Trabajo Fin de Máster
Máster Universitario en Ingeniería Industrial

Estado del arte de sistemas de control basados en inteligencia artificial aplicados a sistemas energéticos

Autora: Carmen Pilar Serrano Madrona

Tutor: Francisco Javier Pino Lucena



Dpto. Ingeniería Energética. Grupo Termotecnia
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2024

Trabajo Fin de Máster
Máster Universitario en Ingeniería Industrial

Estado del arte de sistemas de control basados en inteligencia artificial aplicados a sistemas energéticos

Autora:

Carmen Pilar Serrano Madrona

Tutor:

Francisco Javier Pino Lucena

Catedrático de Universidad

Dpto. Ingeniería Energética. Grupo Termotecnia.

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2024

Trabajo Fin de Máster: Estado del arte de sistemas de control basados en inteligencia artificial aplicados a sistemas energéticos

Autora: Carmen Pilar Serrano Madrona

Tutor: Francisco Javier Pino Lucena

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2024

El Secretario del Tribunal

A mi familia,

Agradecimientos

Querría dar las gracias a todos aquellos que me han ayudado y apoyado a lo largo de este camino. A mi tutor, al que estaré eternamente agradecida por darme esta oportunidad. A mi familia, que estuvo a mi lado en los momentos más difíciles. A mi amigo y compañero de carrera Antonio, que me anima siempre a ser mejor y superarme. A todos vosotros, gracias.

Carmen Serrano Madrona

Sevilla, 2024

Resumen

Como consecuencia de la transición energética actual, se persigue optimizar el rendimiento de los distintos sistemas energéticos. Para ello, al margen de los sistemas de optimización tradicionales, el uso de técnicas de Inteligencia Artificial permite mejorar la eficiencia energética de estos, gracias a su capacidad de aprender y procesar grandes conjuntos de datos para encontrar soluciones a problemas complejos en tiempo real. De esta forma, y a lo largo del presente trabajo, se presentan los principales sistemas energéticos de acuerdo a su relevancia en la transición energética y posterior aplicación de la Inteligencia Artificial, a saber; sistemas de energías renovables, sistemas de almacenamiento de energía, sistemas de climatización y sistemas de redes inteligentes, esta última por su relación y relevancia con las dos primeras. A continuación, se hará un repaso sobre la Inteligencia Artificial, incluyendo sus principales componentes, técnicas y ramas. Una vez expuestas estas dos secciones, se combinarán ambas para así presentar las principales técnicas de Inteligencia Artificial empleadas para gestionar y controlar dichos sistemas energéticos. Así, se expondrá el tipo de técnica empleada, sus principales aplicaciones a día de hoy y los siguientes pasos de acuerdo al punto de investigación en el que se encuentran.

Abstract

Due to the current energy transition, optimizing the performance of the energy systems is one of the main goals. In order to achieve this, and apart from the traditional optimization systems, the use of Artificial Intelligence techniques improves the energy efficiency due to their ability to learn and process large datasets to find solutions to complex problems in real time. In this project, the main energy systems are presented according to their relevance in the energy transition and the subsequent application of Artificial Intelligence, specifically; renewable energy systems, energy storage systems, HVAC systems, and smart grid systems, the last one due to its relation and relevance to the first two. Afterwards, an overview of Artificial Intelligence will be provided, including its main components, techniques, and branches. Once these two sections are presented, they will be combined to introduce the main Artificial Intelligence techniques used to manage and control those energy systems. The type of technique employed, its main applications today, and the next steps according to the current research stage will be highlighted.

Índice

Agradecimientos **viii**

Resumen **x**

Abstract **xii**

Índice **xiv**

Índice de Tablas **17**

Índice de Figuras **19**

1 Introducción **21**

2 La transición energética y el paradigma actual **23**

2.1. Marco histórico y precedentes de la transición energética *25*

2.2. El Acuerdo de París y los Objetivos de Desarrollo Sostenible *26*

2.1.1 El Acuerdo de París 27

2.1.2 Los Objetivos de Desarrollo Sostenible 27

2.3. La transición energética y la Inteligencia Artificial *30*

3 Inteligencia artificial **33**

3.1. Definición de Inteligencia Artificial *34*

3.2. Marco histórico de la IA *35*

3.3. Funcionamiento de la IA *38*

3.3.1 Infraestructura de la IA 38

3.3.2 Componentes de la IA 39

3.4. Principales ramas de la IA *44*

3.3.3 Tipos de IA 44

3.3.4 Ramas de la IA 46

3.5. Riesgos y futuro de IA *55*

4 Sistemas de control basados en IA para sistemas energéticos 57
4.1. La IA y las energías renovables 60
4.1.1 Sistemas de control basados en IA: energía solar y energía eólica 63
4.1.2 Sistemas de control de energía geotérmica basados en IA 75
4.1.3 Próximos pasos de la IA en las energías renovables 77
4.2. La IA y los sistemas de almacenamiento de energía 78
4.2.1 Sistemas de almacenamiento de energía térmica y su relación con la IA 78
4.2.2 Baterías y su relación con la IA 81
4.3. La IA y el confort térmico en edificios 83
4.3.1 Sistemas de control para la operación de HVAC 84
4.3.2 Sistemas de control para el mantenimiento predictivo de HVAC 88
4.4. La IA y las Smart Grid 90
4.4.1 Técnicas de IA para Migrogrids 91
4.4.2 Técnicas de IA para Smart Grids 94

5 Conclusiones 97

Referencias 99

Glosario 105

ÍNDICE DE TABLAS

Tabla 2.1 Resumen ODS 7 29
Tabla 2.2 Resumen ODS 13 30
Tabla 3.1 Comparación IA generativa y adaptativa 35
Tabla 3.2 Comparativa entre Machine Learning y Deep Learning 49

ÍNDICE DE FIGURAS

Figura 2.1 Pilares de la transición energética 24
Figura 2.2 Transiciones energéticas a lo largo de la historia 25
Figura 2.3 Logo Acuerdo de París [53] 27
Figura 2.4 Objetivos de Desarrollo Sostenible [1] 28
Figura 2.5 Infografía oficial ODS 7 [2] 28
Figura 2.6 Infografía oficial ODS 13 [3] 29
Figura 2.7 Uso de la IA en diferentes sistemas energéticos 30
Figura 3.1 Representación de la IA emulando al cerebro humano [5] 33
Figura 3.2 Representación de la evolución del ser humano hasta la IA [7] 35
Figura 3.3 Test de Turing [8] 36
Figura 3.4 Etapas de la IA a lo largo de la historia [9] 38
Figura 3.5 Componentes de la IA 40
Figura 3.6 Ejemplo de agrupación exclusiva 41
Figura 3.7 Tipos de IA, incluyendo (*) en los de aplicación real 44
Figura 3.8 Ramas de la IA y principales técnicas 47
Figura 3.9 Tipos de aprendizaje ensamblado: *bagging* y *boosting* [10] 48
Figura 3.10 Arquitectura de Red Neuronal Profunda con 3 capas ocultas [11] 49
Figura 3.11 Icono PNL 51
Figura 3.12 Áreas del PNL 51
Figura 3.13 Icono Lógica Difusa 52

Figura 3.14 Icono Comp. Evolutiva 52
Figura 3.15 Icono Robótica 53
Figura 3.16 Icono Sistemas Expertos 54
Figura 3.17 Arquitectura de Sistemas Expertos [12] 54
Figura 3.18 Icono Visión por Computadora 55
Figura 4.1 Principales desafíos de la IA con las ER 60
Figura 4.2 Usos de la IA en el sector de las ER 62
Figura 4.3 Sistemas de predicción y sus técnicas de IA asociadas 64
Figura 4.4 Esquema de funcionamiento de métodos híbridos 64
Figura 4.5 Infografía sobre beneficio de IA para la energía solar 66
Figura 4.6 Uso de la IA en sistemas de energía eólica [4] 71
Figura 4.7 Esquema sobre la predicción de viento en sistemas eólicos y su utilidad 72
Figura 4.8 Esquema de red recurrente tipo GRU [31] 74
Figura 4.9 Gráfica con la medida real y predicha de la masa extraída [36] 76
Figura 4.10 Técnicas de IA para TESS 81
Figura 4.11 Tipos de aprendizaje de IA empleadas para las baterías recargables 83
Figura 4.12 Diagrama de funcionamiento de MPC 85
Figura 4.13 Diagrama de funcionamiento de FLC 87
Figura 4.14 Sistemas FDD para HVAC 88
Figura 4.15 Esquema de ejemplo de Smart Grid [48] 90
Figura 4.16 Comparación entre valor real y predicción [49] 92
Figura 4.17 Integración de la tecnología blockchain en una Smart Grid [52] 94
Figura 4.18 Usos de la IA para cada nivel 96

1 INTRODUCCIÓN

"La inteligencia artificial va a cambiar el mundo más que cualquier otra cosa en la historia de la humanidad. Más que la electricidad." – Kai-Fu Lee

Actualmente, la situación energética a nivel mundial está marcada por varios desafíos que son necesarios enfrentar. Por una parte, la crisis climática, la alta emisión de CO_2 y el futuro agotamiento de los combustibles fósiles, hacen necesario virar hacia un modelo energético diferente con fuentes de energía más limpias y sostenibles. Por otro lado, junto con el calentamiento global y la degradación ambiental, existe un problema de abastecimiento de energía en diversas zonas a nivel global, pues aún existen millones de personas sin acceso a fuentes de energía asequibles y fiables. Garantizar el acceso universal a la energía de manera segura supone un esfuerzo por parte de organizaciones de gobiernos internacionales, que requiere de la cooperación de distintos países para implementar las políticas y realizar las inversiones necesarias.

De la mano de estas medidas, y para lograr una transición energética que permita virar hacia un futuro más sostenible, es necesario el uso de nuevas tecnologías. Así, y como parte de un proceso de transformación digital, la Inteligencia Artificial sirve de medio para lograr todos estos objetivos de manera eficiente, optimizando los recursos energéticos, mejorando la previsión de la demanda y facilitando la integración de energías renovables en las redes eléctricas. Gracias a la capacidad de la Inteligencia Artificial (IA) para procesar grandes volúmenes de datos, aprender de la experiencia, tomar decisiones informadas en tiempo

real y realizar predicciones precisas, es posible mejorar el funcionamiento de diversos sistemas energéticos, optimizando la gestión de estos y reduciendo el desperdicio energético.

Por todo esto, el objetivo del presente trabajo es realizar un estado del arte, en base a una revisión bibliográfica actualizada, en el que se hace un recorrido las distintas formas en la que la IA se puede emplear para gestionar y controlar sistemas energéticos. Dada la extensión de los diferentes sistemas energéticos existentes, el trabajo se centra en los más relevantes de cara a la transición energética, en los que a su vez se han realizado más avances en lo relativo a sistemas de control basados en Inteligencia Artificial.

A lo largo del apartado 2, se presenta una breve explicación sobre la situación energética actual, los precedentes de esta, los próximos pasos y cómo la Inteligencia Artificial puede facilitarla.

En el apartado 3, y de manera más extensa, se hace un repaso de los conceptos básicos de la Inteligencia Artificial. Se presenta una definición de esta, su funcionamiento, principales componentes y ramas. El objetivo de este apartado es servir de antesala del siguiente, pues expone los términos y técnicas que se aplican posteriormente al control de sistemas energéticos.

En el apartado 4, por otro lado, se combina todo lo expuesto en los dos apartados previos, haciendo un recorrido por las distintas técnicas de Inteligencia Artificial empleadas en los principales sistemas energéticos. Para ello, el apartado se divide en 4 partes, cada una de ellas dedicada a una tecnología. La primera está dedicada a las fuentes de energía renovables, con especial dedicación a la energía solar y la eólica. El segundo por otro lado, se centra en los sistemas de almacenamiento energético, haciendo una reseña de los almacenamientos de energía térmica y las baterías, en particular. Por otro lado, el tercero, revisa los sistemas de control empleados en los sistemas de climatización, para reducir el consumo energético y mejorar la eficiencia energética. Por último, en el cuarto, se describe brevemente el uso que se hace de esta tecnología en las redes inteligentes y cómo esta combinación es optimizada incorporando también el uso de blockchain.

En el último apartado, el quinto, se presentan las conclusiones obtenidas a lo largo del trabajo, realizando un análisis sobre las ventajas e inconvenientes detectados en este tipo de tecnología, los principales desafíos a abordar y los posibles siguientes pasos.

En definitiva, el objetivo de este trabajo es realizar una revisión sobre cómo la Inteligencia Artificial puede servir de medio para lograr una transición energética mejor, sirviendo mejorar la eficiencia energética, reducir desperdicios y costes, contribuyendo a conseguir un modelo energético más resiliente y respetuoso con el medio ambiente.

2 LA TRANSICIÓN ENERGÉTICA Y EL PARADIGMA ACTUAL

"La transición hacia energías renovables no solo es una necesidad ambiental, sino también una oportunidad económica. Los países que la lideren serán los líderes del futuro" - Angela Merkel

En las últimas décadas las energías renovables han tenido un notable auge como consecuencia de la transición energética. Debido a las altas emisiones de gases de efecto invernadero que tiene como consecuencia el consumo de combustibles fósiles, se está llevando a cabo un proceso de cambio de fuentes de energía a nivel mundial. Sin embargo, no son los factores ambientales los únicos impulsores de esta transición, sino también componentes económicos, tecnológicos y políticos. A modo de resumen, los principales factores que motivan la transición energética son:

1. Factores ambientales: Debido al cambio climático es necesario reducir la emisión de gases de efecto invernadero. Por ende, será necesario reducir el uso de combustibles fósiles pues suponen la principal fuente de CO_2, perjudicando tanto la calidad del aire, como el medio ambiente y la salud pública. Así, el principal objetivo de la transición energética es reducir la dependencia de dichos combustibles (petróleo, gas natural y carbón) para usar, en su lugar, fuentes de energía que resulten menos contaminantes (energías renovables). De esta manera, no solo se prescindiría del uso de combustibles nocivos para el medio ambiente, sino que se sustituirían fuentes de energía limitadas, por otras en las que el agotamiento no sería un problema que afrontar.

2. Factores tecnológicos: Los avances tecnológicos son los responsables de conseguir una mayor eficiencia en las fuentes de energía renovables. Además, gracias a la innovación realizada en sistemas de almacenamiento, se puede hacer frente a problemas históricos de las energías verdes, como la intermitencia, dando lugar ahora a un suministro constante y, por tanto, fiable. Además, y como se verá en apartados posteriores, el uso de Inteligencia Artificial para la gestión energética consigue mejorar la eficiencia operativa y el aprovechamiento de los recursos disponibles.

3. Factores económicos: Por otro lado, los combustibles fósiles no son renovables y se encuentran en una situación próxima a agotarse, siendo su extracción cada vez más compleja y de mayor coste. Además, en contraposición al incremento de coste de estos, los avances tecnológicos han permitido

también que las energías renovables sean cada vez más asequibles, produciéndose una significativa reducción de su coste. De esta manera, energías como la solar o la eólica son ahora fuentes de energía competitivas frente a las fuentes de energía convencionales. La transición energética implica una revolución a nivel de empleo en distintos sectores relacionados con la fabricación, instalación y mantenimiento de tecnologías limpias, suponiendo la creación de nuevos puestos de trabajo y, por tanto, un crecimiento económico.

4. Factores políticos: El consumo energético global tiene consecuencias directas e indirectas en el panorama político. En primer lugar, la dependencia de combustibles fósiles, estando estos distribuidos de forma desigual alrededor del mundo, da lugar a problemas geopolíticos. Por otro lado, existen ya marcos normativos y políticas adoptadas que fomentan el uso de energías renovables, siendo estas cruciales para fomentar el uso de las energías limpias. Por último, el uso de energías renovables se traduce en una mayor estabilidad energética, pues la diversificación de los recursos da lugar a una menor dependencia de importaciones y a una mayor estabilidad ante la variación de precios o posibles crisis energéticas.

La combinación de estos cuatro factores sirve de impulso a nivel mundial hacia sistemas energéticos más limpios y sostenibles. Así, para lograr este objetivo, son necesarios una serie de componentes clave para la transición:

Para que la transición energética pueda tener lugar, es necesaria la modernización de tecnologías e infraestructuras, la inversión por parte de distintos gobiernos y países, así como la modificación de los marcos normativos y políticos de muchos de ellos. El acuerdo y sincronización de todos estos cambios a nivel mundial supone un reto tanto para los distintos gobiernos como para los pequeños consumidores, que deben cambiar su paradigma de consumo. Es, sin duda, un proceso complejo destinado a alargarse en el tiempo pero que, lejos de ser abstracto, está ya siendo implementado y monitoreado de distintas maneras a nivel mundial.

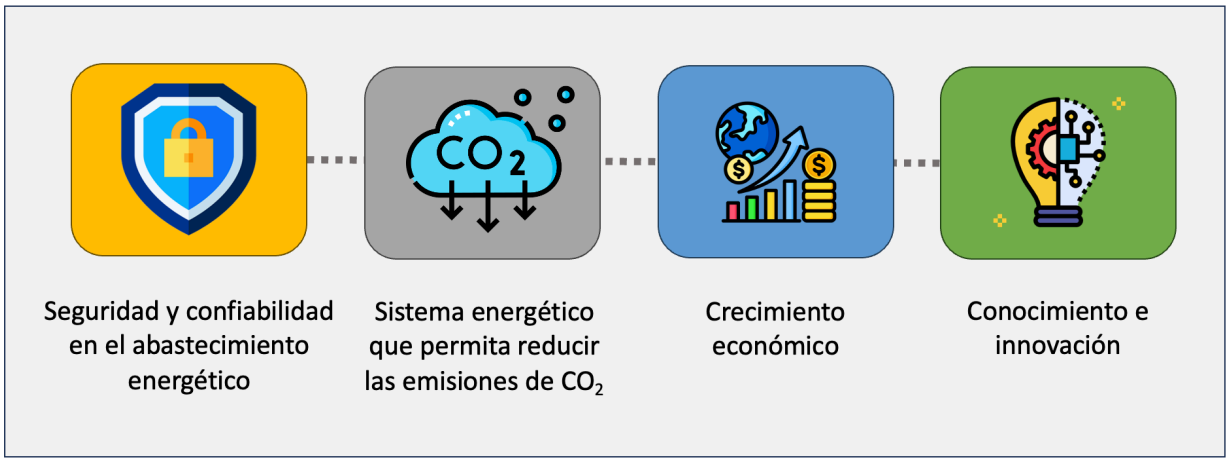


Figura 2.1 Pilares de la transición energética

En los siguientes apartados, se expondrán cuáles son esos cambios necesarios a nivel tecnológico, las inversiones que se están realizando y las políticas que se están implementando para que esta transición sea posible. Además, se enlazará todo ello con la Inteligencia Artificial, exponiendo cómo esta puede facilitar y optimizar este cambio tan necesario. Sin embargo, antes de ahondar en los pormenores de la transición energética actual, se presenta el marco histórico y los precedentes que nos han llevado hasta el punto en el que nos encontramos.

2.1. Marco histórico y precedentes de la transición energética

Aunque al mencionar el término "transición energética" se suele pensar en la evolución hacia fuentes de energía más limpias, históricamente no es el primer cambio sucedido a este respecto. Ya existen precedentes de cambio en el uso de fuentes de energía previos al enfoque de sostenibilidad actual y estos, se han desarrollado a lo largo de distintos momentos de la historia.

- El primer cambio tuvo lugar con la Revolución Industrial. Antes de esta, las principales fuentes de energía provenían de la biomasa, como por ejemplo la madera. Sin embargo, con la revolución de la industria iniciada a finales del siglo XVIII, el carbón pasó a tener un papel protagonista, por ser el combustible consumido por las máquinas de vapor.
- La segunda transición energética acontecida fue la sucedida en el siglo XX, época en la que los motores de combustión interna y el sector automovilístico tuvieron un gran crecimiento. Así, el petróleo y el gas natural sustituyeron al carbón, tanto por su mayor eficiencia energética como por su ahorro de costes a la hora de ser transportado. Además, cabe destacar también este siglo el desarrollo de la energía nuclear. Sin embargo, se considera aún a día de hoy una fuente de energía que genera grandes controversias debido la naturaleza de sus residuos, a los problemas de seguridad y la gravedad de sus consecuencias.
- El tercer y último gran cambio, hasta la fecha, es el relativo al desarrollo de tecnologías renovables a finales del siglo XX y principios del XXI. Si bien la preocupación por el medio ambiente ha ido en crescendo, las energías renovables como la solar, la eólica, la hidroeléctrica y la geotérmica se han empezado a desarrollar y a implementar, reduciendo los costes a ellas asociados y aumentando su eficiencia.

