

---

# INTELIGENCIA ARTIFICIAL PARA LA ORQUESTACIÓN DEL MODELO ELÉCTRICO DEL FUTURO

**WOLFRAM ROZAS**

EOI, UNED

**JAUME MANERO**

Universitat Politècnica de Catalunya

**RAFAEL PASTOR**

**JOSÉ CARPIO**

UNED

En el reciente informe del panel de la ONU sobre la situación del cambio climático (IPCC6) se establece una conclusión vital, que los efectos del calentamiento global ya son tangibles y medibles en toda la tierra y que debemos tomar medidas inmediatas para aminorar estos efectos que potencialmente pueden agravarse hasta poner en peligro la civilización tal y como la conocemos hoy en día. Este informe, que posiblemente ha impulsado los

importantes, aunque tímidos, compromisos de la conferencia de cambio climático de Glasgow de 2021 (COP26) nos impulsa a acelerar inversiones y proyectos para limitar el impacto en nuestra civilización.

Sabemos que tenemos que actuar ya para alcanzar el objetivo de 1,5°C, con unos efectos notables, pero quizá controlables sobre el clima. Subidas superiores a este límite pueden ocasionar cambios en el clima de un impacto inasumible para nuestra sociedad (mkinsey2021).

La herramienta más importante que tenemos es la descarbonización de nuestra economía, de modo que los combustibles fósiles se vean reemplazados por energías que no generen emisiones, lo que conlleva una electrificación masiva de nuestra sociedad, desde al transporte, al control del clima, pasando por la transformación de numerosos procesos industriales, evidentemente con una generación eléctrica 'limpia' o sin emisiones de gases con efecto invernadero.

Transformar el modelo de generación eléctrica para eliminar las emisiones de efecto invernadero es un proyecto muy ambicioso. En 2019 las emisiones de CO<sub>2</sub> atribuibles a la generación de energía en la Unión Europea (UE) fueron de 810.001 ktCO<sub>2</sub>e (kilo-toneladas equivalentes de dióxido de carbono), que aunque un 43% menores que en 1990 representan un 26% del total de emisiones de la UE en este mismo año (UE2021CO2). Dentro de este proceso de descarbonización, la generación a partir de fuentes renovables tiene una importancia capital.

Las energías renovables se caracterizan por ser originadas a partir de algún fenómeno natural, como los ríos y las presas, las olas o mareas en el medio marino, o el viento, el sol, las diferencias de temperatura en distintos medios naturales, o bien en el calor que generan capas profundas de la tierra.

Las energías fundamentales para cubrir los objetivos de nuestros sistemas energéticos son el viento o el sol. Cuando se modelan los futuros sistemas

eléctricos basados en energías renovables, estas dos fuentes cubren el 70% de los nuevos modelos energéticos totalmente renovables (jacobson2017).

Viento y Sol tienen una característica común y es su intermitencia, ya que son fenómenos meteorológicos que aparecen y desaparecen. La red eléctrica, para ser estable, tiene que ajustar la oferta de energía a la demanda del sistema para conseguir una onda eléctrica dentro de unos requerimientos de calidad de la onda, y para conseguirlo dispone de una herramienta clave, la predicción precisa de los distintos agentes del sistema (anees2012).

El cambio del paradigma en el que la distribución de las fuentes de generación eléctrica, la fotovoltaica doméstica, el crecimiento explosivo de vehículos eléctricos y el almacenamiento de energía presenta una serie de nuevos retos a los sistemas eléctricos de todo el mundo. La necesaria estabilidad de los sistemas se convierte en un problema de mucha mayor complejidad, y en un reto para los operadores de red en todo el mundo.

La inteligencia artificial, en sus disciplinas de Machine Learning o Deep Learning (Iecun2015) con su capacidad de abordar problemas de gran complejidad está resolviendo problemas que creíamos enquistados hacia muchos años. Desde el reconocimiento de imágenes que se resistía a enfoques basados en programación tradicional (russakovsky2015), sus aportaciones a la teoría de juegos jugando por encima del nivel humano en GO o en Ajedrez (silver2017), la generación de estructuras de proteínas en tres dimensiones (jumper2021), o bien los nuevos y apasionantes modelos masivos de lenguaje basados en grandes redes neuronales de grafos conocidas como «transformers» (child201901).

En este artículo exploramos distintas contribuciones que la disciplina de la inteligencia artificial realizará en el proceso de transformación energética en el que estamos inmersos, de hecho, el nuevo modelo energético se apoyará en algoritmos avanzados de inteligencia artificial que puedan abordar un nivel de complejidad mucho más alto que el actual.

Este artículo está estructurado en cuatro secciones. En la primera analizamos la problemática de la integración de las energías renovables en el sistema eléctrico y como Red Eléctrica Española (REE) ha abordado este problema. La segunda sección desarrolla la problemática añadida de la generación distribuida y el impacto que tendrá la irrupción del almacenamiento. El tercer capítulo aborda la capacidad de la Inteligencia Artificial para abordar problemas de gran complejidad, capacidad que se aplica en el sistema eléctrico en el Capítulo quinto. Este breve artículo finaliza con unas pequeñas conclusiones y previsiones de evolución futura.

## LA INTEGRACIÓN DE LAS ENERGÍAS RENOVABLES EN LA RED ELÉCTRICA ↓

Para entender dónde estamos actualmente es preciso conocer un poco la evolución histórica del Sector Eléctrico Español. Hasta la mitad de la década de los 80 del siglo anterior la generación, el transporte, la distribución y la comercialización de energía eléctrica en España tenía una estructura vertical que estaba repartida entre unas pocas grandes empresas privadas y una pública (ENDESA; que sólo tenía la generación de las centrales térmicas que consumían carbón nacional), interconectadas entre ellas, ligadas a las zonas geográficas definidas por las grandes cuencas hidrográficas de nuestro país y que funcionaban de forma más o menos independiente buscando su óptimo económico y estableciendo, cuando lo necesitaban, acuerdos bilaterales de compra y venta de energía con las empresas vecinas.

En 1984 esta situación cambia con la entrada en vigor del Marco Legal Estable, que garantizaba la continuidad de las empresas eléctricas como un monopolio a cambio de una fuerte intervención en su gestión. Así, se nacionaliza la red de transporte de energía eléctrica en alta tensión con la creación de Red Eléctrica de España, y se le otorga a esta empresa la capacidad de planificar y gestionar el funcionamiento del sistema de forma centralizada, decidiendo incluso la generación de cada central eléctrica con el objetivo de buscar el óptimo del conjunto del sistema, y del posterior reparto de los costes y de los beneficios entre las empresas eléctricas, que seguían siendo las propietarias de las centrales, en función de la generación que se les ha asignado. A este tipo de funcionamiento centralizado con el objetivo del óptimo global se le conoce como funcionamiento en *pool*.

En 1997 el modelo de gestión y determinación de precios cambia radicalmente con la Ley del Sector Eléctrico (la aplicación en España de la Directiva Europea del Mercado Interno de Electricidad del año anterior). Ahora el sistema se liberaliza y se crea un mercado eléctrico marginalista, horario y diario, en el que el precio que se paga por la energía corresponde al del último megavatio-hora comprado y vendido. Este modelo corresponde básicamente al modelo teórico del mercado de competencia perfecta que todos hemos estudiado, en el que el precio del producto lo fija la intersección de la curva agregada de las ofertas de energía (una curva monótona creciente) con la curva agregada de las demandas (una curva monótona decreciente).

