrew N (2017) Artificial intelligence is the new electricity. *Newstex Global Business Blogs*
- Andrew NG, Zhang T (2017) The optimistic promise of artificial intelligence; how AI is going to be like electricity, transforming every industry. *Wall Street J* (online). (ISSN: 2574 9579)
- Azadeh A, Sohrabi P, 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*. June, 2015. (ISSN: 1443–3015).
- Barbosa M, Grayson D (2009) Site visits: assessing and improving the climate for women in physics. In Harline BK, Horton KR, Kaicher CM (eds) AIP conference proceedings. American Institute of Physics. <https://doi.org/10.1063/1.3137748>
- Barlow M (2015) Learning to love data science. Exploring Predictive Analytics, Machine Learning, Digital Manufacturing and Supply Chain Optimisation. United States of America
- Bramer M (2007) Principles of data mining. Springer, London (2007)
- Chaoqum M, Gaojun G, Jianhong W (2007) Data clustering theory, algorithms and applications. United States of America
- Castañón AM, García-Granda S, Guerrero A, Lorenzo MP, Angulo S (2014) Energy and environmental savings via optimisation of the production process at a Spanish cement Factory. *J Clean Prod Elsevier* (ISSN: 0959-6526)
- Cronin P, Ryan F, Coughlan M (2008) Undertaking a literature review: a step-by-step approach. *Br J Nurs* 17(1):38–43
- Eurostat (2019) Estadísticas de precios eléctricos. <https://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do>
- Fabbe-Costes N, Jahre M, Roussat C (2009) Supply chain integration: the role of logistics service providers. *Int J Prod Perform Manag* 58(1):71–91
- Gilvonio LR, Inche-Mitna JL (2005) El Ahorro de energía en la industria cementera como estrategia de la excelencia operativa (tesis doctoral). Universidad Mayor de San Marcos, Lima
- Hemingway P, Brereton N (2009) What is a systematic review? Series, 2nd edn. Hayward Medical Communications, Newmarket
- Hernández J, Ramírez MJ, Ferri C (2004) Introducción a la minería de datos. Pearson Educación, Madrid
- Hurtado, L., Quintero, O.L. & García, J. J., (2014). Estimación del precio de oferta de la energía eléctrica en Colombia mediante inteligencia artificial. *Rev Mét Cuant Para Econ Empresa*. ISSN: 1886-516X
- Khotanzad AI (2018) Using artificial intelligence to develop electricity load forecasts. *Power Magazine* 62(6):1
- Lane J, Wade J, Down L, Bonnington S, Holding P, Lennon T (2011) A peer review intervention for monitoring and evaluating sites (PRIME) that improved randomized controlled trial conduct and performance. *J Clin Epidemiol* 64(6):628–636
- Lara J (2014) Minería de datos. Centro de Estudios Financieros, Madrid
- Michalewicz Z (1999) Genetic algorithms + data structures = evolution programs. Ed. Springer
- Nagi J (2009) An intelligent system for detection of non-technical losses in Tenaga Nasional Berhad (TNB) Malaysia low voltage distribution network. University Tenaga Nasional, Malasia
- Nagi J, Yap KS, Tiong SK, Ahmed SK, Mohamad M (2010) Nontechnical loss detection for metered customers in power utility using support vector machines. *IEEE Trans Power Deliv* 25(2):1162–1171
- Nagi J, Mohammad AM, Yap KS, Tiong SK, Ahmed SK (2008) Non-technical loss analysis for detection of electricity theft using support vector machines. *IEEE International Conference on Power and Energy*, pp 907–912
- Nagi J, Yap KS, Nagi F, Koh SK, Ahmed SK (2010) NTL detection of electricity theft and abnormalities for large power consumers in TNB Malaysia. In: *IEEE SCORED*, pp 13–14
- Oakley A (2003) Research evidence: knowledge management and educational practice: early lessons from a systematic approach. *Lond Rev Educ* 1(1):21–33
- OFICEMEN (2019) Informes Estadísticos Avance Nacional Diciembre 2019. <https://www.oficemen.com/shop/>
- Parejo M, Navarrete B, Mora P, Alfala-Luque R (2021) Desarrollo metodológico para la optimización del coste eléctrico en fábricas de cemento, mediante inteligencia artificial, operando sobre el coste eléctrico del mercado. *Dirección y Organización*. Julio, 74, pp 5–19