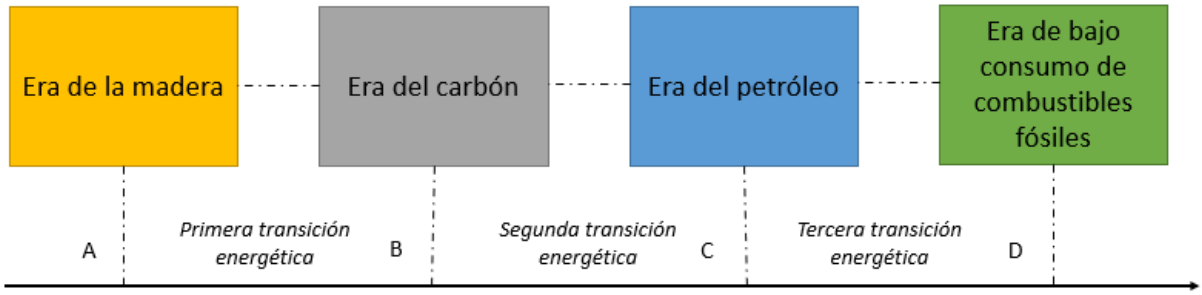


Figura 2.2 Transiciones energéticas a lo largo de la historia

Cada una de estas transformaciones (Figura 2.2) refleja una evolución en la comprensión y la capacidad tecnológica de la humanidad para aprovechar distintas fuentes de energía. La transición energética actual hacia fuentes renovables y sostenibles es parte de este largo proceso de evolución, teniendo esta vez un enfoque más fuerte en la sostenibilidad ambiental y la seguridad energética. De esta manera, y como consecuencia del aumento de la conciencia sobre los problemas ambientales globales, se han establecido diversas políticas y acuerdos internacionales como el Protocolo de Kioto y el Acuerdo de París, para reducir las emisiones de gases de efecto invernadero y promover el uso de energías limpias.

Por otro lado, el marco histórico de la transición moderna muestra cómo esta es un fenómeno multifacético y evolutivo, influido por factores técnicos, económicos, políticos y sociales. La historia de la energía siempre ha estado en transición, pero la fase actual es única en su enfoque en la sostenibilidad y el medio ambiente. Así, esta tercera transición se enmarca dentro de una serie de acontecimientos que han resultado ser clave para que esta pueda tener lugar. Dentro de ellos, cabe destacar una serie de hitos sucedidos a lo largo de los últimos 50 años que ha fomentado su desarrollo. A saber:

- Las crisis del petróleo de 1973 y 1979. Estas pusieron en evidencia la vulnerabilidad de la dependencia mundial de este combustible, especialmente el proveniente de regiones geopolíticamente inestables. Debido a esto, muchos países comenzaron a buscar fuentes de energía alternativas y a mejorar la eficiencia energética.

- El aumento de la conciencia ambiental. A raíz de dos grandes accidentes sucedidos en la segunda parte de la década de los 80 se iniciaron fuertes movimientos ambientalistas. Tanto el accidente nuclear de Chernóbil en 1986 como el derrame de petróleo del Exxon Valdez en 1989 dieron lugar a un debate público sobre los impactos ambientales de las fuentes de energía tradicionales, generando un mayor interés en alternativas renovables.

- La reducción de costes de las renovables. Los desarrollos tecnológicos llevados a cabo desde la década de los 90 han permitido que las energías renovables, especialmente solar y eólica, hayan disminuido notablemente sus costes de producción. Gracias a esto, este tipo de tecnología se ha vuelto más competitiva frente a los combustibles fósiles tradicionales.

- El Protocolo de Kioto. Este tratado internacional, aprobado en 1997, fue uno de los primeros acuerdos que establecía metas para cuantificar y limitar las emisiones de gases de efecto invernadero por parte de 37 países y la Unión Europea. Así, instauró un marco en el que tanto gobiernos como empresas se han visto obligados a considerar el medio ambiente a la hora de tomar decisiones y crear leyes.

- El Acuerdo de París. Este acuerdo, firmado en 2015 por 196 países, estableció un plan de acción mundial para limitar el calentamiento global a menos de 2°C por encima de los niveles preindustriales, con esfuerzos para intentar no superar los 1,5°C. Gracias a él, los países involucrados han basado sus estrategias en la reducción del uso y dependencia de los combustibles fósiles, así como en su compromiso con las energías renovables.

- Los objetivos de Desarrollo Sostenible. Esta iniciativa, lanzada por las Naciones Unidas en 2015, está compuesta por 17 objetivos interconectados diseñados para conducirnos a un futuro más sostenible y equitativo para todos. Estos objetivos abarcan una amplia gama de metas, incluyendo varias en relación a la protección del medio ambiente.

- Los avances en políticas a nivel mundial. Son numerosos los países que han implementado sus propias políticas para promover la transición energética a lo largo de los últimos 25 años. Un claro ejemplo de ello son los subsidios para energías renovables, los impuestos a los combustibles fósiles y las normativas para mejorar la eficiencia energética tanto de edificios como de vehículos.

- La innovación tecnológica y la economía verde. En la última década, el avance realizado en almacenamiento de energía, como las baterías de iones de litio, ha mejorado la viabilidad de las energías renovables. Además, conceptos como las redes inteligentes, la movilidad eléctrica o el uso de la inteligencia artificial están transformando la infraestructura energética y el uso que de ella se hace.

2.2. El Acuerdo de París y los Objetivos de Desarrollo Sostenible

Dentro de los hitos destacados en el apartado anterior, caben destacar dos de ellos, tanto por su relevancia e impacto aún la actualidad como por su conexión y relevancia para la Inteligencia Artificial y el modo en el que esta se aborda dentro del sector energético. Ambos hitos, acontecidos en el año 2015, están estrechamente relacionados y resultan cruciales para entender cómo se aborda a nivel mundial la sostenibilidad ambiental.

2.1.1 El Acuerdo de París

El Acuerdo de París es un tratado aprobado en diciembre de 2015 en la 21ª Conferencia de las Partes de la Convención Marco de las Naciones Unidas sobre el Cambio Climático. Entró en vigor en noviembre de 2016 estando firmado por 196 países y suponiendo el primer acuerdo vinculante mundial de lucha contra el calentamiento global. Establece un plan de acción para conseguir, como principal objetivo, que la temperatura media de la Tierra se incremente un máximo de 2°C en 2100, intentando ajustarlo a no más de 1,5°C. Este objetivo se traduce en reducir las emisiones de los denominados gases de efecto invernadero en un 80% para el año 2050 respecto a 1990. El objetivo de estas medidas, es limitar el calentamiento global para así frenar ciertos problemas a día de hoy ya existentes, como el aumento del nivel del mar fruto del derretimiento de los glaciares, la contaminación del aire, los daños en la capa de ozono, etc.



Figura 2.3 Logo Acuerdo de París [72]

Dentro de los compromisos alcanzados dentro del tratado, los países aceptaron someterse a revisiones cada cinco años para fomentar un marco de transparencia que monitorice el progreso. Además, como parte del acuerdo, se ofreció financiación a los países aún en desarrollo para que también pudieran tomar medidas que frenaran el cambio climático para fortalecerles y mejorar así su capacidad para hacer frente a los impactos de este. De esta forma, la implementación del Acuerdo de París tiene lugar en ciclos de cinco años momento en el que los países participantes envían su plan nacional actualizado de acción climática, conocido como Contribución Determinada a Nivel Nacional o CDN. En sus CDN, los países publican las medidas que implementarán para reducir sus emisiones de gases de efecto invernadero para así alcanzar los objetivos del Acuerdo de París.

Si bien, estas contribuciones no son vinculantes legalmente, la participación de cada país en este proceso de revisión global sirve para impulsar la ambición colectiva. Esto resulta fundamental, pues el éxito del Acuerdo de París depende de la voluntad y el compromiso de todos los países para aumentar sus ambiciones y realizar acciones concretas hacia un futuro sostenible y de bajas emisiones de carbono.

2.1.2 Los Objetivos de Desarrollo Sostenible

En el año 2015, la Organización de las Naciones Unidades (ONU) estableció los denominados "Objetivos de Desarrollo Sostenible" (ODS), con el fin de abordar los principales problemas económicos, ambientales y sociales a los que se hacen frente a nivel mundial. De acuerdo a la ONU, esto pretende ser un plan de acción que sirva tanto para las personas como para el planeta, en favor de la prosperidad. De esta manera, los ODS se estructuran en 17 puntos, destinados a eliminar la pobreza, mejorar la educación, reducir la desigualdad, promover la salud y proteger el medio ambiente. El plazo marcado en primera instancia es la consecución de objetivos para el año 2030, provocando que distintos países trabajen coordinados para alcanzar dichas metas.

Como se puede ver en la imagen siguiente, son varios los objetivos relacionados con el sector energético, siendo fiel reflejo de la estrecha relación existente entre la transición energética y los ODS. De esta manera, para lograr un desarrollo sostenible, resulta necesario reconocer del papel esencial que juega la energía. Así, la consecución de sistemas energéticos sostenibles, asequibles y de confianza resulta fundamental para alcanzar muchos de los objetivos previstos por la ONU.

Dentro de los 17 ODS previstos, son 8 los que tienen un mayor impacto en el panorama energético, a saber:

- ODS 7: Energía Asequible y No Contaminante.
- ODS 13: Acción por el Clima.

- ODS 11: Ciudades y Comunidades Sostenibles.
- ODS 9: Industria, Innovación e Infraestructura.
- ODS 12: Producción y Consumo Responsables.
- ODS 15: Vida de Ecosistemas Terrestres.
- ODS 3: Salud y Bienestar.
- ODS 6: Agua Limpia y Saneamiento.



Figura 2.4 Objetivos de Desarrollo Sostenible [1]

Sin embargo, son los objetivos 7 y 13 (Figura 2.4) los que tienen un mayor impacto en el panorama energético, pues abordan directamente las cuestiones de energía sostenible y acción climática, respectivamente, siendo así fundamentales en el contexto global actual. De esta forma, no solo son cruciales para mitigar el cambio climático sino también para promover un desarrollo económico y social sostenible.

Por otro lado, ambos objetivos están interconectados, pues una de las estrategias más efectivas para combatir el cambio climático que se propone en el ODS 13 es la transición a energías limpias y asequibles que se plantea en el ODS 7. Además, el desarrollo de estos objetivos repercute en la consecución del resto de manera directa por lo que se la interdependencia del marco de desarrollo sostenible.

A continuación, se resumen brevemente los dos objetivos más arriba citados:

ODS 7: Energía Asequible y No Contaminante



Figura 2.5 Infografía oficial ODS 7 [2]

Este objetivo promueve el uso de las fuentes de energía renovables, a la par que la mejora de la eficiencia energética como medio para reducir el consumo de las energías tradicionales (combustibles fósiles). De esta manera, se reduce la dependencia de unas fuentes de energía de alto coste y contaminación pasando a unos sistemas más sostenibles, modernos y de menor coste.

OBJETIVO	Garantizar el acceso a una energía limpia, asequible, segura, sostenible y moderna.
IMPORTANCIA	Acceso a la Energía: 675 millones de personas viven sin acceso a la electricidad. En caso de continuar el ritmo de cambio actual, para el año 2030 alrededor de 2000 millones de personas seguirán dependiendo de combustibles fósiles. Resulta vital garantizar este tipo de acceso a energías limpias para promover la calidad de vida, en especial la salud, y mejorar el medio ambiente. Sostenibilidad Energética: Virar a este tipo de fuentes de energía sostenible se traduce a su vez en la reducción de las emisiones de carbono y otros contaminantes, consiguiendo así frenar el cambio climático y mejorando la salud pública. Eficiencia Energética: Reduciendo por ende tanto el consumo de energía como el coste asociado a esta.
ACCIONES Y ESTRATEGIAS	Aumentar la proporción de energía renovable en el marco energético mundial. Duplicar la tasa global de mejora de la eficiencia energética. Mejorar la tecnología e incrementar las infraestructuras para así conseguir servicios energéticos sostenibles y asequibles a nivel mundial.

Tabla 2.1 Resumen ODS 7

ODS 13: Acción por el Clima



Figura 2.6 Infografía oficial ODS 13 [3]

Como se ha comentado en apartados anteriores, la emisión de gases de efecto invernadero impacta de manera directa en el cambio climático acelerándolo de una manera para la que los países no tienen armas con las que hacer frente a las consecuencias. Por ello, tomar medidas que disminuyan el ritmo de avance de este resulta de especial importancia. Así, la transición energética se ha convertido en la palanca de cambio para combatir este y reducir su impacto.

OBJETIVO	Combatir el cambio climático y su impacto.
IMPORTANCIA	Urgencia Climática: En caso de no adoptar medidas de carácter urgente, se prevé que la temperatura media mundial se eleve por encima de los 3ºC. Por ello, y para evitar las repercusiones que se generarían fruto de ese delta, es necesaria la acción inmediata para proteger los ecosistemas, la salud humana, la producción de alimentos y el acceso al agua. Resiliencia y Adaptación: Promoviendo estrategias a nivel mundial para que los distintos países consten de herramientas con las que hacer frente a este cambio climático.

ACCIONES Y ESTRATEGIAS	Integrar medidas de cambio climático en las políticas nacionales y estrategias de planificación. Mejorar la educación, la sensibilización y la capacidad humana e institucional respecto a la mitigación del cambio climático, la adaptación, la reducción de impacto y la alerta temprana. Cumplir con los compromisos del Acuerdo de París, incluyendo los compromisos financieros de los países desarrollados para apoyar las acciones en los países en desarrollo.

Tabla 2.2 Resumen ODS 13

2.3. La transición energética y la Inteligencia Artificial

Existen dos maneras de generar energía eléctrica, a saber, la generación térmica y la renovable. Como se ha visto en los apartados anteriores, dada la situación actual con los combustibles fósiles y el cambio climático, la sociedad está virando hacia una producción de energía más sostenible y limpia. De acuerdo a la Agencia Internacional de la Energía (AIE), la energía renovable tendrá una capacidad de 10.800 GW en 15 años, incluyendo fuentes como la energía solar, eólica o geotérmica, entre otras [4]. Si bien este tipo de fuentes de energía se caracterizan por ser inagotables y respetar al medio ambiente, también presentan ciertos hándicaps, como su intermitencia, inestabilidad y la dificultad de integrarlas en los sistemas de red actuales, por los problemas que presenta para realizar estimaciones óptimas.

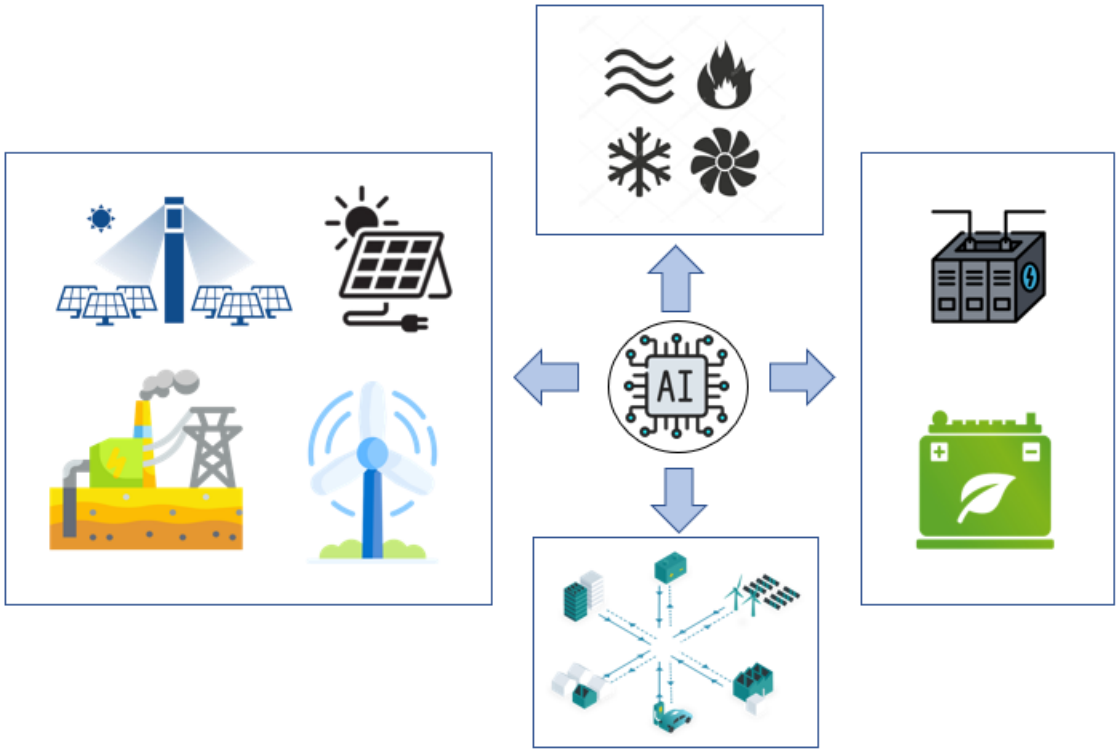


Figura 2.7 Uso de la IA en diferentes sistemas energéticos

De esta forma, la Inteligencia Artificial surge como adalid para abordar este tipo de problemas para las fuentes renovables, así como para otros sistemas energéticos que también cumplen un papel fundamental

en la transición energética. Así, los sistemas de almacenamiento de energía, la optimización de los sistemas de climatización y las redes inteligentes que emplean fuentes renovables, desempeñan también un papel fundamental en esta transición y, a su vez, hacen uso de la Inteligencia Artificial para mejorar su rendimiento (Figura 2.7). De esta manera, el uso de la Inteligencia Artificial permite mejorar la productividad de todos estos sistemas energéticos, reducir sus costes y mejorar su operatividad para integrarlos en el panorama energético actual.

A continuación, se hace un breve repaso por todos estos sistemas energéticos, cuyos sistemas de control basados en Inteligencia Artificial se expondrán en el apartado 4, describiendo ahora la relevancia de cada uno de ellos y los espacios de mejora que se pueden abordar al incorporar este tipo de sistemas de control.

En primer lugar, y en lo relativo a las energías renovables, se verá principalmente el uso que se hace de la IA para las energía solar y eólica. La energía solar, por su parte, es la energía más limpia y extendida a nivel mundial. Sin embargo, de la misma forma que sucede con la energía eólica, es intermitente, reduciendo por tanto su fiabilidad. El uso de Inteligencia Artificial permitirá solventar este tipo de desafíos, sirviendo para realizar predicciones sobre la generación de energía, tratando así de compensar el desfase existente entre la oferta y la demanda de la red eléctrica derivado de dicha intermitencia. Además, y en relación al almacenamiento de energía, servirá también para optimizar el uso de estos y, por ende, la estabilidad del sistema energético. Así, y gracias a la implementación de la Inteligencia Artificial en ambas tecnologías, se fomenta el cumplimento de los ODS 7 y 13, al facilitar un acceso más fiable y sostenible a la energía y disminuir las emisiones de gases de efecto invernadero, respectivamente.

Por otro lado, este tipo de tecnologías permite no solo realizar predicciones sobre la demanda sino también realizar predicciones en lo relativo al mantenimiento de los equipos, disminuyendo el tiempo que estos están fuera de servicio y mejorando, por tanto, tanto la fiabilidad de los sistemas como el coste de estos. Por último, se verá también como la Inteligencia Artificial se emplea para diseñar sistemas energéticos, ya sean sistemas de energía renovable o de almacenamiento de energía, permitiendo no solo optimizar su diseño y ubicación, sino también los materiales empleados en estos. En este caso, además del ODS 7, los ODS 9 y 12 se ven afectados, gracias al fomento de la innovación tecnológica para el primero, y la optimización de los recursos en las tareas de operación y mantenimiento en el segundo.

En lo relativo a los sistemas de climatización, estos suponen un consumo energético importante dentro del consumo global, por lo que mejorar su rendimiento y eficiencia energética supone un reto importante como parte de la transición energética. Así, el objetivo de la Inteligencia Artificial en este caso es mejorar la eficiencia energética de estos a la par que se mantiene el confort térmico, impactando por tanto de manera positiva en los ODS 7, 9 y 11. Al igual que sucedía con las energías renovables y los sistemas de almacenamiento, la Inteligencia Artificial permite realizar tareas predictivas sobre los sistemas de climatización. Por una parte, permiten predecir las condiciones térmicas y los parámetros necesarios del sistema para poder alcanzar el objetivo óptimo del sistema. Por otra, permiten también realizar tareas de mantenimiento predictivo, con ventajas similares a las vistas anteriormente. Además, el uso de Inteligencia Artificial permite optimizar el rendimiento de estos en tiempo real, considerando tanto las necesidades desde el punto de vista térmico como las necesidades de acuerdo a los picos de la demanda eléctrica, intentando en todo momento reducir el consumo en los momentos críticos sin perjudicar el confort térmico. Por último, y en lo relativo a los sistemas de climatización, la Inteligencia Artificial permite gestionar los encendidos y apagados de los equipos de acuerdo a la inercia térmica del edificio y al comportamiento de los ocupantes del mismo, pues tiene la capacidad de aprender del histórico de peticiones de estos de acuerdo a las condiciones de cada momento.

Para terminar, y en lo relativo a las redes inteligentes, estas juegan un papel fundamental promoviendo la transición energética. Su uso, permite integrar fuentes renovables de manera descentralizada, facilitando por tanto el cambio hacia una generación eléctrica distribuida. Además, permiten reducir el consumo energético y aumentar la eficiencia, gracias al monitoreo que hacen de la electricidad en tiempo real. Si bien este tipo de redes presentan múltiples ventajas y son parte importante en la transición energética,

presentan a su vez una serie de desafíos que la Inteligencia Artificial es capaz de abordar con distintos sistemas de control y predicción. En primer lugar, permiten mejorar la gestión de la demanda en tiempo real, actuando en caso de picos y reduciendo por tanto los costes asociados a las fuentes de energía de soporte. Por otro lado, permiten también hacer una mejor integración de las energías renovables, gestionando la generación de energía de acuerdo a la intermitencia de estas. Además, permite mejorar las tareas de mantenimiento predictivo, reduciendo los costes, la respuesta en caso de incidentes y mejorando la experiencia de usuario. Por último, además de optimizar el almacenamiento de energía, permite reducir las pérdidas energéticas a la par que permite implementar estrategias de gestión energéticas en las que automatizar y optimizar el funcionamiento de las redes inteligentes.