Aunque la idea de este cambio a un modelo económico liberalizado pudiera parecer la correcta, sin embargo, el mercado eléctrico dista mucho de cumplir las condiciones del modelo teórico de competencia perfecta. En primer lugar, la energía eléctrica no es un bien, no es un producto que se fabrica y se pone en el mercado en unidades, cuándo y

dónde convenga, sino que es más bien un servicio que, hoy en día, es ya sin duda un servicio esencial en nuestra sociedad. En segundo lugar, está la característica principal de la energía eléctrica que es su imposibilidad de poder almacenarse en grandes cantidades lo que obliga a que, de forma instantánea, en todo momento se tenga que producir la energía eléctrica que se demanda más las pérdidas que se producen en las redes por las que se transporta y se distribuye a los consumidores. Además, la electricidad no se puede «transportar y distribuir» por esas redes como se desee, sino que los flujos de energía son el resultado de la existencia de unas estrictas ecuaciones que responden a las características físicas de las redes y de todos los elementos conectados a ellas. Y, por último, la presencia de los participantes en ese mercado no es libre ya que existen muchas barreras y restricciones que limitan la entrada de nuevos compradores (que demandan energía eléctrica) y, muy especialmente, de nuevos vendedores (que producen esa energía). Por este motivo, desde el inicio del mercado eléctrico que conocemos fue necesario crear dos figuras fundamentales para que las reglas del mercado real se asemejaran lo más posible a las de la competencia perfecta en la fijación de precios, que son el Operador del Sistema y el Operador del Mercado. El primero, que le corresponde a Red Eléctrica de España como responsable del control y gestión del funcionamiento del sistema desde el punto de vista técnico, garantiza la continuidad, calidad, seguridad y coordinación de las operaciones de generación y transporte. El segundo, que se le asignó a una nueva empresa denominada entonces OMEL (Organización del Mercado Eléctrico) y, actualmente, OMIE (Operador del Mercado Ibérico de Energía – Polo Español), es a quien corresponde velar por la correcta operación económica del sistema mediante la gestión de ese mercado de ofertas de compra y de venta de energía eléctrica y la liquidación final resultante.

En las dos últimas décadas la aparición de factores externos a los estrictamente técnicos propios del sistema eléctrico nos han llevado a la situación actual de incertidumbre en los precios e, incluso, de poner en cuestión el propio modelo del mercado eléctrico liberalizado que tenemos hoy, aunque no es previsible un cambio del modelo.

Ante esta situación y debido a la existencia de cada vez más instalaciones de tamaño pequeño y medio cuyo objetivo es la generación de energía eléctrica con energías renovables, desde hace ya más de una década cada vez tiene más fuerza dentro de los sistemas eléctricos de todo el mundo la idea de la generación distribuida junto a la generación convencional existente. Esta idea cambia el paradigma tradicional de la generación de electricidad que es producida en unas pocas grandes centrales y de las redes de transporte y distribución entre esas centrales y los consumidores, al escenario emergente de una generación que está basada en la existencia

de muchas centrales de generación eléctrica de tamaño mucho menor que están muy dispersas y localizadas en la proximidad de los consumidores, lo que permite que se conecten incluso en las redes de distribución de baja y media tensión sin tener que pasar la energía que generan por la red de transporte de alta tensión.

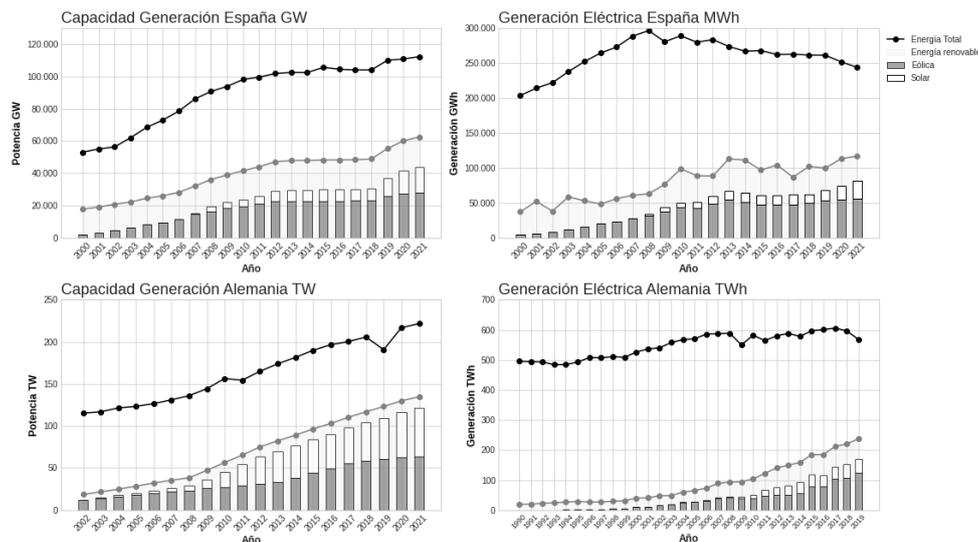
Aunque no existe una definición única y universalmente aceptada de qué es la generación distribuida, desde la aparición de este concepto al final del siglo pasado y principios del actual, todas sus definiciones se basan en tres características: su nivel de potencia, su localización y su carácter de no ser gestionada de forma centralizada (Of *et al.* 1999, Ackermann, Göran Andersson, and Soder 2001). Así, se puede decir que la generación distribuida es una generación de energía eléctrica formada por unidades cuyas potencias van desde decenas de kilovatios a decenas de megavatios, que están conectadas en las redes de distribución eléctrica de media y baja tensión en la proximidad de los consumidores y que se despachan de forma independiente de la, generación centralizada tradicional.

Las centrales que forman los sistemas de generación distribuida son principalmente las instalaciones basadas en la generación eléctrica con energías renovables, como son las instalaciones eólicas y fotovoltaicas y, en menor medida, minihidráulicas, de cogeneración, turbinas de gas (de la gasificación de residuos urbanos, agrícolas y rurales) y pilas de combustible (Parlamento Europeo y Consejo de la Unión Europea 2009). Y lo son tanto por su pequeña y mediana potencia como por el carácter no gestionable de las primeras, que viene dado por la variabilidad del recurso energético primario en el que se basan, como son el viento y el sol.

La generación distribuida presenta bastantes ventajas, tanto técnicas como económicas, como son, por ejemplo, la reducción de las pérdidas en la red, una mayor disponibilidad de potencia, un aumento de la fiabilidad de suministro y de satisfacer la demanda local o la reducción de los costes de las infraestructuras. Sin embargo, también presenta problemas técnicos y de operación como la disminución de la estabilidad del sistema, su no despacho junto al resto de generación, la introducción de perturbaciones provocadas por los convertidores electrónicos que afectan a la calidad de la onda de tensión, el funcionamiento en isla si se desconectan del sistema eléctrico general (microrredes) o la disminución de la garantía de suministro que está asociada a la incertidumbre del recurso primario.

La integración de la generación distribuida es un problema presente en la agenda de los gestores de red de todo el mundo desde principios de ese siglo. Un componente muy relevante de estas energías distribuidas es la generación renovable, que es, por condicionamientos físicos, distribuida. Los retos de esta integración, así como su impacto en plani-

**FIGURA 1**  
**CAPACIDAD INSTALADA Y GENERACIÓN TOTAL ANUAL EN ESPAÑA Y ALEMANIA**



Fuente: REE

ficación de inversiones es conocido. Podemos citar como capítulos clave dentro de esta integración, la agregación de fuentes mediante previsión continua de generación, la limitación de rampas horarias, la gestión del soporte reactivo, etc. (Lopes *et al.* 2007).

Al principio de la introducción de las energías renovables, la imposibilidad de abordar estos retos de forma económicamente viable fue uno de los puntos de resistencia al desarrollo de la energía eólica o fotovoltaica, impactando en el desarrollo de políticas ambiciosas de crecimiento renovable en algunos mercados (Sovacool 2009). Tuvo que ser ya bien entrada la segunda década, cuando el éxito renovable empezó a ser un hecho tangible. En informes del Think Tank renovable REN21 ya se muestra la evolución meteórica desde 2004, con un crecimiento de 10 países con industria eólica en 2004 a más de 40 en 2013 (REN21 2014).

Es en este periodo se producen grandes avances. En este sentido es bueno resaltar el planteamiento de REE que con su centro de control de renovables (CECRE) (López 2018) diseñó un modelo que ha sido replicado con éxito en numerosos sistemas de red por todo el mundo.