28. Pavlos SG (2007) Artificial intelligence solution to electricity price forecasting problem. *Appl Arti Intell* 21(8):707–727
29. Pereira L, Afonso L, Papa JP, Vale ZA, Ramos C, Gastaldello DS, Souza AN (2013) Multilayer perceptron neural networks training through charged system search and its application for non-technical losses detection. In: *IEEE PES, ISGT Latin America*
30. Pérez C (2007) *Minería de datos técnicas y herramientas*. Thomson, Madrid
31. Provost F, Fawcett T (2013) *Data science for business*. O'Reilly Median Inc., USA
32. Quinlan KM, Kane M, Trochim WMK (2008) Evaluation of large research initiatives: outcomes, challenges, and methodological considerations. In: (Series Ed.) & Coryn CLS, Scriven M (eds) *New directions for evaluation*, No 118: Reforming the evaluation of research, pp 61–72
33. Ramos CC, de Sousa AN, Papa JP, Falcao AX (2011) A new approach for nontechnical losses based on optimum-path forest. *IEEE Trans Power Syst* 26(1):181–189
34. Sánchez Cazorla A, Alfalla-Luque R, Irimia-Diéguez AI (2016) Risk identification in megaprojects as a crucial stage of risk management: a literature review. *Proj Manag J* 47(6):75–93
35. Shaohog J, Wemeng XY, Xiaohong W (2012) Research on the key technology of energy management and optimization in cement enterprises. *Adv Mater Res* 433–440:1910–1914
36. Swanepoel JA (2013) Modeling for integrated energy optimization in cement production. In: *Conference on the industrial and commercial use of energy, ICUE*. Article number: 6761634. ISSN: 0196-8904
37. Swanepoel JA, Mathews EH, Vosloo J, Liebenberg L (2013) Integrated energy optimisation for the cement industry: a case study perspective. *Energy Convers Manag* 78:765–775. ISSN:0196-8904
38. Tranfield D, Denyer D, Smart P (2003) Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *Br J Manag* 14(3):207–222
39. Wellesley M (2011) EnvaPower's new artificial intelligence software makes managing electricity a no-brainer. *PR Newswire*, New York
40. Zhang J, Cheng Ch (2008) Day-ahead electricity price forecasting using artificial intelligence. In: *IEEE Canada electric power conference*. INSPEC Accession Number: 10459652

Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

B. Presentación de los resultados de la tesis doctoral en foros académicos y empresariales. Carta de interés.

Los resultados de esta tesis doctoral se han presentado en varios foros, tanto académicos como empresariales:

- Workshop Programa de Doctorado Ciencias Económica, Empresariales y Sociales, celebrado el 21 de junio de 2021 y organizado por el Programa de doctorado. En este acto se presentó el trabajo, la metodología y los resultados de la tesis doctoral.

- Jornada "El Mercado Eléctrico en el Sector Cementero". Jornada organizada por la Escuela Técnica Superior de Ingeniería de la Universidad de Sevilla y celebrada el 27 de mayo de 2021. En este acto se presentó el trabajo, la metodología y los resultados de la tesis doctoral.

- II Jornada de Ingeniería Ambiental. Esta Jornada se celebró el 7 de julio de 2021 y fue organizada por el Departamento de Ingeniería Química Ambiental de la Escuela Técnica Superior de Ingeniería de la Universidad de Sevilla. Durante la jornada, en una ponencia el trabajo, se presentaron la metodología y los resultados de la tesis doctoral.

- II Workshop on Energy Economic and Public Policies Evaluation. Este workshop lo organizó la Cátedra de la Economía de la Energía y del Medio Ambiente de la Universidad de Sevilla el 16 de julio de 2021. Se presentaron el trabajo, la metodología y los resultados de la tesis doctoral.

- Comisión de la Energía de OFICEMEN. Se celebró el 20 de junio de 2021. En esta comisión de trabajo están representados los máximos responsables de los temas eléctricos de las cementaras que operan en España. Durante la misma pudimos exponer y debatir el trabajo de investigación y resultados obtenidos con esta tesis doctoral, con este grupo de responsables empresariales, resultado de gran utilidad todas sus aportaciones y el debate final.

Por otro lado, la consultora INERCO ha redactado una carta de interés por la investigación académica. En la misma se manifiesta el interés por poner en marcha un proyecto piloto que sirva para desarrollar la investigación de manera práctica en una planta cementera. Se acompaña la carta de interés.