En definitiva, existe una sinergia entre las fuentes de energía renovables, las redes inteligentes y el almacenamiento de energía que impacta directamente en la transición energética, así como también lo hace el consumo y la forma de operar los sistemas de climatización. Para poder mejorar esta y optimizar el uso que se hace de todas estas tecnologías, el uso de técnicas de Inteligencia Artificial permite mejorar el rendimiento de estas, reduciendo el consumo, los costes y mejorando la seguridad y fiabilidad de las mismas.

3 INTELIGENCIA ARTIFICIAL

"Una computadora puede ser llamada 'inteligente' si logra engañar a una persona haciéndole creer que es humano." - Alan Turing

A lo largo de las últimas décadas, el ser humano ha aspirado a la creación de tecnologías que imitaran el comportamiento y razonamiento humano. A la hora de establecer en qué consiste ese razonamiento humano y qué es lo que caracteriza nuestra forma de funcionar y procesar la información, el protagonista no es otro que el cerebro. Este es un órgano que gobierna desde el procesamiento de los estímulos que percibimos a través de nuestros sentidos hasta almacenar toda esa información, realizar razonamientos lógicos, sentir emociones o imaginar. Al fin y al cabo, es el símbolo de la evolución y lo que nos hace "inteligentes". Pues bien, esta inteligencia es la que se pretende conseguir con máquinas que imitan nuestro comportamiento: sistemas inteligentes que reproducen nuestra forma de pensar y sirven para dar respuestas únicas, creativas, complejas y razonadas a problemas de distintas casuísticas.

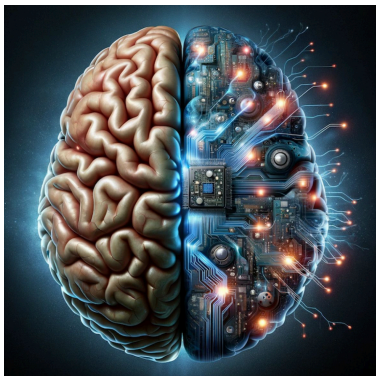


Figura 3.1 Representación de la IA emulando al cerebro humano [5]

Sin embargo, la creación de este tipo de sistemas supone un reto a nivel tecnológico y de programación, que se estudia dentro del campo de la Inteligencia Artificial (IA). Pues bien, en el próximo apartado se definirá el término IA, su funcionamiento, tipos, problemas y futuro. El objetivo de este apartado es, junto con el anterior, servir como preámbulo del siguiente apartado de este TFM, en el que se establecerá la

relación existente entre la IA y el sector energético. Si bien el alcance de dicha relación supondría un estudio mucho más extenso y complejo que el realizado en este trabajo, el cuarto apartado se centrará en el uso de la IA para gestionar y controlar sistemas energéticos.

3.1. Definición de Inteligencia Artificial

La Inteligencia Artificial (IA) se enmarca dentro del campo de estudio de la informática y su objetivo es la creación de sistemas informáticos que lleven a cabo tareas para las que normalmente se requiere de inteligencia humana. De esta manera, es una rama compleja y multidisciplinar cuyas técnicas y métodos persiguen conseguir máquinas que repliquen parcialmente el pensamiento y el comportamiento humano. Así, al emular las funciones cognitivas de las personas, son capaces de llevar a cabo una tipología de tareas muy extensa, como la resolución de problemas complejos, traducción de distintos idiomas, procesos de percepción y aprendizaje o asistentes personales y digitales, entre otros.

La IA, por tanto, genera sistemas que perciben los datos de su entorno, procesan la información de entrada y generan una respuesta a ellos. Para generar este tipo de respuesta, se emplean una serie de modelos y algoritmos que interpretan los datos de manera autónoma y generan conclusiones basándose en datos y experiencias pasadas. La diferencia entre esta forma de funcionar y la de los sistemas informáticos tradicionales es que la IA tiene capacidad de adaptación, usando códigos compuestos por listados de instrucciones que son más flexibles y pueden procesar grandes cantidades de datos, en busca de patrones con los que aprender de acuerdo a la nueva información obtenida. Además, no solo compone su proceso con datos procedentes de campos científicos o tecnológicos, sino que los combina con otros de diversas disciplinas, incluyendo psicología, sociología, filología, o historia, danto lugar a resultados creativos y originales.

Si bien una de las principales características es, como se ha visto, la capacidad de adaptación, existen a su vez dos tipos de IA de acuerdo a cuán alta sea esta capacidad:

- IA generativa:

Este subcampo de la IA realiza tareas de acuerdo a los datos que recibe de los usuarios. De esta forma es capaz de crear contenido nuevo en distintos formatos (material audiovisual, softwares y textos) a partir de datos ya existentes. Este tipo de IA se suele emplear para la creación de contenido, especialmente para las artes y la música, y procesamiento de lenguaje logrando material muy parecido al que generaría un ser humano.

- IA adaptativa:

Por otro lado, este tipo de IA tiene una capacidad de adaptación mayor que la generativa. Así, la IA adaptiva va ejecutando cambios durante la toma de decisiones, fruto de su aprendizaje en función del entorno. De esta manera, su objetivo es conseguir rapidez, precisión e inmediatez a la hora de conseguir resultados, buscando que estos sean dinámicos y basados en datos lo más recientes posibles. Para lograr todo esto, la IA adaptiva reescribe el código conforme este se va ejecutando, realimentándose de los resultados en tiempo real y optimizando la respuesta de manera simultánea. Este tipo de IA se emplea, por tanto, en sectores que necesiten entornos dinámicos, adaptaciones a tiempo real y toma de decisiones precisas minimizando los errores, como puede ser la realización de predicciones o el análisis de datos.

No es de extrañar, por tanto, que la IA adaptiva se postule como modelo con más potencial para los próximos años. De acuerdo a la empresa Gartner, aquellas compañías que empleen sistemas de ingeniería para desarrollar IA adaptativa contarán con una ventaja del 25% en su rendimiento para el año 2026, tanto en velocidad como en número de modelos de IA que estén operativos [6].

A modo de resumen se presenta la tabla a continuación (Tabla 3.1):

	IA generativa	IA adaptativa
Aprendizaje	Emplea datos existentes y patrones previos, sin ir reajustando la respuesta de acuerdo a los cambios detectados.	Aprendizaje continuo y reajusta de respuesta de acuerdo a lo aprendido, para dar respuestas más precisas.
Flexibilidad	Encuentra una limitación en la flexibilidad, dado que no va modificando las reglas y patrones de entrada una vez comienza a ejecutarse	Más flexible gracias a la adaptación y aprendizaje de datos nuevos, danto lugar a menor número de errores.
Aplicaciones	Sectores creativos orientados a la búsqueda de resultados originales. Creación de contenido y procesamiento del lenguaje.	Sectores que necesiten entornos dinámicos y actualizaciones en tiempo real.
Tipología de resultados	Resultados creativos, como material audiovisual. Entregables innovadores, únicos y similares a los que habría generado un ser humano.	Pronósticos y resultados basados análisis de datos que se ajustan a condiciones de entrada cambiantes.

Tabla 3.1 Comparación IA generativa y adaptativa

3.2. Marco histórico de la IA

Si bien cuando se hace referencia a la historia de la IA todo el que tenga un mínimo conocimiento sobre el tema piensa en Alan Turing y la década de los 50, ya existían referencias a esta mucho antes de ese momento. De hecho, el concepto que sustenta la IA en base al que tenemos máquinas capaces de "pensar solas" ha sido una idea presente en el ser humano ya desde la antigüedad. El primer registro en relación a esta idea data del año 1842 [7], cuando la pensadora y matemática Ada Love diseñó el primer código similar a un algoritmo que emplearía una máquina. Ella misma especuló con la posibilidad futura de tener máquinas que podrían hacer más allá que procesar datos y números, vaticinando cómo podrían, por ejemplo, componer piezas musicales de diferente longitud y complejidad.

No sería hasta 100 años después de ese hecho, que la IA arrancaría realmente como concepto, hasta llegar a la situación actual. Sin embargo, este camino no se ha producido de manera lineal, sino que ha pasado por distintas épocas, de mayor o menor avance en función de las circunstancias.



Figura 3.2 Representación de la evolución del ser humano hasta la IA [7]

De acuerdo a esto, las etapas en la historia de la inteligencia artificial, son:

Nacimiento de la IA (1950 – 1956)

Aunque el nacimiento de la IA está fechado en el año 1950, existe un precedente pocos años antes que es considerado por muchos como la primera inteligencia artificial. Así, en el año 1943, los investigadores Warren McCulloch y Walter Pitts publicaron el artículo "*A logical calculus of ideas immanent in nervous activity*", en el que presentaban por primera vez una red neuronal artificial.

No sería hasta 7 años después, en 1950, que dos hechos sentarían el nacimiento de la IA. En primer lugar, se crea el primer ordenador de red neuronal, llamado Snarc, de la mano de dos alumnos de la Universidad de Harvard. Por otro lado, ese mismo año, el matemático inglés Alan Turing publica en la revista *Mind* el artículo "*Computing machinery and intelligence*" en el que propone el famoso Test de Turing, utilizado aún a día de hoy para valorar las IA. Con este, Turing plantea si las máquinas pueden o no pensar realmente, tratando de demostrar la inteligencia de las máquinas testeando sus respuestas en comparación a las que daría una persona.

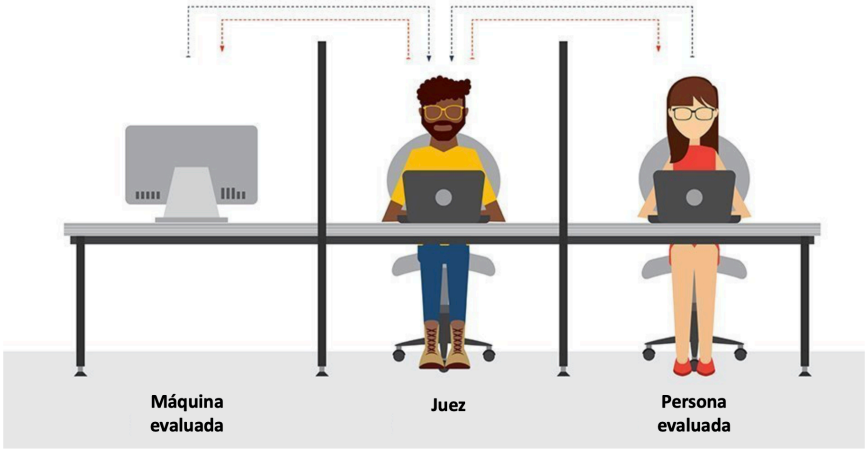


Figura 3.3 Test de Turing [8]

El experimento estaba formado por una máquina y dos seres humanos (Figura 3.3). Durante la misma, uno de los seres humanos operaba como juez, y lanzaba preguntas tanto a la otra persona como al ordenador, que ambos debían contestar. Si bien no proponía un número cerrado de preguntas a realizar, sí establecía un criterio a través del cual dirimir si el ordenador era inteligente o no: en caso de que el juez fallara más de la mitad de las veces qué respuesta provenía de la persona y cuál de la máquina, se podía concluir que la segunda era inteligente.

Por último, en esta etapa, se incluye la conferencia "*Darthmouth Summer Reasearch Project on Artificial Intelligence*" en 1956 por ser la primera vez que se empleaba el término "Inteligencia Artificial" de la mano de John McCarthy.

Maduración de la IA (1957 – 1973)

Durante este periodo hubo un rápido crecimiento de la IA, que cada vez resultaba más popular. En estos años, se crearon numerosos lenguajes de programación y tuvieron lugar varios avances. De esta manera, Arthur Samuel creó el término "*Machine Learning"* en 1959, trabajando para la empresa IBM. Por otro lado, en 1961, la compañía General Motors crea *Unimate,* el primer robot industrial que se usaría en cadenas de montaje para transportar y soldar partes de automóviles en Nueva Jersey. Dos años después, se fundaría el *MIT Artificial Project* de la mano de John McCarthy, que también propulsó el Laboratorio de IA en la Universidad de Stanford. En el año 1964, se desarrolla el primer programa informático de PNL (Procesamiento Natural del Lenguaje) de la mano de Joseph Wizenbaum, considerándose este como el primer *chatbot*.

Sin embargo, a partir del año 1966 el avance comienza a decaer debido a varios motivos. Por un lado, ese mismo año, el gobierno de Estados Unidos encargó el informe ALPAC (*Automatic Language Advisory Comittee)* para evaluar la traducción automática empleada para las traducciones del ruso en la Guerra Fría. El informe arrojó resultados muy negativos, en los que ponía en evidencia la falta de avances de una tecnología que no había cumplido con los objetivos. Esto dio lugar a la cancelación de muchos proyectos por la reducción de la financiación de muchos patrocinadores, entre los que cabe destacar el Departamento de Defensa y la CIA.

Por otro lado, en 1973, el matemático James Lighthill publicaba el informe "*Lighthill*". En él, se hacía un análisis similar al llevado a cabo en el informe ALPAC años antes, evaluando negativamente el avance de la IA, lo que condujo al gobierno británico a reducir también su financiación.

Primer invierno de la IA (1974 – 1980)

A raíz de los dos eventos anteriores, dio comienzo el primer invierno de la IA. Si bien hubo algún avance aislado, como que un vehículo autónomo fuera capaz de recorrer una estancia llena de obstáculos de manera exitosa (1979), la falta de financiación provocó una caída en la investigación durante estos años.

Auge de la IA (1980 – 1987)

El avance que supuso un antes y un después para poder dar por terminado el primer invierno fue la creación, por parte de *Digital Equipment Corporations* en 1980, del primer configurador experto, XCON. Este sería un sistema comercial destinado a la creación de nuevos pedidos informáticos. Eso dio paso a una década sucedió llena de numerosos avances de la mano de un aumento en la financiación, lo que se conoció como el *boom* la IA. A modo de ejemplo, y como otros avances de esa década, caben destacar el primer automóvil sin conductor creado en 1986 o el primer sistema de asesoría estratégica creado en 1987.

Segundo invierno de la IA (1987 – 1993)

En el año 1987, el mercado baso en máquinas LISP se hundió debido a la aparición de competidores mucho más asequibles. Esto dio paso al segundo invierno de la IA. Este segundo parón resultó especialmente significativo, pues puso en evidencia lo vulnerable que resultaba el hardware especializado en IA, dada la rapidez de los avances tecnológicos y el mercado. Una vez más, la financiación en la IA se desplomó.

Resurgimiento de la IA (1993 – 2011)

Pese a la falta de financiación proveniente del segundo invierno, durante la década de los 90 tuvieron lugar varios avances relevantes para el campo de la IA. En 1997, el ordenador *Deep Blue* gana al ajedrez a Kasparov, siendo la primera vez que una máquina gana a un campeón de ajedrez. Ya entrada la década de los 2000, se lanza el primer robot aspirador *Roomba* y su resurgimiento continúa hasta el año 2011, con el lanzamiento de *Siri* de la mano de *Apple*.

Etapa actual de la IA (2012 – presente)

Durante esta etapa la tendencia continua positiva. Se realizan desarrollos de asistentes virtuales y motores de búsqueda, entre otros. Durante este periodo cabe destacar al programa *Eugene*, por ser el primero en pasar el Test de Turing en 2014. Además, destacan también los avances de *OpenAI* usando Deep Learning para generar el primer contenido casi idéntico al que haría un ser humano de los últimos años.

Existen debates en la actualidad sobre si un tercer invierno está por venir o si, por el contrario, la IA continuará creciendo con una tendencia más o menos positiva. Esos son los casos presentados en la figura siguiente (Figura 3.4), que se tratarán en más detalle en el apartado sobre el futuro de la IA (apartado 3.5).

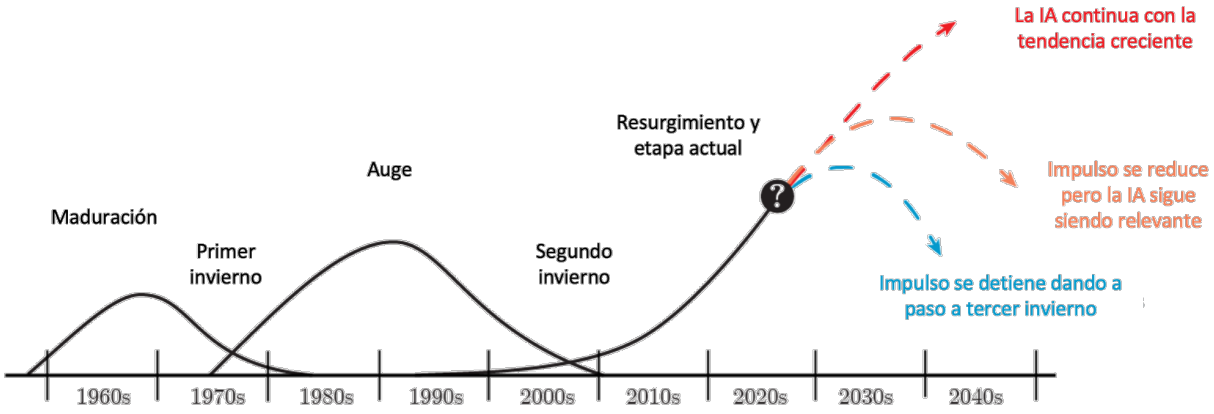


Figura 3.4 Etapas de la IA a lo largo de la historia [9]

3.3. Funcionamiento de la IA

Para comprender el funcionamiento de la IA, es necesario hacer un recorrido por varios aspectos de la misma. En primer lugar, es necesario detallar cuál es su estructura, es decir, cuáles son los elementos que la componen tanto física como de manera lógica. Por otro lado, es necesario detallar los componentes clave que participan en su funcionamiento, como pueden ser el lenguaje o la capacidad de razonar. Por último, una vez conocida la infraestructura y sus componentes, entender qué tipo de IA se pueden encontrar y cuáles son las principales ramas dentro de este campo permitirá mapear las diferencias de funcionamiento entre una y otra.

3.3.1 Infraestructura de la IA

La infraestructura de la IA se puede presentar categorizada en 4 partes, a saber: hardware, software, algoritmos y datos. Esta categorización supone un enfoque integral que permite entender el ecosistema necesario para poder desarrollar y hacer uso de este tipo de tecnología. Comprender cómo estas 4 partes interactúan entre sí sirve como antesala para tener una visión global del funcionamiento de la IA. Someramente, y a alto nivel, este tipo de sistema es alimentado por datos, que les permiten mejorar su funcionamiento. Por otro lado, los algoritmos procesan la información y toman decisiones para dar resultados lo que, a su vez, es ejecutable gracias al hardware y al software que soportan el funcionamiento de los programas. A continuación, se presenta cada una de esas 4 partes de manera más detallada:

- **Hardware**

El hardware hace referencia al medio físico que soporta los procesos de la IA. Para ello, debe tener la suficiente potencia para procesar el volumen de datos que se maneja. El hardware, a su vez, se divide en 3 componentes principales: las unidades de procesamiento como las GPU (Unidades de Procesamiento Gráfico) o las TPU (Unidades de Procesamiento Tensor), la memoria y el almacenamiento y, por último, la infraestructura de redes. Las primeras son las responsables de manejar de manera eficiente las operaciones relacionadas con los modelos de Deep Learning. Por otro lado, la memoria, son las encargadas de albergar los datos y modelos necesarios tanto de manera permanente como en tiempo real para el procesamiento y, para terminar, la infraestructura de redes sirve para transferir información entre los distintos componentes del hardware.

- **Software**

El software hace referencia al soporte no físico que permite desarrollar los programas de IA. Al decir soporte no físico, se hace referencia a todas las herramientas, plataformas, bibliotecas y demás medios virtuales que sirven de interfaz entre el hardware y los algoritmos para poder realizar el procesamiento de datos. A su vez, destacan 3 tipos de software, a saber: los sistemas operativos, los *frameworks* y las plataformas de implementación. De esta forma, los primeros sirven de base para poder ejecutar, los segundos permiten crear y entrenan los modelos a ejecutar y los terceros proporcionan la infraestructura necesaria para la el despliegue de la IA a mayor escala.

- **Algoritmos**

Un algoritmo es un conjunto de operaciones que permiten resolver un problema, de acuerdo a su definición matemática. En el caso de la IA, la definición aplicada sería la siguiente: un algoritmo es un conjunto de operaciones y métodos (matemáticos y estadísticos) que permite a las máquinas tomar decisiones en función a los datos de entrada y el aprendizaje adquirido. Existen distintos tipos de algoritmo dentro de la IA, en función de su finalidad. Entre ellos, caben destacar los algoritmos de aprendizaje automático (Machine Learning) en los que se incluyen las redes neuronales, entre otros; así como los de optimización y preprocesamiento, destinados a las etapas de entrenamiento y limpieza de datos previo uso, respectivamente.