### LA GESTIÓN DE LAS ENERGÍAS RENOVABLES HASTA HOY. LAS PROPUESTAS PIONERAS ↓

En 2004 España se comprometió con el desarrollo de las energías renovables, compromiso que ha mostrado un crecimiento sostenido a lo largo del tiempo (ver Fig. 1), sin embargo, ya que España es una isla energética (con pocas conexiones con la red europea) hace que la integración con la red nacional fuera especialmente crítica. Por ello España crea el concepto de centro de integración único

(CECRE, Centro de Control de Energías Renovables) para optimizar la integración de estas tecnologías en el sistema.

Como elemento de comparación en la Fig. 1 vemos el perfil evolutivo de Alemania comparado con España, en los que se aprecia el incremento de la capacidad instalada renovable, eólica y solar en ambos países y su contribución a la generación.

Este concepto de centro único para gestionar la energía renovable, inicialmente diseñado para la generación eólica se adaptó a otras renovables, que han tenido un crecimiento posterior relevante, como la fotovoltaica. El CECRE calcula en tiempo real la cantidad renovable que se puede integrar en cada momento, y da órdenes individuales a cada uno de los parques de cuando puede o no puede realizar esta integración de forma segura. Utilizando algoritmos de previsión más la información continua de todos los generadores con capacidades superiores a 5 MW.

En este momento, la penetración de las energías renovables está creciendo de forma sostenida en todos los países del mundo. En los países avanzados encontramos coberturas de generación renovable que pueden superar un tercio de la generación global. No obstante, los agresivos programas de la Unión Europea están empujando un crecimiento de estas cifras que pueden llegar a ser cercanas al 80% renovable en 2030 en muchos países europeos.

### Retos y enfoques para la integración de renovables en la red ↓

La importancia de las energías renovables para alcanzar la sostenibilidad futura del sistema eléctrico

es capital, y para ello se están realizando avances importantes destinados a equilibrar la problemática de la intermitencia (inherente a muchas fuentes de generación) y la necesidad de cubrir la demanda en todo momento. En estos momentos existe consenso en la necesidad de disponer de almacenamiento (a corto, medio y largo plazo) para redes con alta introducción de renovables, necesidad que se dispara al alcanzar volúmenes muy altos de introducción de renovables (cerca del 80%) tal como se describe en el modelado de redes nacionales (para una descripción detallada de las redes Europeas [Child *et al.* 2019]).

La investigación se centra en tres corrientes principales (Schill 2020), que son:

- Almacenamiento a nivel de red global sin vinculación a otras fuentes de energía
- Almacenamiento a nivel de red global vinculándolo a otras fuentes de energía (ejemplo transformándolo en H<sub>2</sub> verde)
- Almacenamiento de energía de origen fotovoltaico con baterías domésticas o industriales

En niveles de penetración medios, el almacenamiento se centra en los excesos de energía renovable, lo que se puede remediar mediante el 'corte' de entrada de los excesos de energía al sistema, lo que se utiliza actualmente en sistemas de producción renovable (que como máximo alcanzan penetraciones del 60% en ocasiones puntuales). Otra alternativa al almacenamiento es la expansión de la red de transmisión de modo que se compensen regiones lejanas, este problema ha sido investigado en profundidad y en escenarios futuros se demuestra que a mayores áreas conectadas se disminuye la necesidad de almacenamiento (Schlachberger *et al.* 2017). Para España, que es casi una isla energética por disponer de muy pocas conexiones con las redes europeas, este es un problema clave, y está incluido en el Plan Nacional Integral de Energía y Clima (PNIEC) que lo considera como uno de los elementos clave de inversión de los próximos años.

La vinculación de sectores (Brown *et al.* 2018) es un elemento que puede ayudar a disminuir las necesidades de almacenamiento utilizando los excesos, como por ejemplo la penetración del vehículo eléctrico, el almacenamiento de energía en forma de calor (como se realiza en la generación termosolar), o bien la transformación de energía en hidrógeno verde H<sub>2</sub> para su almacenamiento.

En cualquier caso, cuando la penetración de renovable alcanza cifras del 90% se observa que la necesidad de almacenamiento se dispara ya que no se utiliza para mitigar los excesos de energía sino para generar cargas residuales necesarias para cubrir la demanda. Finalmente, el uso de baterías domésticas para almacenar energía fotovoltaica es un área de intensa investigación y desarrollo en estos momen-

tos. Estas baterías optimizan las plantas domésticas de generación y en estos momentos ya disponemos de información de mercados en los que su introducción es muy alta (fundamentalmente Estados Unidos y Australia). Estas baterías contribuyen a mejorar la integración de la energía eléctrica en la red aunque su crecimiento no viene guiado por necesidades globales sino por elementos de coste, facilidad de uso y entorno regulatorio. En algunos estudios ya se observa un impacto notable de estas baterías en la red, comparable a baterías de gran escala, aunque a coste superior (Say, Schill, and John 2020).

El uso de las baterías domésticas está dirigido a la obtención de rentabilidad en instalaciones individuales de generación, lo que puede tener un impacto relativo en la red, pero la aparición de figuras como los agregadores virtuales con modificaciones en la regulación que les permitiera entrar como jugadores activos en la fijación de precios, puede tener impactos notables en la estabilidad de la red global.

## LOS RETOS DE LA GENERACIÓN DISTRIBUIDA

La generación distribuida, con la consecuente integración en el sistema eléctrico de la generación basada en las energías renovables, está suponiendo una mayor penetración de estas energías en el mix eléctrico y está planteando nuevos retos al sistema. Entre esos retos que se plantean, además de los técnicos tradicionales, se pueden destacar la necesidad de aumentar la capacidad de almacenamiento de energía eléctrica y la aparición de nuevos tipos de consumo.

Para aumentar la capacidad y flexibilidad del sistema es necesario, allí donde existe generación distribuida, disponer también de una cierta capacidad de almacenamiento y de gestión de la demanda. Esta evolución lógica en la generación distribuida ha llevado a los actuales DER (del inglés *Distributed Energy Resources*), que agrupan a los generadores renovables con sistemas de almacenamiento de energía y sistemas inteligentes de respuesta a la demanda, todos ellos próximos y conectados a la red de distribución y gestionados de forma conjunta, (Li *et al.* 2010, Kroposki *et al.* 2020). Y de los DER a las futuras redes inteligentes o Smart Grids en las que se integrarán la digitalización y el control de las instalaciones y las redes de distribución de energía eléctrica con el tratamiento inteligente de un enorme volumen de datos de generación, consumo y estado del sistema para optimizar su funcionamiento (Oliveras *et al.* 2014, Widergren *et al.* 2019), para llegar finalmente a los más amplios sistemas multienergéticos o MES (del inglés *Multy Energy Systems*) que no solo tratarán de energía eléctrica sino que también la gestionarán de forma conjunta con las instalaciones locales térmicas y de gas (Chertkov and Göran Andersson 2020).

La energía eléctrica puede almacenarse transformándola en otros tipos de energías como energía

potencial (en grandes centrales de bombeo hidráulico y en sistemas de aire comprimido), energía química (en baterías), energía térmica (mediante sistemas de sales fundidas), energía cinética (mediante volantes de inercia) y en forma de campo eléctrico (en supercondensadores) y de campo magnético (en bobinas superconductoras). Se trata de un almacenamiento con un doble objetivo, técnico y económico, ya que, evidentemente, siempre se pierde energía en todos esos procesos de transformación.

Así, el fin de estos sistemas es almacenar energía cuando ésta es más barata para poder disponer de ella cuando es más cara, lo que se denomina desplazamiento de la demanda, y con ello contribuir además a disminuir tanto la variación horaria de la potencia que se tiene que generar, como la diferencia que hay en el día de esa potencia entre las horas de punta y las horas de valle, lo que se denomina aplanado de la curva de la demanda. Actualmente el problema del almacenamiento está en que, con la tecnología actual, no se pueden almacenar grandes cantidades de energía con un coste razonable. Mientras se aumenta esa capacidad de almacenamiento, mejorando y buscando nuevas tecnologías, (y además de ello) también se puede actuar sobre la propia demanda mediante la gestión y el uso en conjunto de los distintos tipos de almacenamiento ya existentes, dando señales de precios a los propios consumidores (respuesta a la demanda) o, en el futuro, actuando de forma automática sobre algunos tipos de cargas que en determinados momentos podrían pasar a ser generadores (por ejemplo, los vehículos eléctricos conectados a la red).