Parque Científico Tecnológico Isla de la Cartuja. Edificio INERCO
C/ Tomás Alba Edison, 2
41092 · SEVILLA · ESPAÑA
Tfno.: +34 954 468 100
Fax: +34 954 461 329
info@inerco.com
www.inerco.com

**SR. D. MANUEL PAREJO GUZMÁN
DIRECTOR GENERAL
FUNDACIÓN LABORAL ANDALUZA
DEL CEMENTO Y EL MEDIO AMBIENTE
C/ MUÑOZ OLIVÉ, 1 – PORTAL 1-2ºPLANTA-
MÓDULOS 6 Y 7
41001 SEVILLA**

Sevilla, 28 de abril de 2021

Estimado Sr. Parejo,

Hemos tenido conocimiento de la investigación en la que se encuentra trabajando para desarrollar su tesis doctoral en la Universidad de Sevilla, con mención industrial, relativa al "DESARROLLO METODOLÓGICO PARA LA OPTIMIZACIÓN DEL COSTE ELÉCTRICO EN FÁBRICAS DE CEMENTO MEDIANTE EL USO DE INTELIGENCIA ARTIFICIAL".

Tras las distintas reuniones mantenidas con Vd., y después de que nuestra División de Tecnologías y Servicios Energéticos haya analizado la información que ha compartido con nosotros, quiero hacerle llegar el interés de INERCO por este proyecto. En este sentido, dada la naturaleza de la investigación, con clara aplicación a las empresas cementeras, y el beneficio que es posible obtener con su adecuada aplicación, consideramos adecuado, y de gran interés, dar un paso más y proponer a alguna de las empresas cementeras que operan en España, la posibilidad de poner en marcha un proyecto piloto, para implementar los distintos resultados obtenidos en su investigación en alguna fábrica de cemento. Este paso resultaría fundamental, para conocer con mayor detalle el orden de magnitud de los resultados que podrían alcanzarse en materia de ahorro eléctrico en la industria cementera, con las distintas herramientas de Inteligencia Artificial que Vd. propone en su tesis.

En la confianza de que podamos avanzar en la adaptación y validación de los resultados obtenidos en su investigación a casos específicos de fábricas de las empresas cementeras, y ello revierta en una mejora de su productividad, quedamos a la espera de sus noticias.

Reciba un cordial saludo,


Francisco José Rodríguez Barea
Director de Tecnología e Ingeniería
INERCO

C. Mención a tesis industrial.

La tesis doctoral se propondrá para recibir la "Mención de Doctorado Industrial".

En aplicación de lo establecido en el apartado 6 de la Disposición final tercera del RD 195/2016, de 13 de mayo, por el que se modifica el art. 15 del RD 99/2011, se otorgará la mención "Doctorado Industrial" siempre que concurren las siguientes circunstancias:

a) La existencia de un contrato laboral o mercantil con el doctorando. El contrato se podrá celebrar por una empresa del sector privado o del sector público, así como por una Administración Pública.

En nuestro caso, la empresa cementera FYM HeidelbergCement Group, se ofreció a facilitar todo tipo de información relacionada con el proceso productivo, consumo de recursos, de electricidad, etc. en su fábrica de Málaga (España), para el desarrollo de esta tesis doctoral. Esta empresa se encuentra asociada a la Fundación Laboral Andaluza del Cemento y el Medio Ambiente (FLACEMA), a través de la Agrupación de fabricantes de Cemento Artificial de Andalucía (AFCA). El doctorando mantiene un contrato de alta dirección, en calidad de director gerente, con la citada fundación del sector cementero, FLACEMA.

b) El doctorando deberá participar en un proyecto de investigación industrial o de desarrollo experimental que se desarrolle en la empresa o Administración Pública en la que se preste el servicio, que no podrá ser una Universidad. El proyecto de investigación industrial o de desarrollo experimental en el que participe el doctorando debe tener relación directa con la tesis que realiza. Esta relación directa se acreditará mediante una memoria, que ya ha sido entregada, y que tendrá que ser visada por la Universidad.

Respecto a este requisito, el pasado 25 de junio de 2020, FLACEMA y la Universidad de Sevilla suscribieron un "Convenio Específico de Colaboración para la "colaboración entre la Universidad de Sevilla y FLACEMA para el desarrollo de un Proyecto de Investigación Industrial o de Desarrollo Experimental en el Marco de un Programa de Doctorado de la US". En este convenio se sientan las bases de la colaboración de la investigación que FLACEMA y la US llevarán a cabo, siendo la investigadora principal

la Profesora Dra. D^a Rafaela Alfalla Luque, para reducir el coste eléctrico de las fábricas de cemento utilizando técnicas de IA.

Sevilla, noviembre de 2021