Un parámetro que sirve para medir la funcionalidad de los algoritmos y que es necesario entender de cara al apartado 4 de este trabajo, es la explicabilidad. Pues bien, la explicabilidad es la capacidad de un algoritmo para ser entendido e interpretado, y así comprender de qué manera ha llegado al resultado obtenido.

- **Datos**

Los datos hacen referencia al conjunto de información necesario para poder entrenar un sistema de IA. De esta manera, se puede evaluar su rendimiento y optimizar los resultados para obtener respuestas lo más precisas posibles. Para que estos datos puedan cumplir su función y ser útiles a nivel de depurar el funcionamiento de la herramienta, es necesario que sean grandes volúmenes de datos de gran precisión, que deben limpiarse y estructurarse de acuerdo a su tipología. Para ello, se emplean desde bases de datos, APIs (Interfaz de Programación de Aplicaciones) o sensores, para trabajar tanto con datos almacenados como con otros en tiempo real.

3.3.2 Componentes de la IA

Como se ha comentado en el apartado anterior, el objetivo de la IA es crear sistemas capaces de realizar tareas para las que haría falta inteligencia humana. De esta manera, las máquinas sujetas a IA no solo ejecutarían un listado de órdenes determinado, sino que podrían percibir e interpretar datos, razonarlos y aprender sobre ellos y sobre el lenguaje para poder resolver problemas.

Así, y de acuerdo a la siguiente imagen (Figura 3.5), los cinco componentes clave de la IA, son: aprendizaje, razonamiento, resolución de problemas, percepción y procesamiento del lenguaje. Cada uno de ellos desempeña un papel crucial en la capacidad de la IA para adaptarse, tomar decisiones adecuadas, solucionar problemas complejos, interpretar el entorno y comunicarse eficazmente con los humanos. Comprender la importancia de estos componentes resulta esencial para apreciar el alcance y el potencial de la IA en el mundo moderno, consiguiendo aplicaciones inteligentes y autónomas.

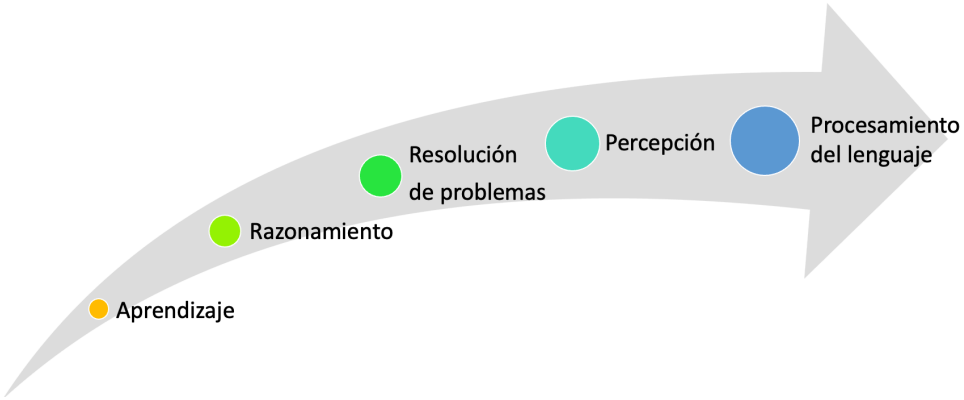


Figura 3.5 Componentes de la IA

3.3.2.1 Aprendizaje

Uno de las características distintivas de la IA es su capacidad para aprender. De la misma manera que los humanos, este tipo de sistemas son capaces de adquirir conocimientos, en este caso implementados computacionalmente. De esta forma, el término "aprendizaje" dentro de la IA hace referencia a la capacidad de los sistemas para adquirir habilidades o conocimientos a través de la experiencias y datos que manejan. Así, logran mejorar su rendimiento sin la necesidad de ser programados por un humano para tal fin.

Existen distintos métodos de aprendizaje aplicados a este campo. En primer lugar, el método de ensayo y error es aquel en el que el sistema ejecuta la resolución de problemas hasta dar con el resultado correcto. Durante dicha ejecución y las sucesivas, el programa registra todas las acciones que dieron resultados positivos, almacenándolos para volver a usarlos en futuras ocasiones. Otro método muy extendido es el memorístico. En él, el sistema retiene datos y elementos de distintas tipologías: matemática, lingüística, lógica, enfoques, etc. A modo de ejemplo, en las aplicaciones de reconocimiento de imagen, la IA aplica los patrones memorizados para identificar objetos dentro de un conjunto de datos. Por otro lado, para el reconocimiento de voz, la IA aplica las reglas gramaticales y sintácticas aprendidas para cada idioma.

Por otro lado, existen varios tipos de aprendizaje. Estos 3 tipos que se detallan a continuación pertenecen a la rama de la IA denominada *Machine Learning*, que se explicará en el apartado 3.3.4:

- Aprendizaje supervisado:

En este tipo de aprendizaje, los algoritmos son alimentados con datos etiquetados. Así, se le alimentará datos de entrada y salida. El dato que se da es el de entrada, para su procesamiento, mientras el de salida es el que la IA debería obtener, que se le provee de partida para su aprendizaje. A modo de ejemplo, en el reconocimiento de imagen, se provee al sistema de imágenes de entrada en el que se le dice lo que es cada una, a modo de salida. El objetivo de este aprendizaje es que, tras introducir miles de imágenes sabrá reconocerlas por sí solo aprendiendo a predecir nuevas salidas a base de tiempo y experiencia.

El aprendizaje supervisado se encarga, a su vez, de dos tipos de problemas:

- Problemas de clasificación:

Como su propio nombre indica, es el tipo de problema en el que la solución consiste en aportar una clasificación de los datos de entrada, es decir, saber etiquetar los datos de entrada de acuerdo al criterio establecido. Para ello, se emplean modelos predictivos que permiten al algoritmo clasificar de acuerdo a valores discretos. A modo de ejemplo, forman parte de esta categoría el clasificador de *Naive Bayes* o las máquinas de soporte vectorial, muy habituales estas últimas en sistemas de control basados en IA para sistemas energéticos, como se verá más adelante.

- Problemas de regresión:

Este tipo de problema, si bien es similar al anterior, trabaja con datos de tipo real, es decir, continuos (no discretos). Así, aunque en este caso también se encuentras datos con valores de salida asociados, los modelos empleados de clasificación son diferentes. A modo de ejemplo, se emplean modelos de regresión ya sea lineal, no lineal o lineal bayesiana.

- Aprendizaje no supervisado:

En este caso, por el contrario, los algoritmos no se alimentan con datos etiquetados. De esta forma, al darle datos sin etiquetar, el programa debe deducir los patrones que necesite únicamente de los datos de entrada, sin que el ser humano le provea los de salida. Por ello y ante la falta de guía, los algoritmos realizan un aprendizaje auto organizado en el que buscan similitudes y asociaciones entre los datos de entrada, así como características ocultas y agrupaciones. De hecho, las técnicas que más se usan en este tipo de aprendizaje son:

- Agrupación

Esta técnica, también conocida como *clustering,* sirve para agrupar datos no etiquetados analizando la similitud de los mismos, dando lugar a grupos disjuntos. Este tipo de agrupación, a su vez, puede clasificarse en 4 grupos: exclusivos, superpuestos, jerárquicos y probabilísticos.

Por una parte, las agrupaciones exclusivas, siendo estas las más restrictivas, son aquellas en las que un punto de datos solo puede estar en un grupo, siendo un punto de datos la entidad más pequeña de información. Uno de los ejemplos más comunes de este tipo de agrupación es la de los grupos k-media (Figura 3.6) o más conocida por su nombre en inglés, *k-means*. Las agrupaciones superpuestas, sin embargo, difieren de las anteriores en que los puntos de datos pueden estar en varios grupos a la vez.

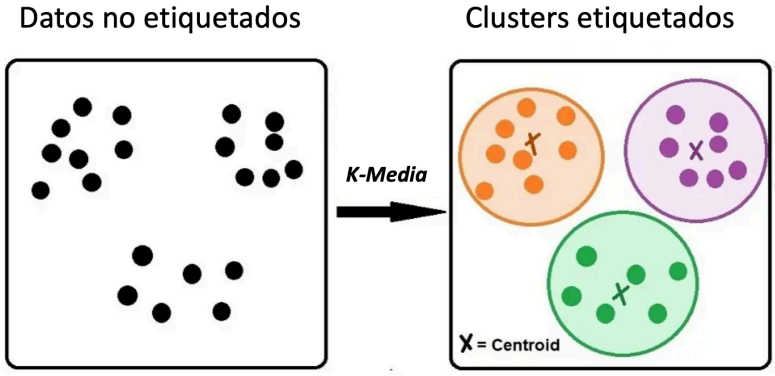


Figura 3.6 Ejemplo de agrupación exclusiva

Por otro lado, la agrupación jerárquica parte de puntos de datos que se incluyen en grupos por separado y que, después, se van uniendo de manera iterativa hasta lograr un grupo. Por último, la agrupación probabilística, agrupa los puntos de datos de acuerdo a distribuciones estadísticas. Un ejemplo de este tipo es el modelo de mezcla gaussiana.

- Asociación

Esta técnica se basa en la búsqueda de reglas que sirvan para detectar relaciones entre variables de muestra, buscando así la concurrencia entre ellas para obtener un método basado en reglas de asociación.

- Reducción de variables

El objetivo de esta técnica es optimizar la precisión de los resultados a través de la mejora del rendimiento de los algoritmos. Para ello, parte de la premisa de que no todas las variables son igualmente válidas en cuanto a la información aportada. Algunas de ellas pueden ser redundantes o estar correlacionadas,

dificultando así la visualización de los conjuntos de datos. De esta manera, a base de ejercicios de selección y extracción de datos, se reduce el número de variables a usar por el algoritmo. Los principales métodos usados en este caso son los análisis de componentes principales, la descomposición en valores singulares o los codificadores automáticos.

- **Aprendizaje por refuerzo**

En el aprendizaje por refuerzo, se usan técnicas de condicionamiento básico, en el que los aciertos se premian y los errores se castigan. En este caso, los algoritmos aprenden a mejorar sus respuestas gracias a un proceso iterativo. Así, en función del tipo de respuesta obtenida (correcta o no), el algoritmo recibe un valor numérico o puntuación definida como negativa. En caso contrario, el valor será el definido como positivo.

3.3.2.2 Razonamiento

Si bien la capacidad de razonar estaba limitada solo a los seres humanos hasta hace varias décadas, ahora la IA hace uso también de esta habilidad. Así, los algoritmos son capaces de hacer inferencias que se ajusten a una situación, para poder hacer deducciones lógicas y tomar decisiones a partir de la información disponible. En este caso, las inferencias usadas por la IA para razonar se pueden categorizar en 3 tipos: deductivas, inductivas o probabilísticas. La lógica deductiva garantiza siempre llegar a una conclusión a base de reglas predefinidas que le permiten llegar hasta ella. La lógica inductiva, por el contrario, se basa en ejemplos y generalizaciones con datos incompletos a partir de los que hipotetiza soluciones. Por último, la lógica probabilística se basa en modelos probabilísticos para tomar decisiones que den resultados coherentes.

3.3.2.3 Resolución de problemas

En este caso, la resolución de problemas está estrechamente relacionada con el punto anterior, pues depende de la capacidad de razonar de los sistemas para poder encontrar soluciones a problemas complejos. Llamando x a la solución a encontrar, los sistemas se valen de distintas técnicas de resolución para encontrarla, pudiendo incluir algoritmos eficientes y análisis de causa raíz para tal fin. Como elementos clave de este componente, existen una serie de pasos seguidos por los sistemas a la hora de llevar a cabo la resolución:

- Definición del problema, especificando el alcance, condiciones de partida, objetivo y estado final deseado, así como otras condiciones de contorno o restricciones que condicionen la resolución.
- Representación del problema, útil para facilitar la resolución. Algunas de las representaciones más comunes son los espacios de estado, los grafos y las reglas de producción.
- Búsqueda de soluciones, que exploran las distintas posibilidades existentes para resolver el problema. Para ello, existen dos técnicas principales con dos enfoques totalmente distintos que dependen del uso o no de información extra que permita guiar las búsquedas de manera eficiente hacia una solución única.

  Por una parte, está la Búsqueda no Informada o Búsqueda Ciega. Esta no emplea información adicional para llegar al objetivo, sino que explora todos los estados posibles por defecto. Para ello, solo emplean la estructura general del problema sin manejar datos que les permitan usar minimizar la distancia o coste que les separa de la solución. Las principales técnicas en este caso son la *Breadth-First Search (*BFS*), Depth-First Search (DFS)* o la Búsqueda de Coste Uniforme.

  La Búsqueda Informada o Búsqueda Heurística, por otro lado, sí hace uso de información adicional para optimizar la resolución del problema, en términos del tiempo o del coste asociado al mismo. Así, emplea una función heurística para minimizar estas variables a partir de un punto de partida

de resolución. En este caso, las técnicas más extendidas son la Búsqueda "A*", la Búsqueda *Greedy Best-First* y la Búsqueda de Haz.

De esta forma, la elección de una búsqueda informada o no dependerá del tipo de problema a resolver y de si se dispone de una función heurística adecuada para poder minimizar el tiempo o el coste asociados de resolverlo.

- Algoritmos de planificación con los que generar las acciones ordenadas que permiten resolver el problema, yendo desde la situación de partida a la deseada.
- Elección de la solución óptima, pues el objetivo de la resolución no es solo encontrar una solución que cumpla con el problema, sino la que lo resuelva de la mejor manera posible. Para ello, se utilizan métodos de optimización como la programación lineal, entera o los algoritmos dinámicos.

3.3.2.4 Percepción

Una de las características más distintivas de la IA es su capacidad de percibir información de su entorno, de la misma manera que lo haría una persona a través de sus sentidos. Para ello, la IA utiliza sus propios órganos sensoriales, pudiendo ser estos reales o artificiales. Gracias a ellos, los sistemas escanean su entorno, recibiendo información principalmente a través de la vista o el oído, y la recopilan y procesan para hacer uso de ella. Durante ese procesamiento, analizan los objetos percibidos en busca de sus principales características y relaciones con otros. A modo de ejemplo, el robot Freddy, desarrollado en la década de los 70 en la Universidad de Edimburgo, fue el primero capaz de usar la percepción para reconocer objetos.

Así, las principales técnicas de percepción son las siguientes:

- Visión por computadora: Sirve para analizar e interpretar datos visuales, incluyendo tareas el reconocimiento de objetos, la segmentación de imágenes y el análisis de vídeo. Para ellos, usa técnicas de Machine Learning y Deep Learning como las redes neuronales convolucionales (CNN) que se tratarán en el siguiente apartado (apartado 3.3.4).

- Reconocimiento de voz: Sirve para convertir el discurso oral en lenguaje de texto a partir de modelos de audio, lengua y pronunciación. En la actualidad es una técnica ampliamente extendida para el uso de asistentes virtuales y sistemas de control por voz.

- Sensores y procesamiento de señales: En este caso, el uso de sensores permite recopilar datos del entorno para procesarlos. Dichos sensores pueden ser micrófonos, cámaras o sensores de proximidad entre otros.

3.3.2.5 Procesamiento del lenguaje

Este componente, el último de los 5 presentados, es el relativo a la capacidad de la IA para interpretar, comprender y generar lenguaje humano de una forma coherente. Para ello, estos sistemas emplean técnicas como la comprensión del lenguaje natural, la traducción automática y la generación de texto, haciendo así posible que interactúen con el lenguaje de manera eficaz. De esta manera, aplicaciones tan comunes como los *chatbots* o asistentes virtuales entienden y responden al lenguaje escrito o hablado.

Si bien se verá en más detalle en el apartado siguiente (3.3.4), al presentar las ramas de la IA, caben destacar en este apartado las dos tipologías más importantes:

- Procesamiento del Lenguaje Natural (PNL): Incluye ejercicios como el análisis sintáctico, el análisis semántico y el análisis pragmático. Para ellos, se emplean modelos como el procesamiento basado en árboles y Redes Neuronales Recurrentes (RNN). A modo de ejemplo, numerosos programas informáticos emplean redes neuronales para buscar erratas y fallos del lenguaje escaneando textos, como en los filtros de *spam* en los que, al detectar ciertas palabras, los correos se categorizan directamente dentro de esa etiqueta.

- Generación Natural del Lenguaje (GNL): En este caso, los sistemas de IA pueden producir texto o habla coherente en lenguaje humano. Este es el caso aplicado a *chatbots*, sistemas de traducción automática y generación de informes.

- Análisis del sentimiento: Este, por el contrario, extrae la opinión, intención o sentimiento transmitido en un texto. Se emplea comúnmente para el análisis de redes sociales y la retroalimentación de clientes.

3.4. Principales ramas de la IA

Existen distintas formas de categorizar los campos y subcampos de la IA. Algunos expertos agrupan por tipología de acuerdo a distintos criterios, otros por los campos de aplicación y algunos por las técnicas empleadas. Dada la diversidad general de opiniones y tras realizar un mapeo de los criterios más extendidos, en el presente trabajo se van a presentar dos formas de categorizar. La primera será lo que comúnmente se denomina "tipos" de IA, que a su vez se desglosará de acuerdo a dos puntos de vista. En segundo lugar, se presentarán las "ramas" de la IA y, dentro de ellas, las técnicas más empleadas de acuerdo a los componentes anteriormente citados.

3.3.3 Tipos de IA

Existen dos formas de categorizar los tipos de IA, bien en función a sus capacidades en cuanto a aprendizaje y aplicación de conocimiento o de acuerdo a su funcionalidad, según el nivel de aplicación de dichas capacidades. Según este criterio, se verán a continuación los tipos en cada caso (Figura 3.7) y una descripción de cada uno.

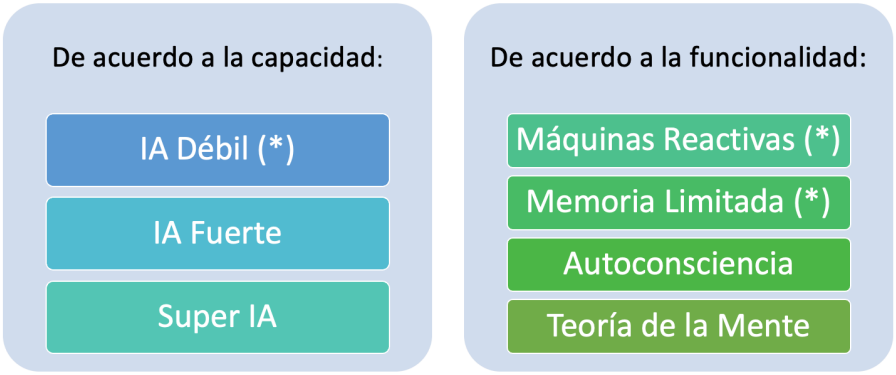


Figura 3.7 Tipos de IA, incluyendo (*) en los de aplicación real

Tipología de IA de acuerdo a la capacidad:

- **IA Estrecha o Débil**

Más comúnmente conocida por su nombre en inglés *Narrow AI/Weak AI,* se emplea en herramientas diseñadas para completar un número de tareas limitado, ejecutar tareas específicas o resolver problemas para los que ha sido programado. Así, es una de las primeras etapas de la IA, estando concebida para llevar a cabo un listado de acciones predeterminado. Además, la falta de habilidades cognitivas le impiden aprender de manera independiente. Este tipo de AI es la usada en asistentes como *Siri* o *Alexa*, vehículos autónomos o la aplicación *ChatGPT* de *OpenAI*. Si bien existen más tipos de IA que se expondrán a continuación, este es el más extendido en la práctica, limitándose el resto de categorías a la teoría en su mayoría. A continuación, se verá que solo otras dos categorías, máquinas reactivas y memoria limitada, se han implementado en la realidad.

- **IA Fuerte**

También conocida como IA General, es un tipo de IA teórica, no llevada a la práctica, en el que los sistemas son capaces de comprender, aprender y aplicar conocimiento de la misma manera que lo haría un ser humano. De esta forma, incluye sistemas con gran capacidad adaptativa que pueden llevar a cabo tareas multifunción y servir de asistentes en la vida cotidiana. De esta forma, no importaría la tipología de problema a resolver, pues se valdrían de aprendizajes previos para aprender a hacer frente a estos sin la necesidad de modificar los códigos de programación iniciales.

Si bien este tipo de IA aún no se ha materializado, continua a día de hoy en investigación para su desarrollo.

- **Super IA**

En este tipo de IA se representa una fase de desarrollo lo suficientemente avanzado como para que los sistemas superen a los humanos en inteligencia, capacidad de adaptación, razonamiento, conocimiento y capacidades. De esta manera, no solo demostrarían un nivel evolutivo superior a nivel cognitivo, sino que gestionarían también emociones, sentimientos y creencias propias. Esta no es solo totalmente teórica, sino que en la comunidad científica aún se trata con cierto escepticismo dada su naturaleza, propia de la ficción.