El gran reto que hay que abordar es que la implantación de la generación distribuida, primero, y de las redes inteligentes, más adelante, ha de hacerse adaptando los sistemas tradicionales existentes a los nuevos requisitos que impondrán los millones de dispositivos de generación, almacenamiento y consumo que se conectarán a ellos, dispositivos que además interaccionarán entre sí y que deberán ser controlados en tiempo real y de forma segura. La magnitud y complejidad del problema y de los modelos que se deberán utilizar para hacerlo abren las puertas a los sistemas inteligentes.

## INTELIGENCIA ARTIFICIAL PARA ABORDAR PROBLEMAS DE GRAN COMPLEJIDAD ↓

La Inteligencia Artificial (IA, en adelante) se puede definir como la capacidad de simulación de la inteligencia humana por parte de las máquinas. Se puede decir que es la disciplina que trata de crear sistemas capaces de aprender y razonar como un ser humano. Para ello, deben aprender de la experiencia, averiguar cómo resolver problemas en unas condiciones específicas, constatar la información de contexto y realizar operaciones/tareas lógicas.

El padre de la Inteligencia Artificial se puede decir que fue Alan Turing que ya apuntó en su artículo

*Computing Machinery And Intelligence* las bases de la IA con una simple pregunta: ¿Pueden las máquinas pensar? Este primer artículo fue publicado en 1950, y a partir de ese año se ha desarrollado esta disciplina científica de manera exponencial, adquiriendo en la actualidad un elevado grado de penetración y aplicación en los diferentes ámbitos científicos e industriales.

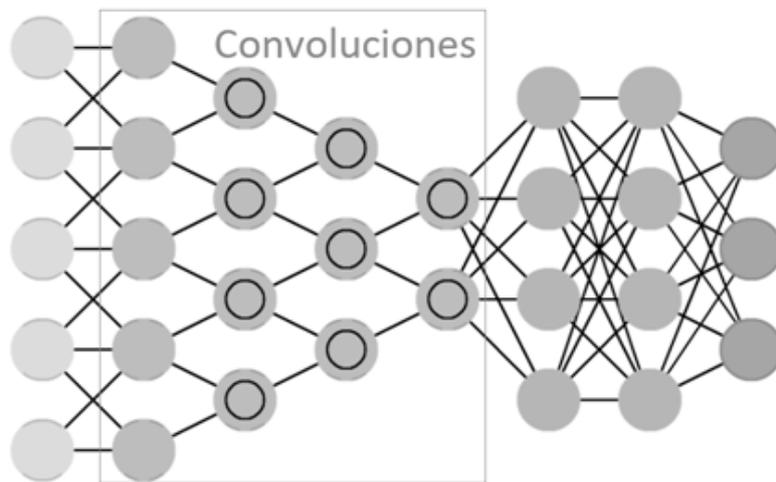
Los sistemas dotados de Inteligencia Artificial pueden dividirse principalmente según su capacidad y su funcionalidad. Si se considera la capacidad, se puede hablar de tres categorías: IA Débil, IA Fuerte y Super IA.

Dentro de la primera categoría (IA Débil), se encuentran todos los algoritmos conocidos como de Aprendizaje Máquina o Machine Learning. Fundamentalmente el empuje recibido en el desarrollo de la IA ha sido debido al desarrollo de este tipo de algoritmos en los diferentes ámbitos de aplicación. Se puede formular una definición más sencilla: «El aprendizaje automático es una aplicación de la inteligencia artificial (IA) que proporciona a los sistemas la capacidad de aprender y mejorar automáticamente a partir de la experiencia sin ser programados explícitamente. El aprendizaje automático se centra en el desarrollo de programas informáticos que pueden acceder a los datos y utilizarlos para aprender por sí mismos».

Estos algoritmos de aprendizaje se pueden categorizar de manera muy básica en algoritmos supervisados y algoritmos no supervisados. Los algoritmos supervisados usan datos que han sido previamente etiquetados e identificados e intenta obtener un modelo matemático que sea capaz de ajustar las salidas del algoritmo a esas etiquetas. Para ello se usan diferentes métricas de evaluación, que suelen depender del algoritmo: precisión (*Accuracy*) de la clasificación, pérdida logarítmica, matriz de confusión, curva ROC, F1 Score, error absoluto medio o error cuadrático medio, entre otras. En el caso de no disponer de datos etiquetados, se usan algoritmos de caracterización (no supervisados) que permiten modelizar patrones por agrupamiento (*K-means*, *Hierarchical clustering*, etc.), descubrir relaciones interesantes entre las variables en un conjunto de datos dado (por ejemplo, el algoritmo Apriori) o buscar características mediante técnicas de reducción de la dimensionalidad (PCA, SVD y Autoencoders). A estos últimos tipos de algoritmos se les suele categorizar como algoritmos de *Feature learning* o *Representation learning*.

Existe una variedad muy amplia de algoritmos asociados a cada uno de los tipos descritos anteriormente. Sin embargo, dentro de los algoritmos de aprendizaje supervisado destacan las redes neuronales, y en particular las redes neuronales profundas. Este tipo de algoritmos ha conseguido resultados excelentes en ámbitos como la visión por computador (reconocimiento de objetos/segmentación/etc.) o el

FIGURA 2  
RED NEURAL CONVOLUCIONAL



Fuente: <https://www.asimovinstitute.org/neuralnetwork-zoo/>

Nota: La figura ha sido modificada por los autores para mejorar la legibilidad de la estructura de la red.

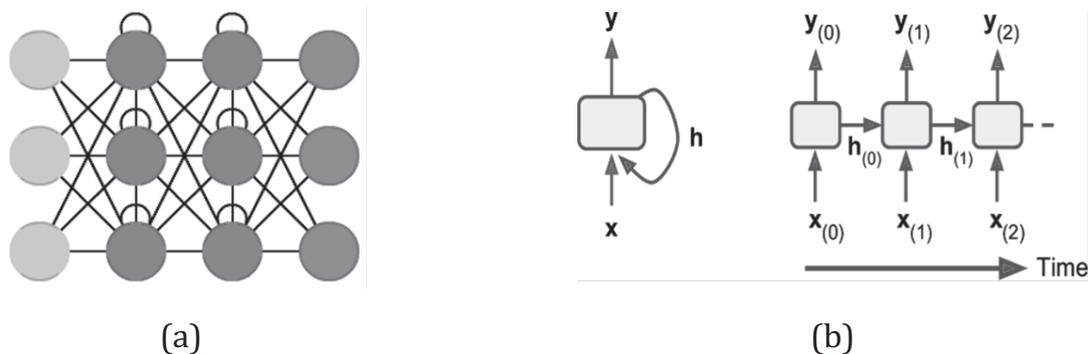
procesamiento del lenguaje natural. Estos resultados han hecho que sea el algoritmo más usado en investigación y en la propia industria en el momento de escribir este artículo. La red neuronal basa su funcionamiento en un modelo simple de neurona llamado *perceptrón* que, en esencia, es una suma lineal de las entradas (mediante un conjunto de pesos) que es a la vez una entrada a una función no lineal en la salida o función de activación. Este modelo fue inventado por Frank Rosenblatt en 1957 en el Cornell Aeronautical Laboratory e inicialmente la función de activación era una función de tipo Step (no lineal, con valores de salida 1 ó 0). De manera general, la estructura de una neurona es equivalente a un perceptrón, pero con posibles variaciones en la función de activación o en la constante que incorpora el sesgo (*bias*).