Tipología de IA de acuerdo a la funcionalidad:

- **Máquinas Reactivas**

Estas máquinas suponen el tipo más básico de sistema de IA, pues solo son capaces de responder a estímulos externos en tiempo real. De esta manera, no pueden almacenar datos en memoria o información para el futuro, estando programadas para un número de funciones limitado. Este tipo de sistemas funciona de acuerdo a datos actuales, ejecutando tareas inmediatas sin la capacidad de utilizar la experiencia para influir en la toma de decisiones. Para ello, emplea métodos de matemáticas estadísticas, pudiendo analizar grandes cantidades de datos para producir una salida que cumpla lo estipulado. Por tanto, se denominan “reactivos” porque, al tomar una decisión, sólo reaccionarán ante situaciones existentes. A modo de ejemplo, una de las máquinas reactivas más conocidas fue la *Deep Blue* de la empresa IBM, ya mencionada en el apartado de marco histórico (apartado 3.2) por vencer a Kasparov en un partido de ajedrez en 1997. Para ello, el sistema analizaba las piezas en el tablero y hacía un análisis de todos los resultados que se podían obtener con cada movimiento, formando así un árbol de decisión con todos los casos posibles. Otro ejemplo, ya más actual, es el motor de búsqueda de plataformas de reproducción como Netflix, en los que se procesa el historial de reproducciones del usuario para hacer sugerencias de nuevos contenidos.

- **Memoria Limitada**

Este tipo de AI, siendo la última de este listado en ser aplicada en el mundo real, sí es capaz de almacenar datos y usarlos a posteriori para influir en su toma de decisiones. Así, emplea modelos de aprendizaje automático para aprender, obtener nueva información y almacenarla. Si bien es cierto que, al contrario que las máquinas reactivas, tiene capacidad de almacenamiento, esta es limitada empleando una memoria transitoria que no permanece a largo plazo. De esta forma, los datos almacenados permanecen durante un periodo de tiempo limitado, pero se borran de la biblioteca al terminar el mismo. En cualquier caso, y en aras de mejorar el funcionamiento de este tipo de sistemas, el entrenamiento con más datos puede mejorar el rendimiento de dichas memorias.

Las máquinas de memoria limitada son, por tanto, capaces de aprender a base de acciones pasados o a través de datos históricos que utilizan para hacer predicciones y construir una base de datos que sirva como criterio para tomar decisiones.

La técnica empleada en los sistemas de memoria limitada es el Deep Learning, que se explicará en el siguiente apartado, dentro de las ramas de la IA. En este caso, los sistemas imitan la función de las neuronas en el cerebro humano, permitiéndoles aprender de su entorno y optimizando las respuestas obtenidas. En

este caso, y por encima de la IA Débil y las máquinas reactivas, los sistemas de memoria limitada son los más usados en las aplicaciones de IA. A modo de ejemplo, los *chatbots* y asistentes virtuales utilizan este tipo de IA para imitar conversaciones. En este caso, el número de interacciones de humanos con la aplicación es directamente proporcional a la calidad de las respuestas obtenidas, pues a mayor cantidad de interacciones mayor es el aprendizaje y los datos almacenados en memoria por estas máquinas. Otro ejemplo de este tipo de IA es el de coches autónomos, que procesan de manera continua los datos de su entorno durante sus trayectos para anticipar giros y movimientos necesarios durante la conducción.

- **Teoría de la Mente**

Este tipo de IA, por otro lado, tiene como objetivo entender los pensamientos, emociones y estados mentales de los seres humanos, e interpretarlos. A su vez, se enmarca dentro de la IA General y, si bien se encuentra aún bajo estudio, su consecución permitiría a las máquinas simular sentimientos y relaciones humanas, modificando el paradigma sobre cómo interactúan estos sistemas con las personas. Además, las máquinas serían también, no solo capaces de citar fuentes, textos, ensayos u obras de arte, sino que podrían entenderlos y contextualizarlos de acuerdo al momento en el que se hicieron y lo que supuso.

Estos sistemas, además de comprender emociones, realizarían las tareas propias de máquinas de memoria limitada. A día de hoy, lo más parecido que se encuentra en la práctica son aplicaciones que emulan capacidades parecidas a las de las personas, como por ejemplo los asistentes de voz. La diferencia en este caso, es que estos asistentes no son capaces de mantener conversaciones de acuerdo a matices, sentimientos, dobles sentidos y, en general, a los estándares de cualquier conversación real. Sin embargo, conseguir que la IA llegue a procesar tal nivel de detalle y matices, que supone un gran riesgo toda la etapa de aprendizaje de estos sistemas hasta perfeccionar la manera de identificar las emociones.

- **Autoconsciencia**

Por último, esta categoría de la IA, a su vez enmarcada en la Super IA, supondría el siguiente escalón a la IA de la Teoría de la Mente, siendo la máxima expresión de desarrollo de la IA. En este caso, las máquinas no solo tendrían la habilidad de reconocer sentimientos y emociones, sino que tendrían conciencia y autoconciencia. Si bien es un campo puramente teórico y casi limitado a la ciencia ficción, su estudio supone un debate ético dentro la comunidad científica, por las implicaciones que tendrían crear sistemas con conciencia de sí mismos, que son capaces de entender y reconocer su propia existencia y estado.

3.3.4 Ramas de la IA

Es habitual, a la hora de pensar en las ramas de la IA, mezclar conceptos como Machine Learning, Deep Learning, Procesamiento del Lenguaje o IA Débil, poniéndolos todos al mismo nivel. Para este ejemplo en concreto, y como ya se ha visto en apartado anteriores, el Procesamiento del Lenguaje es uno de los componentes de la IA, mientras que la IA Débil es uno de los tipos de IA de acuerdo a su capacidad. El Machine Learning, por otro lado, sí es una rama o subcampo de estudio dentro la IA, mientras el Deep Learning es una subcategoría enmarcada dentro del Machine Learning.

El objetivo de este apartado, por tanto, es, habiendo ya presentado la infraestructura, los componentes y los tipos de la IA, abordar ahora las ramas y subcampos de estudio más importantes dentro de esta. De esta manera, las principales ramas de la IA son:

- Machine Learning.
- Lógica Difusa.
- Computación Evolutiva.
- Procesamiento Natural del Lenguaje.

- Robótica.
- Sistemas Expertos.
- Visión por computadora.

Sería posible, para cada una de las ramas, detallar grandes explicaciones de sus avances, campos de estudio y aplicación, sin embargo, no es el objetivo de este trabajo. Si bien, cada rama tiene una importancia variable según el contexto y el campo de aplicación, las ramas relativas a Machine Learning y Procesamiento Natural del Lenguaje tienen un impacto generalizado y gran relevancia a día de hoy. Además, entre estas dos, se hará especial énfasis en Machine Learning y, dentro de ella, Deep Learning y sus principales técnicas; por ser la más relevante dentro del sector energético.

De esta manera, la estructura del siguiente apartado se basará en el esquema de la imagen a continuación (Figura 3.8):

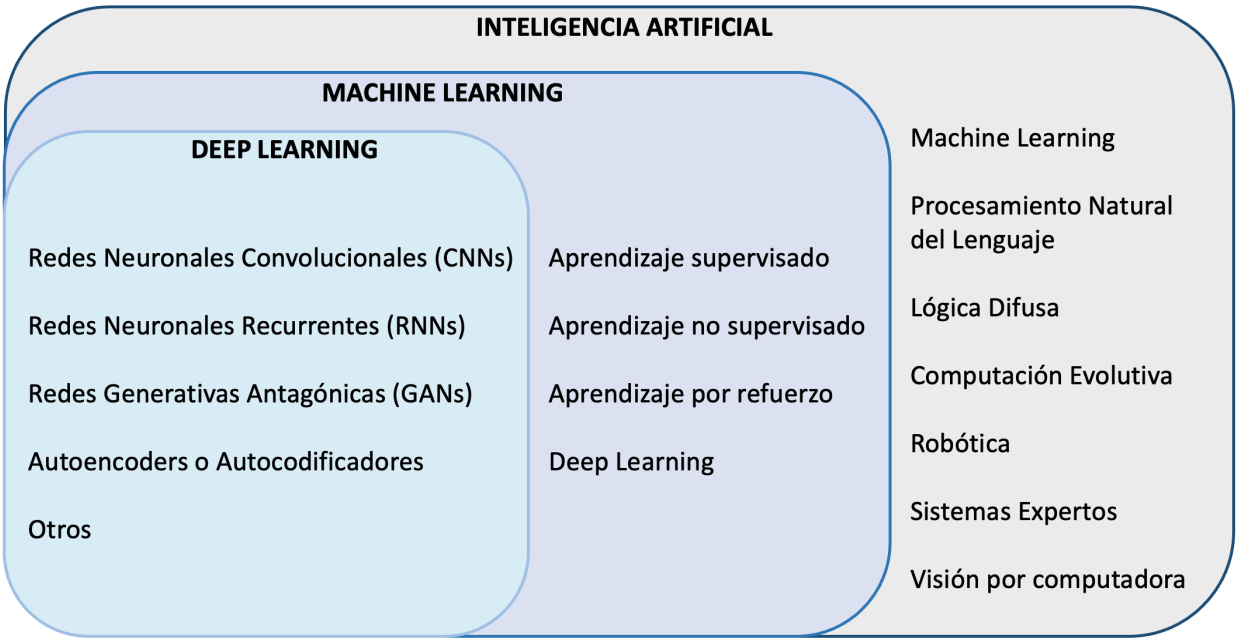
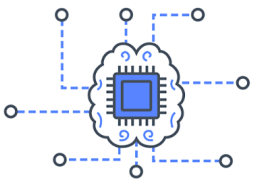


Figura 3.8 Ramas de la IA y principales técnicas

Machine Learning



La rama Machine Learning, o como se denomina en español, Aprendizaje Automático, es de las más importantes, exigentes y reconocidas dentro de la IA. Esta se caracteriza por la capacidad de las máquinas de aprender de manera automática a partir del uso de algoritmos que, a su vez, usan datos para poder funcionar. La principal diferencia entre la IA básica y Machine Learning es que, en la primera, es necesario configurar la máquina para que responda a varios conjuntos de datos, programando manualmente cada toma de decisión. Sin embargo, en el caso de Machine Learning, es posible entrenar a las máquinas para que puedan tomar decisiones a partir del análisis de los datos alimentados sin la necesidad de hacer una programación explícita para tal fin. De esta forma, los algoritmos funcionan como un conjunto de reglas que permiten a las máquinas tomar decisiones tras procesar toda la información, mejorando su adaptabilidad y capacidades para resolver problemas.

Por otro lado, dado que los algoritmos empleados para la toma de decisiones aprenden en base al conjunto de datos alimentados, el rendimiento de las máquinas y la precisión de sus resultados será directamente

proporcional a la cantidad de datos que se les proporcione. Así, a mayor volumen de datos de entrada, los modelos lógicos empleados y los resultados inferidos tendrán una mayor fiabilidad.

Entre las principales técnicas empleadas por Machine Learning son la regresión, la clasificación y el *clustering*. Además, los principales algoritmos empleados en esta rama, son los siguientes: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje por refuerzo y Deep Learning o aprendizaje profundo. Por otro lado, existe también el denominado Aprendizaje Ensamblado, más conocido en inglés como *Ensemble Learning.* Este no es un tipo de aprendizaje en sí mismo sino una técnica de trabajo de Machine Learning por la que se combinan distintos tipos de aprendizaje. Así, en lugar de entrenar un modelo de datos único, se entran varios de manera simultánea y se combinan sus resultados a posteriori, para mejorar su eficiencia y rendimiento en la respuesta. Este tipo de aprendizaje combinado resultará de especial interés en los apartados de uso de IA en energías renovables (apartado 4.1.1). Las principales técnicas del aprendizaje ensamblado que se verán llegado ese punto serán *bagging* y *boosting:*

- *Bagging:* En este caso los modelos se ejecutan de manera independiente (en paralelo). Así, el resultado se obtiene combinando con criterios diferentes (ejemplo: promedio) el resultado de cada uno de los modelos. Un ejemplo de este tipo de técnica en el *Random Forest* (RF), que emplea la técnica de *bagging* con árboles de decisión.

- *Boosting:* En este caso, sin embargo, los modelos no se entrenan en paralelo, sino que lo hacen de manera secuencial, de forma que la salida de uno es la entrada del siguiente. Lo que se persigue, por tanto, es disminuir los errores de cada salida al volver a ejecutar un nuevo modelo. Son ejemplos de esta técnica el *Catboost* o el *XGBoost.*

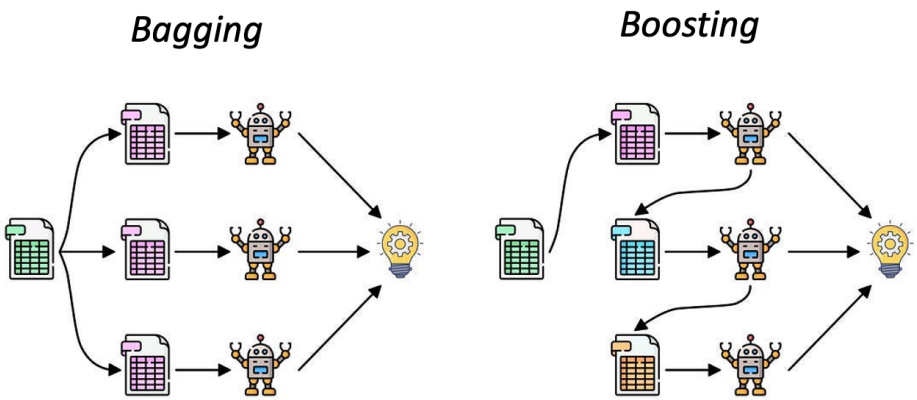


Figura 3.9 Tipos de aprendizaje ensamblado: *bagging* y *boosting* [10]

En cualquier caso, ya se presentaron con anterioridad el aprendizaje supervisado, no supervisado y por refuerzo al hablar del aprendizaje como componente de la IA (apartado 3.3.2.1). Es ahora momento, momento, de detallar el Deep Learning y sus principales características.

- **Deep Learning**

El Aprendizaje Profundo o Deep Learning, es un subcampo dentro del Machine Learning. Este, se caracteriza por la agrupación de algoritmos y "neuronas" (unidades de computación) a modo de redes neuronales que permiten imitar el funcionamiento de cerebro humano. Estas redes artificiales se emplean para trabajar con volúmenes de datos muy extensos y patrones complejos, lo que permite un rendimiento de trabajo superior que el de Machine Learning. De esta manera, los algoritmos de Deep Learning necesitan una cantidad de datos mayor que los de Machine Learning para poder aprender, reduciendo así la

interacción humana necesaria y aumentando el rendimiento. A continuación, se muestra comparativa entre Deep Learning y Machine Learning (Tabla 3.2):

Machine Learning	**Deep Learning**
✓ Rama dentro de la IA.	✓ Campo dentro de Machine Learning.
✓ Menor volumen de datos necesario, con apoyo humano para realizar correcciones.	✓ Mayor volumen de datos necesario para permitir aprendizaje basado en histórico.
✓ Tiempo de aprendizaje menor y menor precisión en los resultados.	✓ Tiempo de aprendizaje mayor y mayor precisión en los resultados.
✓ Correlaciones simples y lineales.	✓ Correlaciones complejas y no lineales.
✓ Unidades Centrales de Procesamiento (CPUS) para aprender.	✓ Emplea Unidades de Procesamiento Gráfico (GPUS) para aprender.

Tabla 3.2 Comparativa entre Machine Learning y Deep Learning

Todas las redes neuronales dentro del Deep Learning se denominan “profundas” por ser multicapa. De esta forma, la información se va procesando en cada una de las capas, de manera que cada salida supone la entrada a la capa siguiente, donde se volverá a procesar la información para optimizar los resultados. Este proceso se va repitiendo a lo largo de todas las capas hasta terminar de recorrer la red.

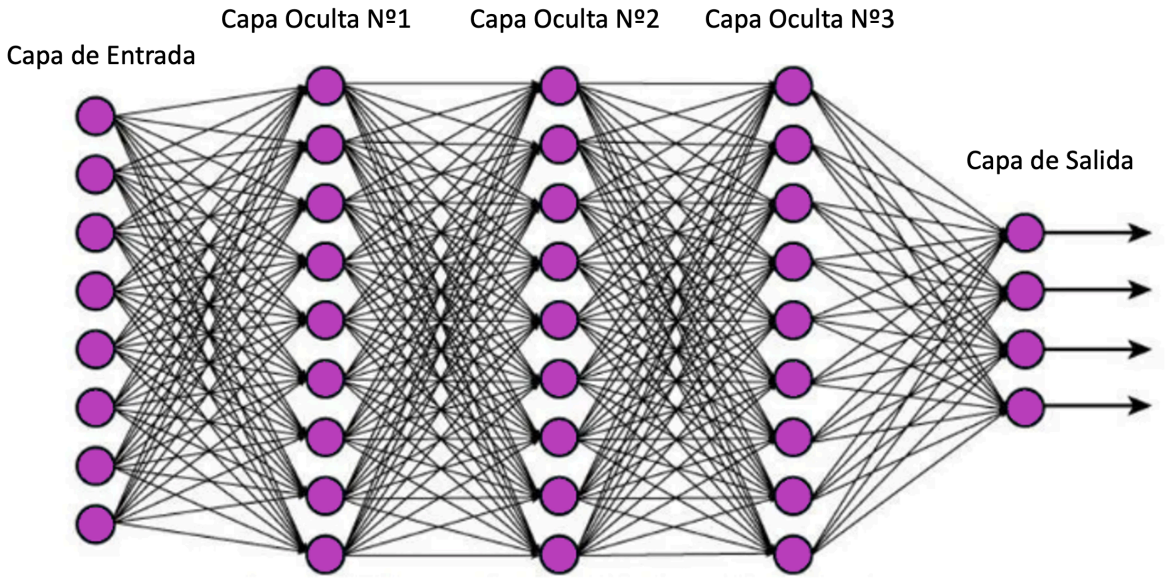


Figura 3.10 Arquitectura de Red Neuronal Profunda con 3 capas ocultas [11]

Por lo general, las capas de una Red Neuronal Profunda (DNN por sus siglas en inglés) se pueden agrupar en 3: capa de entrada, capas intermedias y capa de salida. El avance de la información a través de las capas ocultas, desde la entrada hasta la salida se denomina “propagación hacia delante”. Así mismo, las capas de entrada y salida se denominan “capas visibles”, mientras que las intermedias reciben el nombre de “capas ocultas” (Figura 3.10). Por otro lado, cada una de las neuronas o nodos representados está conectado con todas las neuronas de la capa siguiente, sin embargo, no todas las conexiones tienen el mismo peso. Así, en función del peso de cada una de esas interconexiones, cada nodo tendrá una influencia mayor o menor en el siguiente. Además, a medida que la información va recorriendo la red, capa a capa, esta es capaz de ir aprendiendo más sobre los datos proporcionados, identificándolos y clasificándolos de manera precisa. De

esta manera, el resultado de la capa de salida dependerá de la ponderación existente entre todas las neuronas de la red y de la interpretación o sesgo empleado en la clasificación de la información. Por otro lado, existe un tipo de red, denominadas Redes de Retro propagación (BPNM), que realizan ajustes del algoritmo, propagando los errores de salida hacia atrás en la red, realizando una mejora continua de los resultados obtenidos gracias a dicho proceso de retroalimentación.

Además, existen a su vez varias categorías dentro de Deep Learning, de acuerdo a la tipología de red neuronal profunda que se emplee. A continuación, se explican brevemente las 4 más importantes, mostradas en la Figura 3.8:

1. Redes Neuronales Convolucionales (CNN)

Este tipo de red neuronal está compuesta por un número mínimo de capas que cumplen la siguiente tipología: existe una capa convolucional, una de agrupación y otra totalmente conectada. Si bien puede haber miles de capas, siempre ha de repetirse este patrón. Así, la capa convolucional permite filtrar y clasificar la información de entrada, dando lugar a un mapa de características. La de agrupación (también denominada *pooling*) disminuye la cantidad de datos, reduciendo la dimensión del mapa y los parámetros en él contenido. Por último, la capa totalmente conectada, es la encargada de realizar la clasificación final de la información.

Las redes convolucionales se usan principalmente en aplicaciones de clasificación de imágenes y visión artificial, por lo que la información a filtrar y clasificar en cada una de las capas suelen ser imágenes. Sin embargo, su uso implica un alto número de GPUs por lo que su ejecución requiere un alto número de recursos en tiempo y coste.

2. Redes Neuronales Recurrentes (RNN)

Estas redes se usan para procesar datos secuenciales, empleando también técnicas de aprendizaje supervisado. Así, están diseñadas para trabajar empleando su memoria, pues la entrada y salida de cada una se ve influida por la información de entrada de las capas previas, provocando así una dependencia entre la salida y la secuencia de información en la red. Sin embargo, este tipo de entrenamiento en secuencia puede resultar complejo y difícil de usar, no siendo apto para grandes volúmenes de datos. Los ejemplos más importantes de este tipo de redes, y que se verán aplicados a sistemas de control de energía, son las Unidades Recurrentes Cerradas (GRU, por sus siglas en inglés) que incluyen un criterio de memoria selectiva o las Redes de Memoria de Corto-Largo Plazo (LTSM), que permiten almacenar en memoria los datos más relevantes a la largo plazo, dejando a un lado los de menor importancia.

3. Redes Generativas Antagónicas (GAN)

Al contrario que los dos tipos de redes anteriores, la red generativa antagónica usa técnicas de aprendizaje no supervisado. Su arquitectura resulta peculiar, pues emplea no una, sino dos redes enfrentadas entre sí (de ahí su nombre). El objetivo de este tipo de redes es crear nuevos contenidos de manera que, las dos redes entre sí inician un proceso iterativo de comparación para poder optimizar el resultado final. De esta forma, la primera red se denomina “generador” y es la encargada de crear el contenido de partida. Por otro lado, la segunda red o “discriminador” es la encargada de comparar el resultado del generador con el esperado en realidad, e ir optimizando este hasta llegar al resultado final.

4. Autoencoders o Autocodificadores

Los autocodificadores emplean técnicas de aprendizaje no supervisado y sirven para realizar análisis, reducción y compresión de datos. En este caso, la red neuronal está formada por dos componentes básicos: un codificador y un descodificador, que trabajan de manera secuencial. En primer lugar, el codificador, procesa la información, la reduce y la comprime, codificada. A continuación, el decodificar, interpreta la información codificada y la vuelve a descomprimir a modo de salida.

Procesamiento del Lenguaje Natural

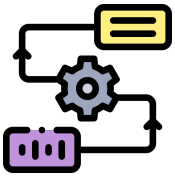


Figura 3.11 Icono PNL

Como ya se vio en el apartado 3.3.2.5, el procesamiento del lenguaje es el quinto componente de la IA. Dentro de este, la tipología más destacada y a la vez, una de las ramas más importantes de este tipo de tecnología, es el Procesamiento Natural del Lenguaje (PNL). Este, permite a las máquinas entender, interpretar y generar palabras, tanto habladas como a través de texto escrito, al igual que lo hacen los humanos a partir de la lingüística computacional y modelos estadísticos. Habitualmente se emplea en traducciones, reconocimiento de voz, procesamiento y generación de textos y evaluación de estos.

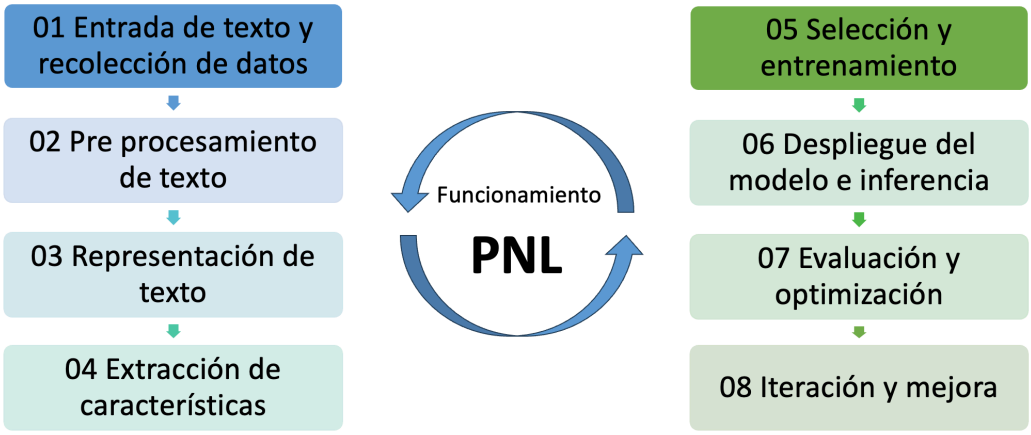


Figura 3.12 Áreas del PNL

Si bien son numerosas las técnicas empleadas dentro del PNL, su funcionamiento se puede agrupar en 8 pasos (Figura 3.12), llevados a cabo de manera secuencial, a saber:

1. Entrada de texto y recolección de datos: En este primer paso, se llena a cabo la recolección de datos de distintas fuentes y el almacenamiento de la información recopilada. Resulta fundamental, en este caso, que el almacenamiento se realice de manera estructurada.

2. Pre procesamiento de texto: Sirve para depurar la información (eliminar ruido) y preparar los datos depurados para su posterior procesado. En este paso destacan técnicas como la división y normalización de texto, eliminación de puntuación y palabras vacías o el *stemming*, que es la eliminación de prefijos y sufijos de las palabras dejando solo la forma raíz.

3. Representación del texto: En este paso, se representa el texto y se emplean técnicas estadísticas que permiten analizar el mismo de acuerdo a la importancia de las palabras, su frecuencia de repetición, así como representaciones vectoriales de acuerdo a la semántica de las palabras empleadas (*embedding* de palabras).

4. Extracción de características: Permite destacar cualquier característica reseñable del texto, para lo que se usan criterios sintácticos o semánticos, entre otros.

5. Selección y entrenamiento de modelos: En este paso, se elige un modelo dentro de los existentes en Machine Learning para llevar a cabo las tareas del PNL, como puede ser el aprendizaje supervisado o el no supervisado.

6. Despliegue e inferencia del modelo: Una vez desplegado, es posible hacer uso de este para realizar predicciones y extraer la información necesaria.

7. Evaluación y optimización: En este punto, se evalúa el algoritmo empleado para optimizar su rendimiento, para lo que se emplean técnicas de ajuste de parámetros y análisis de errores, para disminuir el número de errores y las desviaciones.

8. Iteración y mejora: En el último paso, se añaden nuevos datos y se prueban nuevos modelos que permiten mejorar el algoritmo y su respuesta.

Lógica Difusa



Figura 3.13 Icono Lógica Difusa

La Lógica Difusa, también conocida como *Fuzzy Logic*, parte de la idea de que el mundo no es siempre blanco o negro, 0 o 1, que no siempre es binario. De esta manera, este tipo de IA admite la existencia de verdades parciales, donde los datos que se manejan no tienen por qué ser estrictamente verdaderos o falsos. Así, la Lógica Difusa imita la forma de tomar decisiones de los seres humanos en la medida en la que considera todas las posibilidades entre el 0 y el 1, todos los "grises". Por ende, una de las principales ventajas de este tipo de IA es la flexibilidad que proporciona al considerar que las hipótesis puedan ser parcialmente correctas.

Para que los sistemas que emplean este tipo de lógica puedan funcionar, se basan en una arquitectura dividida en 4 partes, a saber:

- Base de reglas: Incluye el conjunto de reglas y condiciones a usar por el sistema. Este tipo de condiciones son del tipo "*if-then"* (si sucede *x,* entonces sucede *y*) y permiten tomar decisiones en base a una cascada de condiciones.

- Fuzzificación: Consiste en el proceso de transformar los datos de entrada, exactos y nítidos de partida, en conjuntos difusos.

- Motor de inferencia: Es el encargado de decidir qué reglas difusas se activan y cuáles no. Para ello, compara dichas reglas con las entradas difusas. Una vez activadas las reglas pertinentes, se combinan para llevar a cabo acciones.

- Defuzzificación: Esta última parte, deshace la transformación llevada a cabo en el proceso de fuzzificación. Para ello, transforma los datos difusos en valores exactos de nuevo. Así, los datos de salida son precisos y nítidos.

Este tipo de lógica se emplea en un gran número de aplicaciones, como en sistemas de control, PNL y procesamiento de imágenes. Un ejemplo de este tipo de sistemas es el empleado en el sector de la automoción, en el que la lógica difusa se emplea para controlar el sistema de frenado en situaciones de peligro, introduciendo para ello variables como la velocidad del vehículo, la aceleración y el funcionamiento de las ruedas.

Computación Evolutiva

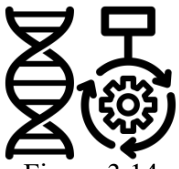


Figura 3.14 Icono Comp. Evolutiva

La computación evolutiva, también conocida como IA evolutiva, emplea un conjunto de algoritmos de IA basados en la evolución natural y la genética para la resolución de problemas complejos. Así, este tipo de sistemas emplea técnicas computacionales para resolver problemas de optimización a base de procesos iterativos de prueba y error. De esta forma, este tipo de computación brinda un enfoque versátil y flexible con el que se pueden generar soluciones nuevas de manera automática, que suelen ser demasiado complejas para el cerebro humano.

Si bien existen diversas técnicas dentro de la computación evolutiva, las dos principales son: algoritmos de optimización por enjambre de partículas y la programación genética.

Los algoritmos de optimización por enjambre, en primer lugar, trata cada una de las posibles soluciones como una partícula. Cada movimiento de las partículas es una iteración en la que estas, se mueven hacia la solución más óptima. Al movimiento de esas partículas se produce en grupo, lo que las hace asemejarse al movimiento de un enjambre, de ahí su nombre.

La programación genética, por otro lado, se denomina así por buscar "descendientes" que sirvan para reproducirse, en cada iteración. De esta manera, existe un grupo inicial con posibles soluciones que se denomina "población inicial". Este grupo, con cada iteración, se va depurando, eliminando las soluciones que se alejan del óptimo y se sustituyen con otras en su lugar creadas a partir de la combinación de soluciones ya existentes. Así, las iteraciones se van repitiendo y se va generando el grupo de descendientes hasta dar con la solución final.

Las técnicas de computación evolutiva, se caracterizan por llevarse a cabo con un tiempo de procesamiento bajo, haciéndolas atractivas frente a otras ramas de la IA, como las redes neuronales. De esta manera, a modo de ejemplo, en el caso de la programación genética los sistemas son capaces de procesar grandes volúmenes de datos de manera rápida y, en el momento en el que los descendientes de una iteración ya no puedan continuar con la optimización, el proceso para de manera automática con la solución final ya encontrada. Otra ventaja de los procesos evolutivos dentro de la IA es que sirven como punto de partida para poder mejorar otros métodos, como algunos de Machine Learning.

Robótica



Figura 3.15
Icono Robótica

Para entender la robótica como una de las ramas dentro de la IA, es necesario saber primero qué es un robot y qué relación existe entre estos y la IA. Un robot es una máquina programable capaz de realizar una serie de tareas complejas. La robótica, por otro lado, es la ciencia encargada de desarrollar robots y aúna conocimientos de ingeniería mecánica, electrónica e informática para llevarlo a cabo. A su vez, la robótica es una rama de la IA, pues los robots se crean con el objetivo de que gocen de autonomía y entidad, capaces de hacer tareas que normalmente harían los humanos.

De esta manera, el uso de IA en la robótica ha supuesto un cambio en el paradigma de trabajo de los robots, modificando la forma de trabajar de estos. El uso de la IA en robots permite optimizar su funcionamiento y la complejidad de las tareas que estos pueden llevar a cabo. Así, combinando a estos con técnicas de otras ramas de la IA, como Machine Learning o el PNL, es posible crear robots que aprendan por sí solo, mejorando a partir de la experiencia y el volumen de información procesada. De esta forma, mejoran su adaptabilidad a nuevas situaciones, captar y procesar información de su entorno a través de sensores, tomar decisiones en consecuencia e incrementan su rendimiento con el paso del tiempo y la cantidad de información adquirida.

La robótica, por tanto, ha supuesto un antes y un después en el sector industrial, pues su incorporación en el sector ha permitido:

- Mejorar el confort de los humanos, dándoles comodidades y evitando que realicen tareas repetitivas y tediosas en muchas ocasiones.
- Aumentar la productividad industrial, disminuyendo el tiempo empleado para llevar a cabo una tarea, y mejorando la producción tanto desde el punto de vista cuantitativo como cualitativo.
- Aumentar la eficiencia de los procesos y, por tanto, disminuir los costes.

La combinación de la robótica y la IA supone uno de los principales avances tecnológicos del sector, empleándose a día de hoy en un gran número de aplicaciones, como vehículos autónomos, drones, y automatización industrial. La sinergia entre estos campos continua, resultando en sistemas robóticos cada vez más avanzados, eficientes y capaces.

Sistemas Expertos



Figura 3.16 Icono Sistemas Expertos

Un sistema experto es un programa informático que utiliza IA para resolver problemas específicos para los que haría falta el conocimiento de una persona experta. Pretenden, así, imitar el juicio y el comportamiento que tendría una persona experta en un campo específico. Así, este tipo de sistemas se utilizan principalmente para la resolución de problemas complejos y muy específicos.

Este tipo de sistemas se caracterizan por tener un alto rendimiento, pudiendo resolver problemas de manera precisa y eficiente. Por otro lado, proporcionan respuestas comprensibles por el usuario de manera muy rápida. Para entender cómo funcionan, resulta fundamental presentar su arquitectura.

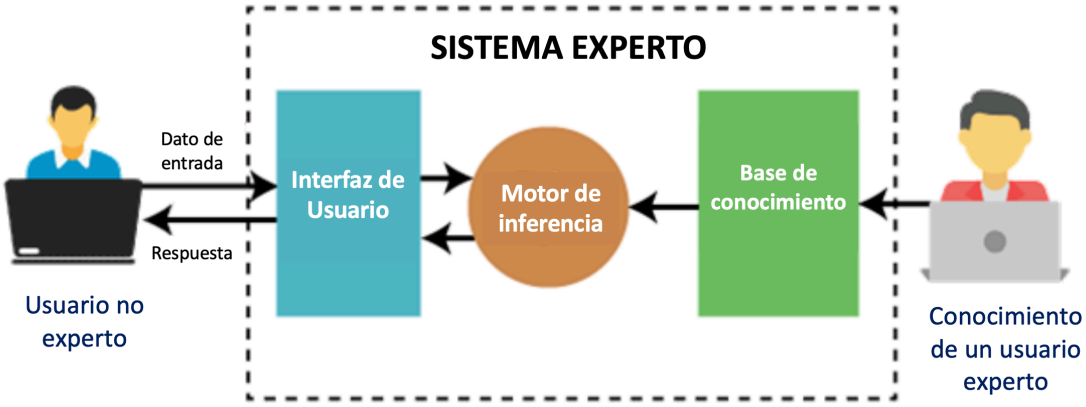


Figura 3.17 Arquitectura de Sistemas Expertos [12]

Para funcionar, los sistemas expertos basan su arquitectura en tres partes: la interfaz de usuario, el motor de inferencia y la base de conocimiento (Figura 3.17):

1. Interfaz de usuario: Hace posible la interacción entre el sistema experto y el usuario. Tiene un funcionamiento bidireccional, sirviendo como medio para que el usuario le de los datos de entrada al sistema y, también para devolver la respuesta al usuario. Además, conecta con el motor de inferencia para proveerle de la información de entrada para su procesado.

2. Motor de inferencia: Una vez recibidos los datos de entrada facilitados por el usuario, el motor de inferencia emplea algoritmos para generar una respuesta a partir de la información almacenada en la base de conocimiento. Existen, en este punto, dos tipos de motores de inferencia: los motores deductivos, que van hacia adelante y deducen el efecto a partir de la causa, y los inductivos que van hacia atrás, deduciendo el efecto a partir de la causa.

3. Base de conocimiento: La base de conocimientos almacena todo el conocimiento provisto por el ser humano experto, de manera estructurada, para que pueda ser utilizado por el sistema. De esta manera, a la hora de hacer una consulta, la información se extrae de la base usando reglas de inferencia. De esta manera, la eficiencia de este tipo de sistemas depende la cantidad de información contenida en la base de datos, pues a mayor información almacenada, mayor será el rendimiento del mismo.

Los sistemas expertos son clave para la detección de posibles futuros problemas, siendo muy extendido su uso en tareas de mantenimiento predictivo y calidad. Además, gracias a su rápido diagnóstico de fallo y su capacidad para proponer soluciones, sirven para mejorar la eficiencia y reducir los costes en la industria.

Visión por Computadora

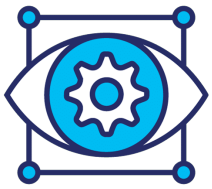


Figura 3.18
Icono Visión por Computadora

La visión por computadora es una rama de la IA que tiene como objetivo desarrollar técnicas que ayuden a las computadoras a ver, observar y entender. A modo de analogía, de la misma forma que la IA permite a las máquinas pensar y aprender por sí mismas, la visión por computadora les permite procesar imágenes y otras entradas visuales para extraer información de ellas. Gracias a esta técnica, los sistemas pueden aprender por sí solos gracias a los datos procesados, pudiendo distinguir unas imágenes de otras, para lo que necesitan ser alimentadas con una gran cantidad de datos. Esta rama emplea mayormente dos tipos de tecnologías: Machine Learning, y dentro de este, redes CNN.

Gracias a las técnicas de Machine Learning, las máquinas aprenden a identificar imágenes gracias a los modelos algoritmos presentados en apartados anteriores. Así, aprenden sobre el contexto de los datos y aprenden a distinguir una imagen de otra sin necesidad de que un ser humano las programe específicamente en cada caso. Las CNN, por otro lado, descompone las imágenes y emplea etiquetas para realizar convoluciones y poder hacer predicciones sobre las imágenes que ve.

3.5. Riesgos y futuro de IA

Si bien se ha visto, a lo largo de toda esta sección, la importancia de la IA en distintos sectores y aplicaciones y cómo esta ha avanzado a lo largo de las últimas décadas, resulta inevitable plantear también los posibles riesgos asociados a esta. Así, las principales preocupaciones y riesgos de la IA son los siguientes:

- Sesgos y tratamiento de los algoritmos, pudiendo tomar decisiones incorrectas en caso de que los algoritmos empleados estén sesgados. Esto podría desembocar en resultados injustos o discriminatorios en función de la situación.
- Problemas de privacidad y seguridad, debido al gran volumen de datos que necesitan recopilar los sistemas de IA para poder aprender. Esto podría dar lugar a brechas en la ciberseguridad y problemas con los datos de carácter personal o de empresas, en caso de un mal uso del mismo.
- Impacto en la empleabilidad, al reducir el número de puestos de trabajo que venían ocupando seres humanos que han sido sustituidos por máquinas y robots que emplean sistemas de IA.
- Problemas éticos, en relación a la decisión tomada por los algoritmos en situaciones que impliquen cierto juicio moral, temas de seguridad o justicia. Además, en este caso, habría que analizar a qué parte se atribuye la responsabilidad civil o penal, en caso de una decisión incorrecta o contraproducente.
- Implicaciones de control a largo plazo, pues en caso de que se desarrolle la Super IA, los sistemas tendrían una capacidad de razonamiento superior a la de los seres humanos, no siendo posible gestionar su control.

Por todos estos riesgos, la Unión Europea (UE) propuso ya la confección de la primera legislación sobre IA, dentro de su paquete de medidas en materia digital. De esta forma, la Comisión Europea lanzó en abril de 2021 el primer marco regulador sobre IA, con una clasificación de los sistemas en función de su nivel de riesgo y el peligro que supongan para los usuarios y unas regulaciones de acuerdo a dicha clasificación.

En este caso, el Parlamento Europeo ha marcado como prioridad a la hora de confeccionar la nueva ley, asegurar que los sistemas de IA sean transparentes, sin discriminación y respetuosos con el medio ambiente. Además, deberán ser seguros y transparentes, para lo que deberán ser controlados por personas que verifiquen su funcionamiento, en lugar de por sistemas automatizados.

Así, la Ley de Inteligencia Artificial fue aprobada por el Parlamento en marzo de 2024 y aprobada por el Consejo en mayo de ese mismo año. Se desplegará en los 24 meses posteriores a esa fecha, de manera gradual, empezando con normativas en relación a la prohibición de sistemas de riesgo inaceptable que comenzarán a aplicar en noviembre de 2024 [13].

Por otro lado, si bien es evidente que se continúan dando pasos en aras de desarrollar y regular los sistemas de IA, ya se vio en el apartado 2 los periodos de bajo avance ("inviernos") por los que ha pasado la IA a lo largo de las últimas décadas. Existen distintas teorías sobre el futuro de la IA y si otro inverno está o no por venir (Figura 3.4). Son distintos motivos los que hacen pensar que un tercer invierno tendrá lugar: los riesgos ya comentados debido al sesgo, los problemas en relación a la ética y el empleo y la falta de regulación. Además, las expectativas infladas sobre la capacidad de la IA, también llevan a muchos expertos a pensar en el excesivo optimismo sobre el avance de esta tecnología y la posibilidad de un nuevo estancamiento en su desarrollo. Por último, todos estos problemas, unidos a los desafíos técnicos que supone hacer una implementación segura de este tipo de tecnología, podrían llevar de nuevo a una reducción de la inversión para su desarrollo.

En cualquier caso, si bien un tercer invierno parece inevitable, son diversas las medidas que se pueden adoptar y, de hecho, se han puesto ya en marcha, para mitigar el efecto de este: la adopción de regulaciones y normativas como la presentada por el Parlamento Europeo en 2024, la supervisión humana de las tecnologías que dicta dicha ley, la colaboración interdisciplinaria entre esta tecnología y otras áreas de la ciencia e industria, así como la educación de los trabajadores para adaptar su trabajo para colaborar con la IA en lugar de sustituir los puestos de trabajo. De esta forma, la conjunción de medidas en el campo de la investigación, la regulación y la industria resulta clave para garantizar un futuro positivo en el campo de la IA, evitando así una caída en el interés y financiación y asegurando su desarrollo sostenible.

4 SISTEMAS DE CONTROL BASADOS EN IA PARA SISTEMAS ENERGÉTICOS

"La tecnología moderna se ha convertido en un fenómeno total para la civilización donde existe un nuevo orden social en el que la eficiencia ya no es una opción, sino una necesidad impuesta a toda actividad humana" – Jacques Ellul

A lo largo del apartado anterior se ha visto cómo la IA permite a las máquinas razonar, aprender de su entorno y resolver problemas complejos, asemejando su comportamiento al de los seres humanos. De esta manera, la IA supone una herramienta fundamental dentro de esta cuarta revolución tecnológica y un elemento clave dentro de la transición energética. El uso de esta tecnología es clave para lograr una transformación digital y sostenible, necesaria a día de hoy. Su implantación implica la disminución de costes y recursos, aumentando por tanto el rendimiento y eficiencia del sistema por lo que la convierte en una herramienta deseada para todos aquellos que persiguen aumentar la innovación y la productividad de su actividad con bajo impacto en sostenibilidad.