Una red neuronal define una estructura en la que todos los datos de entrada ( $X_n$ ) se conectan a todas las neuronas que componen la red, formando lo que se denomina una capa (*layer*). El número de neuronas ( $M$ ) es diferente al número de datos de entrada ( $N$ ), y usualmente suele ser mucho mayor que el número de datos de entrada ( $M \gg N$ ). Esta capa de neuronas se conecta a su vez con otra capa de neuronas, usualmente de menor dimensión y que se suele denominar capa escondida u oculta. De manera sucesiva, se pueden añadir capas interconectadas completamente entre ellas hasta definir una última capa final (denominada capa de salida) que tiene al menos una neurona que produce la salida esperada (por ejemplo, una probabilidad/valor asociado a los datos de entrada). Las neuronas de la capa de salida serán tantas como valores esperados para el problema que resuelve la red neuronal. Por ejemplo, en el caso de usar una red neuronal para predecir el valor de una demanda de carga de flujo eléctrico de una *Smart Grid* (valor numérico continuo), solo sería necesaria

una. Si en vez de ese valor único, tenemos un conjunto de clases como demanda alta, demanda media o demanda baja, se necesitarían tres neuronas (una por cada categoría o clase de equivalencia) en la capa oculta de este clasificador.

Las redes neuronales profundas o *Deep Learning* contienen un número de capas escondidas elevado (aunque algunos autores ya definen una red neuronal profunda como tal con un número de capas escondidas mayor o igual a 2). De la estructura anterior se deduce que cada neurona está caracterizada por tantos parámetros (pesos) como datos de entrada a la neurona. Por ejemplo, para la primera capa escondida tendríamos  $n$  parámetros diferentes para las  $m$  neuronas, haciendo un total de  $n \times m$  parámetros en la primera capa. A medida que se incrementan el número de capas, el número de parámetros se incrementa rápidamente a números elevados (la red GPT-4 tendrá 100 trillones de parámetros mientras que la GPT-3 son aproximadamente 175 billones de parámetros). Esto hace que el entrenamiento de estas redes neuronales profundas requiera una gran capacidad computacional en el caso de tener un número elevado de capas escondidas. Parece lógico por tanto usar el mínimo conjunto de capas posibles, pero se debe tener en cuenta que las capas ocultas representan características o atributos de los datos de entrada. Cada una de las neuronas de cada capa oculta evalúa las entradas de forma diferente, y de esta manera aprende características diferentes de los datos. Es decir, a mayor número de neuronas/capas la red es capaz de representar mejor la estructura de toda la información de entrada. Es evidente que hay que llegar a un compromiso entre estas dos cuestiones, pero fundamentalmente la mayor parte de las veces depende de la disponibilidad de la capacidad computacional. En este sentido hay que destacar que los procesos de entrenamiento de una red

FIGURA 3  
(A) RED NEURONAL RECURRENT Y (B) CELDA BÁSICA



Fuente: (a) <https://www.asimovinstitute.org/neural-network-zoo/> y (b) libro «Neural networks and deep learning» de Aurélien Géron

neuronal profunda necesitan una cantidad elevada de datos de entrada para obtener resultados fiables y con precisiones altas en los procesos de validación y test. Por esta razón, se vinculan las redes neuronales con el Big Data, ya que es necesario una cantidad masiva de datos de entrada para obtener buenos resultados. Este es el motivo por el que el uso de las redes neuronales profundas se ha centrado en la solución de problemas complejos, como el que se hace en esta propuesta.

Para resolver diferentes problemas se podría usar una misma topología/estructura de una red con capas escondidas, pero se ha avanzado en la investigación de este tipo de algoritmos y se ha conseguido formular distintas estructuras/tipos de redes que se usan en determinados problemas. En este sentido, se pueden destacar dos tipos de redes neuronales: las redes convolucionales y las redes recurrentes. Las redes neuronales convolucionales (*convolutional neural network* - CNN) se utilizan para problemas relacionados con la visión artificial (detección de objetos, segmentación, reconocimiento facial, etc.). La estructura de las primeras capas, denominadas convoluciones (véase Figura 2), es la diferencia fundamental con las redes neuronales completamente conectadas (Perceptrón Multicapa -MLP, *Multi-layer Perceptron*).

Una convolución es básicamente una multiplicación de los datos de entrada (imágenes) por una matriz específica denominada *kernel* o *núcleo* (de menor tamaño que la matriz de datos de entrada). Estos *kernels* permiten implementar filtros de características (detectar bordes, identificar colores, etc.) que identifican casi completamente la estructura de la imagen. Las CNN se usan fundamentalmente en problemas de visión, pero pueden usar también en otros problemas como en reconocimiento de lenguaje natural.

Existen redes *preentrenadas* para diferentes tareas como clasificación de imágenes (redes como AlexNet, las variantes de VGG, ResNet o MobileNet) o detección de objetos (Fast R-CNN, Mask R-CNN, YOLO, SSD) y que

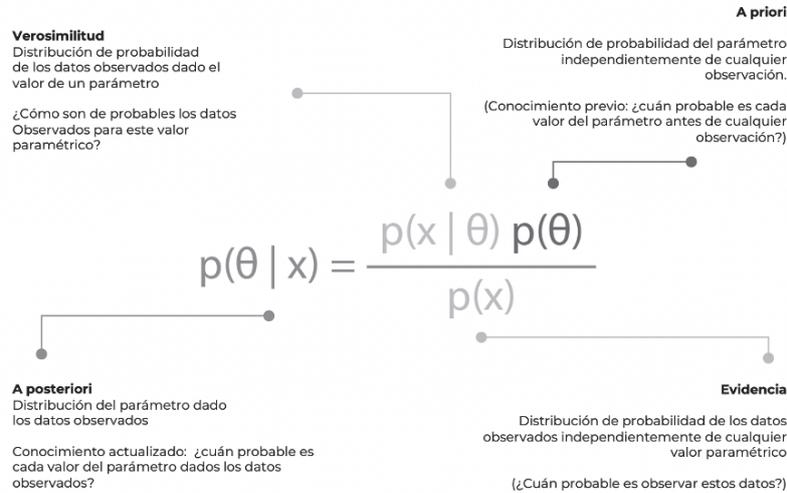
se pueden usar de manera directa o bien adaptarlas a problemas nuevos o específicos mediante aprendizaje por transferencia (*Transfer Learning*).

Las redes neuronales recurrentes (*Recurrent Neural Network* - RNN) añaden la capacidad de almacenamiento de estado a las redes tradicionales, esto es, permiten «recordar» los datos/información previa. Este tipo de redes se emplean en escenarios donde la información tiene una relación estructural relacionada con el momento/posición en el/la que aparecen en la secuencia de datos. Para ello, se implementa una neurona modificada (celda) que almacena una variable de estado ( $h$ ) que tiene en cuenta la última información/dato que «ve» la celda. Se puede ampliar con  $n$  observaciones anteriores de los datos ( $t, t-1, t-2, \dots$ ) y así ampliar el «recuerdo» de la celda (véase Figura 3).

Las RNN se utilizan en escenarios como la predicción de series temporales, el procesamiento de señales y el reconocimiento de caracteres escritos a mano, predicción del lenguaje, etc. Además, las RNN se utilizan ampliamente en la generación automática de música, la subtítulos de imágenes/videos y la predicción de las fluctuaciones bursátiles. Hay variaciones de las redes RNN que permiten ampliar la «memoria» de la red (es el caso de la LSTM, *Long Short-Term Memory*) o mejorar su eficiencia manteniendo la amplitud de la memoria (GRU, *Gated Recurrent Unit*).