De esta manera, son ya numerosos los sectores que emplean este tipo de sistemas, que sigue avanzando y ampliándose aumentado el número de aplicaciones que la utilizan. Caben destacar así, algunos de sus principales usos:

- Sector sanitario: Actualmente la IA se emplea en distintos aspectos dentro de los campos relacionados con la salud. Uno de los ejemplos más extendidos es el uso de aplicaciones que hace un primer diagnóstico al paciente a partir de datos biométricos o tras conversar con él a través de un *chatbot*. Otro uso, también común, es en el diagnóstico por imagen, permitiendo aumentar la previsión y la rapidez a la hora de emitir un diagnóstico.

- Sector financiero: Se emplea de manera extendida en el sector bancario, permitiendo mejorar la eficiencia, la seguridad y los procesos internos, así como evitar posibles fraudes. Además, en términos de inversión, la IA permite predecir los riesgos y oportunidades, empleándose a día de hoy por muchos particulares a través de aplicaciones a modo de guía.

- Sector educativo: En el sector educativo está ya extendido el uso de la IA para distintas aplicaciones, como tutorías virtuales, asistentes a la enseñanza, sistemas de aprendizaje adaptados al estudiantes o métodos de detección de plagio.

- Sector agrícola: Permite detectar posibles riesgos en los cultivos, como enfermedades, plagas o impactos ambientales. De esta forma, a base de medidas preventivas, optimiza los recursos y la productividad.
- Sector logístico y de transporte: Es una práctica habitual en este sector optimizar las rutas de transporte, así como el uso de recursos que se hace para poder llevarlas a cabo. La IA lleva a cabo este tipo de estudios, teniendo en cuenta un mayor número de variables.
- Sector comercial: La IA realiza predicciones de ventas y de productos de mayor demanda, además de hacer recomendaciones personalizadas en función del consumidor. Además, emplea asistentes virtuales como asesores a la hora de realizar las compras.
- Sector automoción: En este caso, el uso de la IA destaca en el mercado de los vehículos de conducción autónoma y de asistencia a la conducción, mejorando así la seguridad durante los trayectos.
- Sector energético: En este sector, la IA tiene un gran impacto en la eficiencia y la fiabilidad de los sistemas, mejorando ambas. Además, se usa en tareas de mantenimiento y en sistemas de control que aplican a distintas tecnologías.

De entre todas esas áreas, este trabajo va a centrarse en el mencionado en último lugar, el sector energético. Dentro de este sector, la IA tiene presencia en distintas aplicaciones, siendo en general la rama de Machine Learning y, dentro de esta, las técnicas de Deep Learning, las más extendidas. Algunos ejemplos de sus usos son:

1. Mantenimiento predictivo: El uso de la IA en este tipo de mantenimiento resulta clave para el monitoreo en tiempo real y la predicción de fallos. Así, se emplean sensores para captar información de entrada que, mediante el uso de algoritmos de Machine Learning, se procesan junto a datos históricos para poder predecir futuros fallos. Este tipo de predicciones se realizan en tiempo real, lo que reduce tanto los costes de mantenimiento como los tiempos de máquina parada. Además, alarga la vida útil de los sistemas y su seguridad [14].
2. Optimización de la generación y distribución de la energía: En este caso, el uso de los algoritmos de Machine Learning tienen dos finalidades fundamentalmente: hacer pronósticos sobre la demanda y gestionar los recursos. De esta manera, permiten predecir la demanda que tendrán los sistemas y gestionar tanto la generación como el almacenamiento de la energía prevista. Esto, permite reducir el desperdicio y mejorar tanto la eficiencia como el consumo de recursos, reduciendo a su vez los costes[15].
3. Optimización del consumo y eficiencia energética: En lo relativo a la optimización del consumo energético, las técnicas de Machine Learning buscan hacer una correcta gestión de la demanda a la que ajustarse [16]. Así, estos algoritmos permiten optimizar los parámetros de operación de los sistemas, buscando patrones de consumo para poder ajustarlo durante las horas de más consumo. Así consiguen aumentar la eficiencia a la par que reducir los costes.
4. Control de sistemas de climatización: En el caso de edificios, se hace un ajuste también del consumo de acuerdo a la demanda gracias al uso de estos algoritmos, optimizando los sistemas de calefacción, ventilación y aire acondicionado. En este caso, el objetivo es encontrar el punto óptimo entre la reducción del consumo energético sin afectar el confort o la productividad [17].
5. Gestión de redes Smart Grid (redes inteligentes): Se realizan predicciones de la demanda para poder realizar ajustes en tiempo real que permiten estabilidad de la red. Para ello, se busca disminuir el

tiempo de respuesta ante cambios en las curvas de oferta y demanda, que permitan maximizar la eficiencia y asegurar la fiabilidad y la estabilidad del sistema [18].

6. Energías renovables (ER): El uso de la IA permite, en el caso de las energías renovables, hacer una mejor integración de estas en los sistemas [19], teniendo en cuenta su variabilidad dada su intermitencia para garantizar un suministro constante. Además, ayudan a elegir la localización para hacer nuevos proyectos, como de solar o eólica, de acuerdo a datos geográficos, climáticos y meteorológicos, para así encontrar emplazamientos que consigan dar lugar a generaciones de energía óptimas. Por otro lado, los algoritmos de Machine Learning, permiten mejorar la eficiencia de producción, al calcular los parámetros de funcionamiento más adecuados de los sistemas, como la posición de las placas solares o de las turbinas en los sistemas eólicos, a tiempo real [20].

7. Almacenamiento de energía: En el caso del almacenamiento, los algoritmos de Machine Learning persiguen optimizar los ciclos de carga y descarga, para aumentar la vida útil de las baterías y su eficiencia a lo largo de su vida útil. Además, y en relación a las energías renovables, calcula la generación energética de estas para poder estimar el almacenamiento necesario [21].

8. Emisiones de CO_2: Como se vio en el apartado 2 de este trabajo, resulta crucial disminuir las emisiones de CO_2, siendo uno de los motores de la transición energética. Por ello, resulta fundamental que la IA sirva de apoyo para conseguir este objetivo. Así, los algoritmos de Machine Learning permiten seleccionar qué fuentes de energía son las más adecuadas en cada caso, para reducir las emisiones, teniendo en cuenta los datos de consumo, demanda, coste y disponibilidad de recursos. Por otro lado, pueden predecir el impacto ambiental de cada sistema energético elegido, a través de simulaciones, para justificar la decisión tomada en cada caso [22].

9. Vehículos eléctricos: Por último, y para los vehículos eléctricos, la IA permite optimizar los tiempos de carga y la velocidad a la que esta se produce (carga inteligente). Además, permite optimizar la autonomía de los vehículos calculando las rutas en tiempo real y minimizando el consumo de energía a lo largo del trayecto. Por otro lado, analiza el estado de las baterías para prolongar su durabilidad y reducir los costes. En el caso de las baterías, la IA gestiona hace un uso también de estos vehículos a modo de unidades de almacenamiento de energía portátiles, empleando sus algoritmos para que puedan descargar a la red si fuera preciso [23].

Este nuevo punto refleja cómo la IA no solo mejora la operación de los sistemas energéticos, sino que también juega un papel crucial en la gestión eficiente y sostenible de la movilidad eléctrica.

En resumen, la IA ha transformado completamente el paradigma de control de los sistemas energéticos, cambiando la forma en la que estos se operan y gestionan. El objetivo de estas técnicas de control no es solo optimizar las redes y los recursos, sino que buscan también un panorama energético más sostenible y respetuoso con el medio ambiente, de acuerdo a las necesidades globales por un futuro más limpio y con menos emisiones. Para ello, las técnicas de Machine Learning resultan cruciales para abordar todos estos puntos, y conseguir un sector energético basado en la innovación, la adaptabilidad y la optimización, tanto a nivel de generación de energías como de distribución y consumo de estas.

Los objetivos, por tanto, del uso de la IA dentro de sistemas de control se pueden sintetizar en la reducción de costes, optimización de la integración de energías renovables y minimización del impacto medio ambiental para una mejor gestión de los recursos energéticos. De esta manera, y a medida que se vayan produciendo avances dentro del campo de la IA, esta tendrá un papel más relevante para conseguir este cambio y conseguir un panorama energético de acuerdo a las necesidades de la población. En los siguientes apartados se expondrán usos y ejemplos de uso de la IA para controlar sistemas energéticos y como este, ha impactado positivamente en todos estos parámetros (económicos, ambientales, sociales y tecnológicos).

4.1. La IA y las energías renovables

Como se ha visto en apartados anteriores, las ER están experimentando un auge debido a motivos ambientales, sociales, políticos y económicos. Sin embargo, este crecimiento se ve a su vez condicionado por los riesgos y particularidades de este tipo de fuente energética. De cara a reducir este tipo de riesgos, existen varias estrategias que se están implementando en paralelo, siendo una de ellas el uso de la IA. De esta manera, los problemas asociados a las ER se abordaban antes desde puntos de vistas más conservadores y con tecnologías más limitadas, que solo permitían recopilar datos y monitorear funcionamiento sin poder actuar sobre él de manera autónoma. Con el uso de la IA, por el contrario, se pueden abordar estas necesidades de forma efectiva gracias al uso de diferentes tipos de dispositivos físicos, recursos computacionales y softwares inteligentes adecuados para este sector. En cualquier caso, resulta indispensable hacer un breve resumen de los principales desafíos de las IA en el campo de las energías limpias, y cómo estos se están atajando.

De esta forma, los principales problemas encontrados en este aspecto se pueden resumir en 7 desafíos fundamentales (Figura 4.1):



Figura 4.1 Principales desafíos de la IA con las ER

1. Disponibilidad y calidad de los datos: Como ya se ha visto, los algoritmos empleados en IA necesitan ser alimentados por un gran volumen de datos para poder aprender antes de generar una respuesta. De esta manera, la disponibilidad y calidad de los datos que se les da para que puedan adquirir conocimientos y capacidad crítica resulta fundamental para que el resultado posteriormente sea correcto. En el caso de Machine Learning, la que se verá es la rama predominante en el sector energético, carecer de datos de alta calidad hace inviable implementar este tipo de sistemas de IA, pues no pueden realizar ninguna de las técnicas ya vistas (aprendizaje supervisado, no supervisado o por refuerzo), así como tampoco pueden funcionar las redes neuronales del Deep Learning. Además, resulta clave en estos casos no exceder la cantidad de técnicas de ajuste y generalización para limpiar o extrapolar los datos, pues pueden dar lugar a resultados equivocados con la correspondiente pérdida de coste y calidad.

De esta manera, existen procesos de auditoría de datos para verificar la calidad de estos, cuando se van a implementar técnicas de IA en este tipo de tecnología. Así, a modo de ejemplo, en el caso de una planta energética las mediciones que se realizan se pueden ver ensuciadas por el ruido que hacen las partes mecánicas, dando lugar a una muy mala calidad de datos de entrada. Auditar el tipo de mediciones realizada, los datos de entrada obtenidos y la viabilidad de estos, es el primer paso antes de poner en marcha este tipo de prácticas. Por último, resulta también de utilidad hacer revisiones periódicas de los resultados obtenidos una vez el sistema de IA está ya implementado, para comprobar que los datos de entrada, su procesamiento y correspondiente aprendizaje por parte del algoritmo está funcionando de manera correcta.

2. Selección de los parámetros de ajuste de los sistemas: A la hora de emplear la IA para controlar sistemas energéticos, y en concreto los de ER, resulta crucial elegir correctamente que variables son las necesarias, es decir, aquellas que influyen de manera directa en los resultados a obtener pues son las que sirven de ajuste de los sistemas. Dependiendo de la técnica de IA empleada, la correcta elección de estas variables será más o menos crítica. Por ejemplo, en el caso de las redes neuronales profundas no requieren una información tan precisa como los sistemas difusos. En cualquier caso, es necesario conocer en profundidad de los sistemas, sus mecanismos físicos e influencias ambientales antes de realizar la selección.

3. Tratamiento de fallos simultáneos: Tanto este desafío como el siguiente están relacionados con las tareas de mantenimiento y su gestión. En caso de que, a lo largo de este tipo de tareas, se sucedan fallos simultáneos, los algoritmos que procesan la información se enfrentan a un gran volumen de datos con distintas motivos y fuentes de entrada. Por consiguiente, tal cantidad de información sin clasificar puede afectar al rendimiento del algoritmo, afectando a la calidad de la solución.

4. Modelado predictivo inconsistente: En este caso, y en lo relativo a las tareas de mantenimiento, supone un gran riesgo para los algoritmos de la IA empleados, que los modelos no tengan buena capacidad de adaptabilidad. Esto se debe a que, los fallos acontecidos a lo largo de la vida útil de una instalación de ER, puede ser muy variada y, en muchas ocasiones, los fallos pueden ser desconocidos, por ser la primera vez que se producen. Así, los modelos de predicción que se desarrollen deben ser robustos y tener la capacidad de adaptarse a los nuevos errores. Por ello, es vital contar con sistemas de control que permitan hacer este tipo de modelos basados en algoritmos de IA, y que conecten sistemas que llevan tiempo operando con otros que se hayan puesto en marcha recientemente, para poder hacer un desarrollo de estos a gran escala, que emplee las lecciones aprendidas de los anteriores.

5. Seguridad y protección de datos: Uno de los mayores desafíos en este caso es la seguridad de los grandes volúmenes de datos que se manejan en estas instalaciones. Existen riesgos y vulnerabilidades en temas de ciberseguridad. De esta forma, es necesaria la instalación de herramientas de seguridad ante posibles amenazas, a la par que se implementan los sistemas de IA.

6. Rendimiento de los algoritmos: Como se comentó al introducir los elementos propios de la IA (apartado 3.3.1), la explicabilidad es una de las maneras de medir el funcionamiento de los algoritmos. De esta manera, se mide la manera en la que estos son entendibles, haciendo accesible la justificación de las decisiones tomadas y sus predicciones. En el caso de las ER, las explicabilidad de los algoritmos entra en conflicto con el rendimiento de los mismos en el caso de Machine Learning. De esta forma, a mayor explicabilidad, menor es el rendimiento de los algoritmos la precisión de sus respuestas. Sin embargo, en caso de usar algoritmos de Deep Learning o redes neuronales, mantienen un buen rendimiento en sus resultados, aunque la explicabilidad no sea tan alta como en el caso de Machine Learning. Así, en función del tipo de algoritmo empleado para los sistemas de ER, encontrar el equilibrio adecuado entre la explicabilidad y el rendimiento resulta fundamental.

De esta manera, las principales técnicas empleadas en los sistemas de ER son técnicas de Deep Learning y redes neuronales profundas:

- Redes Agregadas de Arranque (BANN)
- Redes de Retro propagación (BPNN)
- Redes de Función de Base Radial (RBFNN)
- Redes basadas en el Método de Grupo de Manejo de Datos (GMDH)
- Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS), en el que se combinan las técnicas de redes neuronales con otras de lógica difusa.

Además, se usan también otras herramientas:

- Técnicas de Machine Learning como las Máquinas de Vectores de Soporte (SVM) y de aprendizaje por refuerzo como regresiones bayesianas o métodos estadísticos como la Media móvil integrada autorregresiva (ARIMA) y su variante, la Media Móvil integrada Autorregresiva Estacional (SARIMA) empleados habitualmente junto a estas técnicas.
- Técnicas de sistemas evolutivos como algoritmos genéticos (GA).

7. Almacenamiento de energía: El almacenamiento se usa como solución, entre otros casos, de los problemas de intermitencia de las ER. Dada la entidad de esta solución y sus características propias a nivel tecnológico, se van a tratar en un apartado aparte al de las ER. En cualquier caso, ha de ser mencionado llegado este punto por ser el último de los desafíos de la lista. De esta manera, los sistemas de almacenamiento tienen sus problemas *per se*, como lo elevado de su coste, la densidad energética de potencia y su vida útil. Los sistemas de IA, estudian y proporcionan información sobre los sistemas de almacenamiento energético a nivel atómico y molecular, para poder así diseñar nuevos sistemas con una mayor densidad de carga y vida útil.

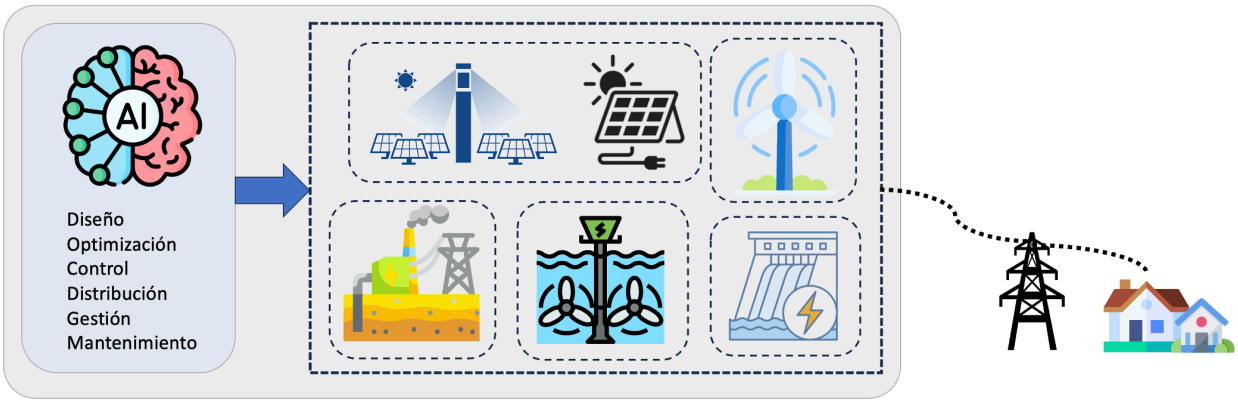


Figura 4.2 Usos de la IA en el sector de las ER

La IA permite mejorar la precisión de las tecnologías de las fuentes renovables, es capaz de modelar distintos escenarios y hacer predicciones del funcionamiento e impactos en cada uno de ellos. Este tipo de tecnología, tras ser desarrollada y probada a lo largo de los últimos años, empieza ya a tener un impacto palpable en el sector, provocando que muchas de las medidas y directrices que se están tomando en política y economía a nivel mundial se vean influidas por estos avances. De esta manera, el uso de IA para la mejora y control de los sistemas energéticos ha supuesto, en el caso de las renovables, una revolución, pues es una de las responsables y de los mayores facilitadores del aumento del uso de las ER en el *pantone* de energías actual. Así, se están consiguiendo tecnologías de energías limpias más avanzadas robustas y fiables,

integrando sistemas de IA e, incluso, incluyendo conceptos de IoT (Internet de las Cosas). Tanto es así, que se ha acuñado el nuevo término IoE (Internet de la Energía). Este es un concepto muy reciente del que se desconocen aún todas las aplicaciones y beneficios que puede conseguir. Sin embargo, cabe destacar su importancia para optimizar la integración de las ER en la red, consiguiendo reducir pérdidas en el transporte y la distribución, minimizando el gasto y aumentando la eficiencia energética.

Como se ven en la Figura 4.2, son numerosas las tecnologías en el sector de energías limpias que hace uso de técnicas de IA, incluyendo la energía solar, tanto solar térmica como fotovoltaica, eólica, geotérmica, o hidroeléctrica. En el caso de la energía solar o la eólica, por ejemplo, la IA permite mejorar su funcionamiento a través de predicciones diarias de consumo, estimaciones de radiación solar, predicción de velocidad del viento, dimensionamiento de sistemas fotovoltaicos, etc. En el caso de estos últimos, la IA ha aumentado su rentabilidad y eficiencia, así como en el caso de las turbinas de sistemas eólicos.

De esta manera, en los siguientes subapartados, vamos a hacer un recorrido por algunas de las energías limpias en las que más integrada se encuentra la IA a día de hoy: la energía solar y la energía eólica, y en una tercera lejana posición, la energía geotérmica.

4.1.1 Sistemas de control basados en IA: energía solar y energía eólica

Las energías solar y eólica son, a día de hoy, los dos tipos de ER más importantes y con mayor preeminencia a nivel mundial, pudiendo abastecer las necesidades energéticas a nivel mundial sin problema [24].Esto se debe a la abundancia y disponibilidad general de ambas, los avances tecnológicos acontecidos en ambas que han permitido reducir costes y su escalabilidad y entre otros. Además de esto, estas son las dos ER en las que la IA está más integrada. Si bien se podrían haber presentado ambas fuentes de energía de manera separada, se han unido en un único apartado dada su naturaleza intermitente. Esta, es la que ha marcado el tipo de sistemas control implantados para este tipo de fuentes de energía, siendo predominantes las aplicaciones encargadas de realizar predicciones. Así, la intermitencia de ambas ha hecho que muchas de las soluciones encontradas a la hora de implementar la IA hayan sido similares, que las técnicas empleadas sean comunes y que se hayan empleado metodologías similares. De esta manera, se van a presentar juntas, en primera instancia, con una introducción sobre la IA conjunta y luego se haya una separación, presentando las principales técnicas de control propias de cada una.