Dada la naturaleza del problema que se está intentando resolver en esta propuesta, estas redes recurrentes se presentan como la mejor alternativa para buscar la solución al problema propuesto ya que la información/datos que se van a emplear tienen una dependencia temporal y secuencial entre sí (datos meteorológicos, demandas de carga y flujos, etc.). En todo caso, se hace patente que hay una incertidumbre clara en los procesos asociados en la generación de energía solar en una microgrid. Esta incertidumbre/variabilidad se pone de manifiesto en la propia exposición de las placas y la intensidad so-

**FIGURA 4**  
**TEOREMA DE BAYES**



Fuente: Elaboración propia

lar recibida, así como en los propios parámetros de fabricación de la microgrid y la batería. En los procesos de esta naturaleza es importante usar otros algoritmos alternativos que permitan tener en cuenta estas incertidumbres (las redes neuronales profundas no integran ese aspecto en sus estructuras). En este caso, la alternativa propuesta a las redes neuronales profundas serán las redes profundas bayesianas. Introducimos el análisis bayesiano y los métodos de resolución posibles, para describir a continuación las redes profundas bayesianas.

Los procedimientos del paradigma bayesiano proporcionan una serie de ventajas, frente a los clásicos métodos frecuentistas y de optimización. Entre esas ventajas, destaca el tratamiento de la incertidumbre de los parámetros de forma nativa, así como la posibilidad de considerar cualquier fuente de incertidumbre durante la inferencia. Por un lado, tenemos la inferencia frecuentista, que es la metodología clásica basada en la máxima verosimilitud. Se basa en eventos aleatorios repetibles para determinar las probabilidades. En lo que respecta a la cuantificación de la incertidumbre, el problema clásico se produce al tratar con eventos irrepetibles y conjuntos de datos de recuento bajo, o al estimar la probabilidad de ocurrencias poco frecuentes. Por el contrario, la inferencia bayesiana usa probabilidades para representar la incertidumbre en cualquier evento o hipótesis. Se basa en el estudio de la distribución de probabilidades de los diferentes sucesos. Las probabilidades se asignan antes y después de la experiencia. De esta manera se definen dos tipos de probabilidades:

*A Priori*. Es la distribución de probabilidad que expresaría las creencias sobre este suceso antes de que se tenga en cuenta una nueva observación. El a priori es el conocimiento previo que se tiene de

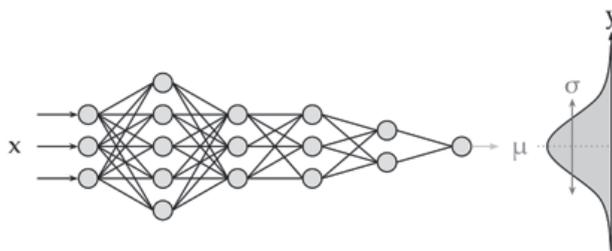
un fenómeno, antes de experimentarlo. Denostado como prejuicio tras Laplace, ahora se considera como la base de conocimiento de partida.

*A Posteriori*. Es la probabilidad condicional del conocimiento a priori a las nuevas evidencias. El a posteriori significa que se revisa el conocimiento a priori con las nuevas observaciones, la nueva evidencia. A esta nueva evidencia se le llama verosimilitud (núcleo de la escuela frecuentista).

El grado de creencia representa el a posteriori y consiste en el a priori actualizado por la verosimilitud de las nuevas observaciones, tomando en cuenta el conjunto de evidencias. El teorema de Bayes (ver Figura 4) se utiliza para actualizar la probabilidad de una hipótesis a medida que se dispone de más evidencias o información.

Los métodos de resolución (algoritmos) más utilizados de la inferencia bayesiana se basan en los métodos de *Markov Chain Monte Carlo* (MCMC) para obtener la estimación de a posteriori. Con el desarrollo de los actuales sistemas de procesamiento y su memoria y velocidad mejoradas, los métodos de muestreo han comenzado a ganar impulso: desde los muy simples (muestreo por inversión), que están atrasados en la práctica, hasta los más complejos como el algoritmo *Metropolis-Hasting*. Actualmente, se ha revitalizado el uso del *Muestreo de Gibbs*. La idea es dividir el problema del muestreo de la distribución conjunta de alta dimensión en una serie de muestras de distribuciones condicionales de baja dimensión. El método de muestreo emplea MCMC, y es un caso particular y simplificado de una familia de los algoritmos *Metropolis-Hasting*. Para evaluar la convergencia de estos algoritmos se emplea el Diagnóstico de Convergencia de *Kullback-Leibler* que es una medida de la similitud o diferencia en-

**FIGURA 5**  
**REDES NEURONALES BAYESIANAS**



Fuente: Elaboración propia.

tre dos funciones de distribución de probabilidad. La evaluación es medir la distancia entre las distribuciones del a priori y el a posteriori.

Las redes neuronales bayesianas (*Bayesian Neural Network* - BNN) se refieren a la extensión de las redes neuronales con la inferencia del a posteriori para controlar el sobreajuste. Desde una perspectiva más amplia, el enfoque bayesiano utiliza la metodología estadística para obtener una distribución de probabilidad conjunta, incluidos los parámetros del modelo de la red neuronal. Entre las características de las BNN se pueden enumerar los siguientes:

- Es un algoritmo prometedor para problemas donde gobierna la incertidumbre.
- Se puede obtener mejores resultados para una gran cantidad de tareas, aunque son extremadamente difíciles de escalar a grandes problemas.
- Las BNN calculan automáticamente un error asociado con sus predicciones cuando se trata de datos de objetivos desconocidos.
- Estiman la incertidumbre en las predicciones, lo cual es una característica deseable para campos como las energías renovables cuyos datos base son meteorológicos.

En la Figura 5 se puede ver la estructura de una red neuronal bayesiana. Fundamentalmente se comporta como una red neuronal profunda pero la salida de la red es la distribución del a posteriori.

Una vez vistos los fundamentos de los algoritmos de Inteligencia Artificial que se usarán en la propuesta, se va a describir cómo serían usados en la propuesta.

#### UNA PROPUESTA PARA APLICAR LA IA PARA EL DESARROLLO DE UN MODELO ELÉCTRICO DE RESPUESTA A LA DEMANDA ¶

La propuesta que planteamos construir con IA tiene como objetivo optimizar una microgrid de fuentes renovables tanto en sus flujos de potencia, de caja y de emisiones de Gases de Efecto Invernadero (GEI). Se trata de una solución de Mitigación del Cambio Climático.

Optimizar el flujo de energía significa volverse independiente sin tener apagones y tener un uso óptimo de la energía. Para lograr este objetivo, es fundamental pronosticar la generación con fuentes de energía renovables con la mayor precisión posible. Nuestra aproximación aplica métodos avanzados de predicción de conjunto como las *Mezclas de Expertos* (Shazeer *et al.* 2017) que ilustramos en la Figura 6. Planteamos que cada experto sea una red neuronal bayesiana.

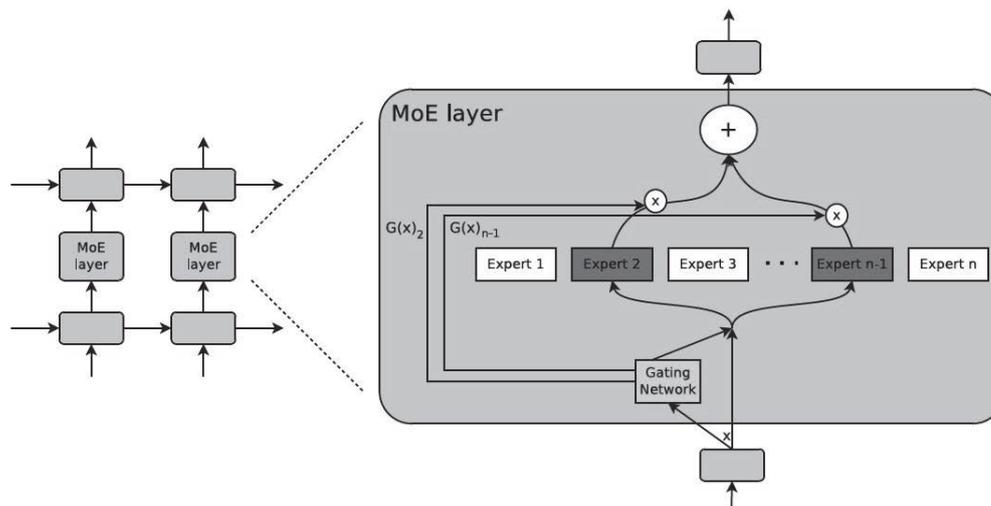
A la hora de maximizar el flujo de caja consideramos tanto la maximización de ingresos por ventas de excedentes en un mercado competitivo, como la enajenación de derechos de emisión (*carbon credits* o *carbon permits*) obtenidos por la venta de certificados digitales de esta producción renovable, y comercializables en el mercado europeo EU-ETS (<https://tradingeconomics.com/commodity/carbon>). El precio de estos derechos de emisión está a finales de Noviembre de 2021 en 69,7€/tCO<sub>2</sub>e habiendo subido desde inicio del año 2021 un 131% ya que 2021 es el inicio de la Fase 4 de adopción del *cap & trade* (la reducción acordada de emisiones en esta fase es del 2,2 %). La extensión de microgrids basadas en fuentes de energías renovables no sólo reducirá el precio de la energía, sino que contribuirá notablemente a la mitigación del Cambio Climático.

La idea central es automatizar las decisiones sobre la unidad de almacenamiento eléctrico, la batería de la microgrid. Es decir, en cada momento podemos consumir la batería, recargarla o vender sus excedentes. Todo dependerá de nuestro patrón de consumo y de los precios actuales de mercado. Si se espera que en el futuro el precio sea más alto, recargaremos y luego consumiremos o venderemos.

Si se espera que sea más barato, la consumiremos o venderemos y luego recargaremos. La decisión de consumo o venta dependerá de nuestro patrón de carga (consumo que realizamos en nuestra unidad familiar o de producción).

Por todo ello es necesario predecir: 1) la carga de la unidad, 2) la generación renovable de la unidad y 3) el estado de carga óptimo de la unidad

FIGURA 6  
MEZCLA DE EXPERTOS



Fuente: Shazeer *et al.* (2017)

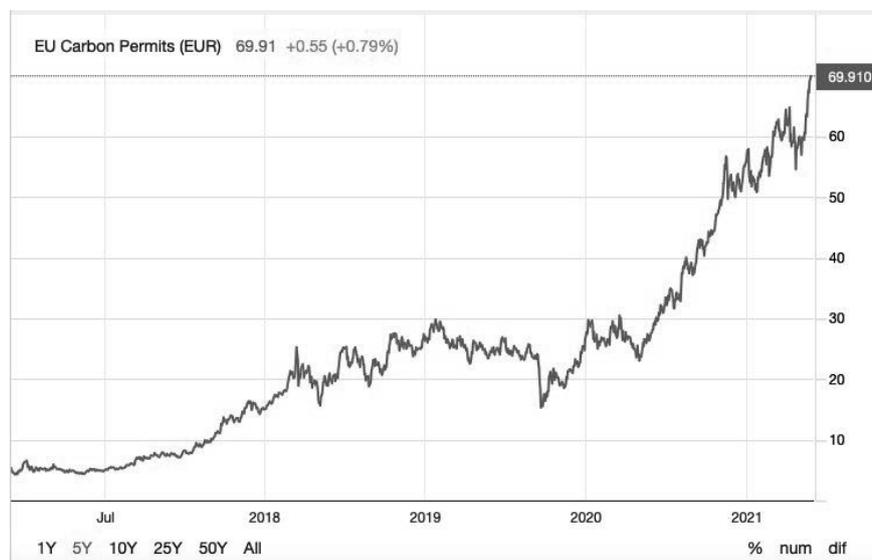
de almacenamiento. Para poner en marcha este motor analítico lo primero que es necesario es recabar los datos apropiados. Los datos de consumo de la unidad los proporciona el contador inteligente. En cuanto a los datos de generación y carga provienen de dos fuentes de datos fundamentalmente: los contadores de las unidades de generación (en las microgrids domésticas actuales típicamente son de tipo fotovoltaico, microeólico, o geotérmico) y los contadores de carga; y los datos climáticos (parámetros como temperatura, viento, irradiación solar, humedad, o humedad son esenciales para determinar la producción renovable). La unidad de almacenamiento informará de su estado de carga. Las microrredes sobre todo emplean baterías de ácido-plomo y de ión litio siendo estas últimas la apuesta actual de la Unión Europea dado su potencial a 2030 por su empleo en el Vehículo Eléctrico (Andrea 2010).

Para agregar todas las energías provenientes de las microrredes, establecemos un proceso que recopila información de los sensores en tiempos de latencia muy bajos. La tecnología conocida como *Edge Computing* analiza el dato allí donde se produce, el sensor; e informa a otras entidades de la situación actual del sistema. Empleando anchos de banda 5G los actuales sistemas son capaces de reaccionar en tiempos de latencia muy bajos, medidos en ms o incluso  $\mu$ s. Los sensores actuales pueden alojar un *contenedor*. Los contenedores son unidades lógicas virtuales que ejecutan cargas de trabajo analíticas o de automatización. Entre las primeras, encontramos la estimación de la carga residual (lo que consume/carga una microgrid menos lo que genera) mediante sofisticados modelos analíticos de aprendizaje profundo que estiman la carga, la generación y el estado óptimo de la unidad de almacenamiento.

El análisis bayesiano considerado un problema matemático intratable hasta hace pocos años, comienza a resolverse gracias a las nuevas plataformas analíticas y la nueva infraestructura de procesamiento ahora desplazada en la nube. Esta aproximación analítica tiene como ventaja tratar problemas con alta incertidumbre, como los climáticos, de una manera más amplia que las técnicas de aprendizaje profundo o las técnicas estadísticas frecuentistas, al analizar toda la población de datos, y no una gran muestra representativa y, sobre todo, al analizar todas las probabilidades de su interacción. Estas técnicas en vez de ofrecer un resultado retornan una función de distribución del a posteriori, es decir, de nuestro conocimiento previo de la carga o de la generación distribuida (a priori) actualizado por las evidencias disponibles (observaciones de alta frecuencia provenientes de nuestro sistema y del clima).

Las técnicas de *Aprendizaje Profundo Bayesiano* son prometedoras en este entorno de predicción de energías de fuente renovable de naturaleza incierta. El aprendizaje profundo se basa en redes neuronales de un notable número de capas que les permiten elaborar niveles de abstracción y adaptarse a regiones locales de datos, y estimar con alta precisión comportamientos no lineales como es el consumo o la generación eléctrica. La aproximación más compleja son los modelos de conjunto que, en su versión más adaptable, son las mezclas de expertos. Se trata de una especie de modelo «director de orquesta» que selecciona los modelos «intérpretes/músicos» que se usarán en cada estimación carga residual según cada combinación de geoposición, tiempo y parámetros climáticos. El «modelo director» (una red neuronal profunda bayesiana) selecciona la importan-

FIGURA 7  
PRECIO DE DERECHOS DE EMISIÓN 2017-2021



Fuente: tradingeconomics.com

cia de los «modelos músicos» a los que ordena «tocar», mediante lo que se conoce como una *red de compuertas o reguladores (gating network)* que decide cuál o cuáles son los expertos más adecuados en cada situación. Quiere decirse que los modelos intérpretes se especializan en zonas de datos como sean las mañanas muy soleadas, tardes ventosas y húmedas o días nubosos nada ventosos y secos. El modelo director elaborará una «opinión común» de los modelos intérpretes en función de la señal de entrada y el grado de conocimiento de cada experto (Charnock, Perraault-Levasseur, and Lanusse 2020, Papadopoulos *et al.* 2016).

Una vez estimada la carga y la generación podemos avanzar a la segunda etapa del motor analítico, la capa de optimización del estado de carga de la unidad de almacenamiento que decidirá automáticamente si debemos consumirla, recargarla o vender sus excedentes. En esta capa podemos, al menos, definir dos estrategias: una cooperativa con otros miembros de nuestra comunidad donde el objetivo sea reducir el coste de la energía, y otra competitiva, donde el objetivo sea maximizar los ingresos derivados de la venta de excedentes. La definición de estas estrategias podemos evaluarla óptimamente con la Teoría de Juegos. De nuevo, dada la alta incertidumbre del sistema empleamos Juegos Bayesianos que definirán sus pagos en función de probabilidades, y dado que en las subastas del mercado eléctrico no hay *conocimiento común* (es decir, los otros jugadores no conocen el precio que ofrecen los otros jugadores) emplearemos *Redes de Riesgos Adversarios*. Estas redes maximizarán el precio de salida en la subasta de la microgrid (Naveiro *et al.* 2019).

Teniendo en cuenta la decisión sobre la unidad de almacenamiento (consumir, recargar al precio del mercado actual u otro futuro, o vender al precio señalado por la estrategia óptima determinada por la Teoría de Juegos) debemos ejecutarla automáticamente. Para ello dispondremos de un *sistema multiagente* que ejecutará las acciones de consumo, recarga y venta tomando en cuenta las restricciones de despacho económico de la microgrid (equilibrio de carga, límites de generación, pérdidas, límites de almacenamiento) (Yoo *et al.* 2013).

Esta optimización podría hacerse a un nivel de agregación mayor como puedan ser comunidades, municipalidades o grandes instalaciones como una Universidad. En estas *Community Microgrid*, la producción será agregada y puesta en el mercado de flexibilidad eléctrica para poder vencer la terrible «curva del pato» que la generación renovable ocasiona cuando el viento deja de soplar o el sol se pone. Para poder equilibrar esta nueva situación, las comunidades energéticas crearán ofertas de portfolio en el mercado de energía de esa producción, garantizando la flexibilidad que necesita el sistema, cada vez más dependiente de las fuentes de energías renovable (Yoo *et al.* 2013).

Finalmente, este enfoque de *Energy Internet* planteado por Jeremy Rifkin, tendrá un gran impacto en los objetivos de reducción de emisiones de GEI y cambio climático. Los nuevos sistemas de tope y canje (*cap & trade*) como el *European Energy Trade System* (EU-ETS) establecen un mercado de intercambios de derechos de emisión (*carbon credits*). Gracias a la tecnología de trazabilidad Blockchain podemos crear *smart contracts* que

certifiquen el origen renovable de nuestra producción y la sitúen en el mercado de derechos de emisión (Rifkin 2011).

Una solución analítica que proporcione mayor precisión en la gestión de la microgrid a sus propietarios ayudará a mejorar el caso de negocio subyacente reduciendo el tiempo de recuperación de inversión, lo cual estimulará su adopción por otros inversores, contribuyendo a una reducción significativa de las emisiones de gases de efecto invernadero.

La complejidad del nuevo sistema eléctrico dada la necesaria *Transición Energética*, requerirá de soluciones que optimicen su gestión analizando cada vez más en detalle todos los elementos concernidos en el sistema: comportamiento de consumo, meteorología y mercado. El empleo de este tipo de soluciones evitará que se cumplan las predicciones obtenidas por los modelos DICE de evaluación económica del Cambio Climático creados por el profesor William D. Nordhaus, premio Nobel 2018 (Nordhaus 1999).

## CONCLUSIONES

La situación actual en la que nos encontramos nos muestra una sociedad cada vez más dependiente de la energía eléctrica, energía que aún se sigue generando en un porcentaje importante con unos combustibles fósiles que cada vez son más caros y que contribuyen de forma negativa al cambio climático. La inclusión de las energías renovables para generar parte de la energía eléctrica, cada vez más demandada, es ya incuestionable pero no serán la solución mientras no existan sistemas de almacenamiento suficientes y se actúe de forma inteligente sobre la demanda. La penetración cada vez mayor de la generación con energías renovables ha puesto en marcha la evolución del sector eléctrico en la que nos encontramos con la aparición de la generación distribuida en el sistema como el primer paso a las previstas redes eléctricas inteligentes y los futuros sistemas multienergéticos que integrarán la gestión y operación de los sistemas eléctricos, térmicos y de gas en nuestras ciudades inteligentes.

La evolución del modelo energético actual hacia uno mucho más distribuido, en el que se deban coordinar millones de unidades de generación, almacenamiento, combinado con una gran penetración del vehículo eléctrico hace que los sistemas de gestión y control del sistema deban evolucionar para realizar la orquestación del sistema de forma automatizada.

Este nuevo modelo generará unos enormes volúmenes de datos e información que deberán ser utilizados en tiempo real, lo que sin duda nos va a llevar a tener que desarrollar y utilizar técnicas de Inteligencia Artificial para dotar de esa «intelligen-

cia» a todo el sistema eléctrico, desde la generación hasta el consumo. Sin la aplicación de estas nuevas tecnologías la integración de las renovables en la red será una empresa imposible.

El nuevo modelo energético se construirá por tanto sobre dos elementos clave, por un lado, la utilización masiva de energías renovables y por otro la gestión y control de la red con la aplicación de algoritmos avanzados de Inteligencia Artificial, la inversión en estas dos áreas será clave para ayudarnos a alcanzar la reducción de emisiones necesaria para la contención del impacto del cambio climático en nuestra civilización.

## BIBLIOGRAFÍA

- Brown, T. *et al.* (2018). «Synergies of sector coupling and transmission reinforcement in a cost-optimised, highly renewable European energy system». In: *Energy* 160, pp. 720-739. issn: 0360-5442. doi: <https://doi.org/10.1016/j.energy.2018.06.222>.
- Chertkov, Michael and Göran Andersson (2020). «Multi-energy Systems». In: *Proceedings of the IEEE* 108.9, pp. 1387-1391. doi: [10.1109/JPROC.2020.3015320](https://doi.org/10.1109/JPROC.2020.3015320).
- Child, Michael *et al.* (2019). «Flexible electricity generation, grid exchange and storage for the transition to a 100% renewable energy system in Europe». In: *Renewable Energy* 139, pp. 80-101. issn: 0960-1481. doi: <https://doi.org/10.1016/j.renene.2019.02.077>.
- Hatziaziyriou, N. (2014). *Microgrids Architectures and Control*. IEEE Press. Wiley
- Li, Fangxing *et al.* (2010). «Smart transmission grid: Vision and framework». In: *IEEE Transactions on Smart Grid* 1.2, pp. 168-177. issn: 19493053. doi: [10.1109/TSG.2010.2053726](https://doi.org/10.1109/TSG.2010.2053726).
- López, S M (Oct. 2018). «Why was Spain a global wind power before the Great Recession? The CECRE from 2006 to 2012». In: *IOP Conference Series: Earth and Environmental Science* 188, p. 012086. doi: [10.1088/1755-1315/188/1/012086](https://doi.org/10.1088/1755-1315/188/1/012086).
- Nordhaus W. (2018). *The Climate Casino*. Yale University Press
- Olivares, Daniel E. *et al.* (2014). «Trends in microgrid control». In: *IEEE Transactions on Smart Grid* 5.4, pp. 1905-1919. issn: 19493053. doi: [10.1109/TSG.2013.2295514](https://doi.org/10.1109/TSG.2013.2295514).
- Say, Kelvin, Wolf-Peter Schill, and Michele John (2020). «Degrees of displacement: The impact of household PV battery prosumage on utility generation and storage». In: *Applied Energy* 276, p. 115466. issn: 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2020.115466>.
- Schill, Wolf-Peter (2020). «Electricity Storage and the Renewable Energy Transition». In: *Joule* 4.10, pp. 2059-2064. issn: 2542-4351. doi: <https://doi.org/10.1016/j.joule.2020.07.022>.
- Schlachtberger, D.P. *et al.* (2017). «The benefits of cooperation in a highly renewable European electricity network». In: *Energy* 134, pp. 469-481. issn: 0360-5442. doi: <https://doi.org/10.1016/j.energy.2017.06.004>.
- Yoo, Cheol Hee *et al.* (2013). «Intelligent control of battery energy storage for multi-agent based microgrid energy management». In: *Energies* 6.10, pp. 4956-4979. issn: 1996-1073. doi: [10.3390/en6104956](https://doi.org/10.3390/en6104956)