La intermitencia de las energías solar y eólica ha provocado el estudio de estas para poder realizar predicciones sobre su disponibilidad y, por ende, de la producción de energía eléctrica. Para ello, se comenzó empleando modelos físicos, estadísticos y de regresión, pero la calidad de los resultados generados era pobre e insuficiente, por lo que se unió a este tipo de estudios, el uso de la IA. Por una parte, se han usado redes neuronales (RNN, LTSM y CNN) como principales técnicas de Deep Learning; SVM, aprendizaje ensamblado y aprendizaje por refuerzo, por la parte de Machine Learning y sistemas de inferencia difusa. En el caso de los modelos de aprendizaje ensamblado, en los que ya se vio que se combinaban los resultados de varios modelos ejecutados en paralelo, destaca el uso de RF, *Catboost* y *XGBoost* para este tipo de aplicaciones.

Sin embargo, los resultados obtenidos han sido insuficientes o poco precisos, por lo que ha sido necesario combinar este tipo de técnicas de la IA de Machine Learning con otras técnicas relacionadas con métodos metaheurísticos (y sus técnicas relacionadas con los sistemas evolutivos).

De manera esquemática, la Figura 4.3, presenta los métodos de predicción para las energía solar y eólica más empleados y las técnicas de IA que se usan para cada uno de ellos.

Si bien los métodos de predicción basados en IA tradicional, como las redes neuronales, la lógica difusa o la agrupación, y ciertos métodos heurísticos como los algoritmos evolucionales o los métodos de enjambre, ya se expusieron en el apartado 3 de este trabajo, aparece ahora una nueva categoría denominada “métodos híbridos”, muy comunes en el uso de la IA en los sistemas de energía solar y eólica. Estos, permiten llegar

donde los métodos simples no lo hacen. De esta manera, combinando los métodos anteriores se consiguen respuestas optimizadas y mejores rendimientos. Su funcionamiento se basa en el uso de dos métodos, donde uno da una predicción de partida y, el segundo, optimiza la respuesta del primero. A modo de ejemplo, se suelen usar redes neuronales profundas para estimar una primera respuesta que después se optimiza a través de algoritmos genéticos.

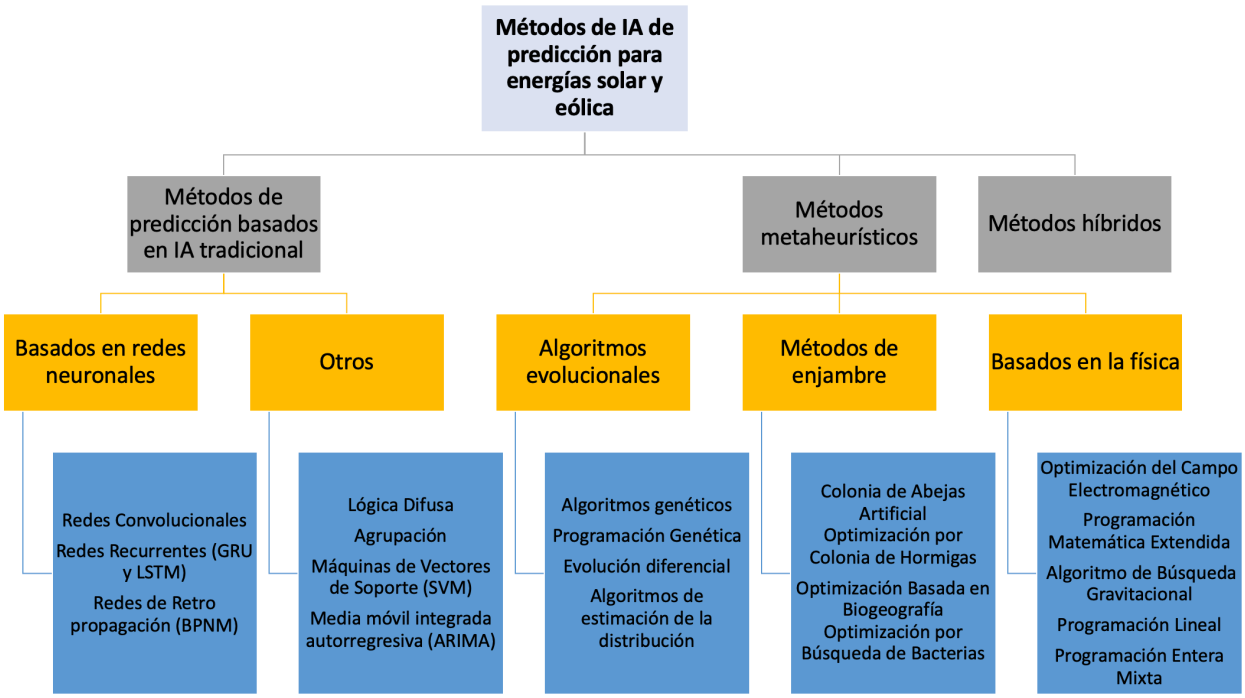


Figura 4.3 Sistemas de predicción y sus técnicas de IA asociadas

En la Figura 4.4 se esquematiza cómo los métodos híbridos se emplean para los sistemas de energía solar y eólica. Así, tras optimizar la primera predicción gracias al uso de dos métodos, se ve la comparativa entre las dos respuestas obtenidas, donde la primera en azul es la predicción original y la segunda, en rojo, es la corregida.

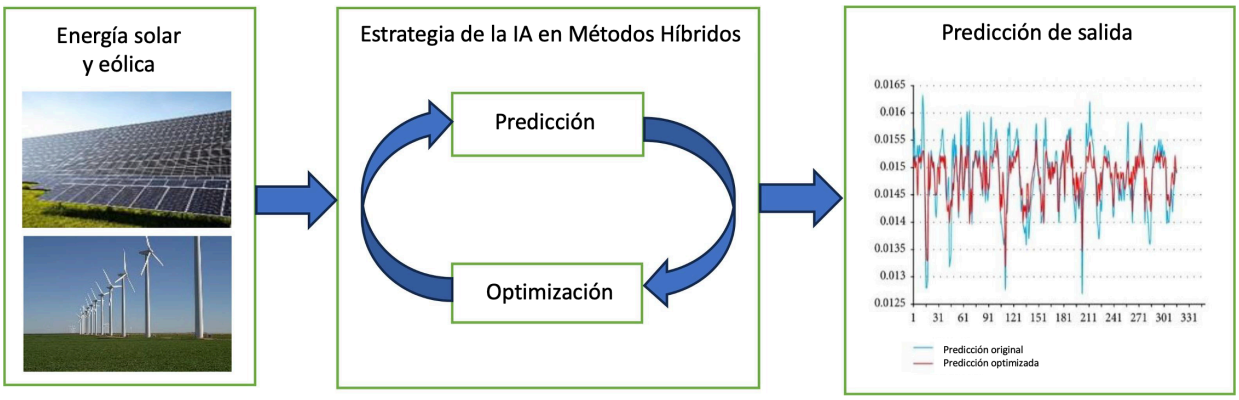


Figura 4.4 Esquema de funcionamiento de métodos híbridos

Existen algunos ejemplos ya implementados de sistemas de control para sistemas de ER solares y eólicos, basados todos en la realización de predicciones para conseguir solventar el problema de la intermitencia de ambas. Se presentan a continuación ejemplos en distintos países del mundo:

- Arabia Saudí: Emplean un modelo SVM con redes neuronales antagónicas que realiza predicciones cada 5 minutos. En este caso, se han producido errores debido a la convergencia prematura y la existencia de mínimos locales que han resuelto incluyendo métodos para el preprocesamiento de los datos [25].

- Australia: El sistema implantado en Australia, concretamente en Alice Spring, usa redes neuronales antagónicas para hacer predicciones horarias para energía solar fotovoltaica. Realizan predicciones para la potencia solar, cuya precisión en los resultados mejoró al introducir en el algoritmo datos de entrada sobre el índice UV. En cualquier caso, sería necesaria la implementación de métodos metaheurísticos como los de la Figura 4.3 para poder mejorar la precisión de los resultados aún más [26].

- China: Aquí realizan predicciones de radiación solar empleando redes neuronales de retardo temporal (TDNN), que son un tipo de redes neuronales profundas que permiten procesar series temporales de datos incluyendo como variable los retrasos o el periodo de tiempo transcurrido entre las distintas entradas. Además, combinan este tipo de red con funciones multiplicativas múltiples, que permite modelar interacciones entre variables con una relación no lineal [27].

  Para poder realizar estas estimaciones, horarias, emplean un algoritmo de preprocesamiento denominado ARMA, por sus siglas en inglés (*Auto Regressive Moving Average*), también conocido en español como Media Móvil Auto Regresiva), método muy conocido para la estimación de valores futuros a partir de datos históricos. Este modelo, se representa de la siguiente manera:

$$y_t = c + \sum_{i=1}^{p} \phi_i \, y_{t-i} + \sum_{j=1}^{q} \theta_j \epsilon_{t-j} + \epsilon_t$$

  Donde:

  - c es una constante.
  - y_t es el valor actual de la serie.
  - ϕ_i son los térmicos auto regresivos.
  - θ_j son los términos de la media móvil.
  - ϵ_t representa el error cometido a lo largo del tiempo.
  - p es el número de retardos.
  - q es el número de errores considerados.

  Además, en China también, existe un sistema que realiza predicciones de potencia diarias de energía eólica gracias a modelos de LTSM que se alimentan con datos pre procesados empleando *XGBoost,* LSTM, CNN y redes multicapa.

- India: Realizan predicciones horarias de radiación solar con redes antagónicas entrenadas con el algoritmo LM (*Levenberg-Marquardt*). Si bien no utilizan pre procesamiento de datos, el uso de métodos heurísticos permitiría refinar las predicciones, dada la complejidad de las mismas [28].

- Irán: En Irán han implantado este sistema en dos ubicaciones diferentes, una hace predicciones horarias o mensuales y la otra las hace diarias. En ambos casos emplean SVM, concretamente en su versión SVR (Regresión con Máquinas de Soporte Vectorial), combinado con RBFNN (redes de función de base radial). Lo que difiere de una y otra es el método de pre procesamiento empleado. En el primer caso, el también utilizan SVR-RBFNN, consiguiendo mejoras palpables en el rendimiento del sistema una vez se inició el pre procesamiento [29]. Sin embargo, en el

segundo caso con predicciones horarias, emplean modelos empíricos, obteniendo una peor calidad de los resultados. De acuerdo a los estudios realizados, la sustitución de los modelos empíricos por SVR-RBFNN mejoraría el rendimiento también en este caso [29].

- Países Bajos: Realizan predicciones diarias con redes neuronales que se alimentan con datos pre procesados a partir de SVR, RF y aprendizaje ensamblado. Si bien tiene un funcionamiento adecuado, presenta ciertos problemas a la hora de encontrar mínimos globales, por lo que se plantea incluir métodos heurísticos para el pre procesamiento [30].
- Taiwán: Este sistema de predicción horaria emplea CNN y se caracteriza por su robustez y predicción precisas gracias a los métodos de pre procesamiento empleados, a saber: SVM, LTSM y RF [31].
- Turquía: En este país existen dos sistemas de predicción, con la particularidad de que uno de ellos solo hace predicciones solares de radiación cada hora y el otro, si bien hace las predicciones horarias, sirve tanto para solar como para eólica. En el primer caso, emplea lógica difusa con SVM y un pre procesamiento de datos basado en ANFIS. El segundo, por otro lado, utiliza aprendizaje ensamblado con preprocesamiento basado en *AdaBoost,* SVR, k-media y regresiones lineales [32].
- Ecuador: En este caso, las predicciones también son diarias para sistemas de energía eólica y se basan en modelos LTSM, pero tienen un pre procesamiento de datos basado en ARMA, entre otros [33].

4.1.1.1 Sistemas de control particularizados para energía solar

Como se viene comentando en los puntos anteriores, la IA se emplea, en el caso de la energía solar, para realizar predicciones, optimizaciones, modelados y pronósticos. Así, ha sido posible modelar la radiación solar, resolver problemas con datos insuficientes (falta de irradiación) y evaluar ubicaciones en las que no había suficientes datos relacionados como para hacer el estudio de viabilidad.

Hasta ahora, ese tipo de estudios de simulación se había llevado a cabo con modelos físicos tradicionales. Sin embargo, el uso de la IA en estos casos da lugar a resultados más certeros y precisos, optimizando la cantidad de trabajo computacional para tal fin y la eficiencia total del sistema.

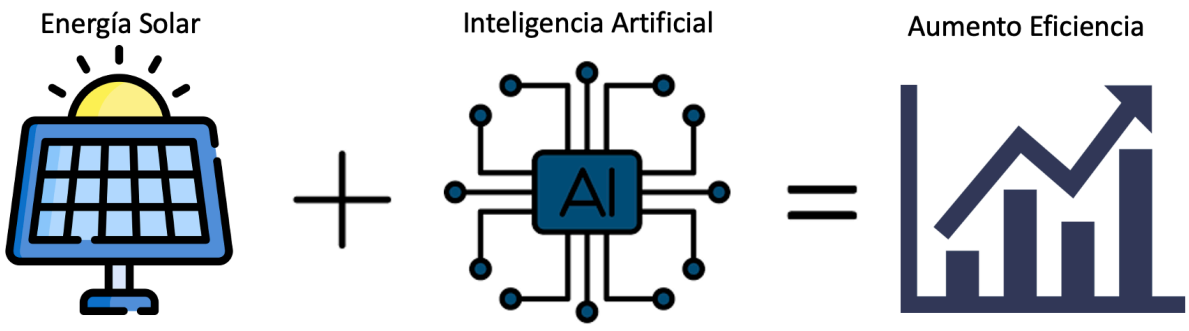


Figura 4.5 Infografía sobre beneficio de IA para la energía solar

De manera general, las redes más utilizadas para las predicciones de radiación, irradiancia, temperatura ambiental diaria, potencia máxima de módulos fotovoltaicos o calefacción de agua son las ANN. Sin embargo, para los modelados de suministro de energía fotovoltaica, índice de claridad, irradiancia global por hora o chimeneas solares, los resultados obtenidos con ANFIS resultaban de mayor calidad [4]. Para este tipo de estudios, y así poder comparar los resultados al emplear distintas técnicas, se calculan diferentes

tipos de error. De esta forma, y antes de proseguir con los sistemas de control para cada tipo de estimación, se van a presentar los errores que se han usado para poder medir el rendimiento y cómo se calcula cada uno:

- MAE (*Mean Absolute Error*): Error Absoluto Medio. Es la media del sumatorio de las diferencias absolutas encontradas entre los valores predichos y los reales.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|$$

- MAPE (*Mean Absolute Percentage Error*): Error Porcentual Absoluto Medio. Es la media del sumatorio de las diferencias absolutas encontradas entre los valores predichos y los reales, expresada como porcentaje sobre el número de predicciones realizadas. En otras palabras, es el MAE expresado en porcentaje.

$$MAPE = \frac{100}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right|$$

- RMSE (*Root Mean Square Error*): Error Cuadrático Medio. Es la raíz cuadrada de la media de los errores cuadrados.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}$$

- rRMSE (*Relative Root Mean Square Error*): Error Relativo Cuadrático Medio. Es el RMSE frente a la media de los valores reales, expresado como un porcentaje.

$$rRMSE = \frac{RMSE}{\bar{y}} \times 100\%$$

- rMBE (*Relative Mean Bias Error*): Sesgo Medio Relativo. Mide el sesgo promedio relativo en las predicciones, expresado como un porcentaje de los valores reales.

$$rMBE = \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)}{\sum_{i=1}^{n} y_i} \times 100\%$$

- STD (*Standard Deviation*): Desviación estándar. Es un indicativo de la dispersión de los datos respecto al valor medio real.

$$STD = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \bar{y}_i)^2}$$

- R^2: Coeficiente de determinación. Es la proporción de la varianza en los valores reales. Su valor oscila entre 0 y 1, siendo 1 cuando la predicción es perfecta.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2}$$

Donde todos estos errores siguen la misma notación:

- y_i es el valor real.
- y_i es el valor predicho.
- n es el número de predicciones.
- $\bar{y}$ es la media de los valores reales.

Una vez detallados los errores, se detallan ahora distintos sistemas de control para sistemas solares que están bajo estudio y desarrollo en la actualidad:

- **Sistema de predicción de radiación mediante ANFIS**. En comparación con los modelos estadísticos empleados anteriormente para estimar la irradiancia global, proveen de resultados más precisos, siempre y cuando se alimente el algoritmo con suficientes datos de entrada, tanto a nivel cuantitativo como cualitativo. Sin embargo, se encuentra muy limitado por la ubicación y las variables climáticas optimizables por el modelo. En esos casos, los errores medidos arrojan los siguientes resultados [34]:

  rMBE = −4.08 ± 2.18 %
  rRMSE = 25.9 ± 0.90 %
  Standard Deviation (STD) ~ 1.44

  El rMBE es bastante bajo, con una leve desviación negativa que implica una subestimación muy leve de los valores reales (entorno al 4%). Sin embargo, tanto el rRMSE como el STD indican que, aunque los errores no tienen una alta dispersión, son lo suficientemente grandes como para que este tipo de sistema de control no sea aún lo suficientemente confiable. Necesitaría ajustes y revisiones en su funcionamiento antes de ser desplegado.

- **Sistema de predicción del rendimiento de plantas de chimenea solar mediante ANFIS**. Las plantas de chimenea solar, más conocidas en inglés como *Solar Chimney Power Plant* (SCCP) permiten generar electricidad mediante el uso de una turbina situada en su base. Esta funciona gracias a la circulación del aire por la chimenea, de abajo a arriba, fruto de la diferencia de densidades entre el aire frío y el caliente que sale por la parte superior [35]. Para este tipo de plantas, se consiguió un coeficiente de determinación muy alto, R^2=0,92 [36], durante la fase de modelado, por lo que las estimaciones mediante el uso de la IA son bastantes certeras respecto a la realidad. En este caso, sí se consigue una estimación del rendimiento realista y con bajo costo computacional.

- **Sistema de predicción horaria de irradiancia solar usando BANN** (*Bootstrap Agregation Neural Netowrks)* o en español Redes Neuronales Agregadas, que son redes neuronales que aplican la técnica de *bagging* vista con anterioridad. Este método ha sido ya probado en Argelia usando 8 parámetros de entrada sobre el clima y la meteorología. En este caso se ha comprobado que los resultados han sido altamente precisos con un coeficiente de determinación R^2=0,9680 [37]. El uso de BANN, además, se ha comprobado es adecuado para aquellas regiones en las que no se disponen aparatos de medición para introducir las condiciones meteorológicas de partida, pues funciona bien con un pequeño conjunto de datos estadísticos para empezar a funcionar.

- **Sistema de predicción para la radiación solar difusa, usando BPNN**. En este caso, se midieron 7 parámetros como datos de partida para el modelo, a saber: temperatura media, mes, horas de luz al día, velocidad del viento, humedad relativa, precipitaciones y radiación solar global diaria. En este caso, el RMSE conseguido fue muy bajo (RMSE = $2{,}823 \times 10^{-4}$) [38]. La radiación solar difusa pronosticada con la IA, de esta forma, fue muy precisa de acuerdo a la realidad.

- **Sistema para predecir la temperatura media, usando GA y BPNN**. Este tipo de sistema ha arrojado uno de los mejores resultados de entre los propuestos, con un MAPE<1% y RMSE=0,3853 ± 0,4057 [39]. Este sistema permite predecir de manera precisa la temperatura radiante media con un coste computacional muy bajo, por lo que resulta óptimo en recursos, costes y resultados. Si bien muchas ventajas, el inconveniente detectado es la necesidad de preparar los datos de entrada que servirán para el aprendizaje del algoritmo.

- **Sistemas de predicción de la radiación solar global.** Para este tipo de sistemas, existe dos variantes: uno que emplea el modelo CMLP basado BPNN; y otro que emplea SVR.

  El primero emplea el algoritmo de retro propagación aplicado a un tipo de estructura de red neuronal denominado CMLP (*Cascaded Multilayer Perceptron*) en español Perceptrón de Cascada Multicapa, que son redes neuronales en las que no todas las conexiones siguen un patrón lineal típico. Dado el tipo de sistema de IA aplicado, ideal para casos más complejos, se consiguieron resultados muy precisos. Para ello, se probó en distintas ubicaciones con distintos marcos temporales (diarios y mensuales) y se compararon los resultados con 7 modelos determinísticos basados en temperatura con rRMSE = 5,67 – 6,57 % [40]. El principal inconveniente de este sistema es que, dada su complejidad, resulta difícil integrar otros sistemas o técnicas computacionales que lo complementen, incrementando por tu tanto su coste.

- El segundo, por otro lado, solo se ha podido probar en una ubicación (Egipto) y, aunque los modelos de regresión de vectores soporte han dado resultados adecuados durante la fase experimental, todavía es necesario refinar el conjunto de datos de entrada para el aprendizaje del modelo y las pruebas que a estos se le realizan.

Sistemas de control para energía solar fotovoltaica

Uno de los objetivos principales del uso de la IA en la energía solar fotovoltaica es conseguir reducir el coste y mejorar la funcionalidad y eficacia de la tecnología empleada. Hasta la llegada de la IA, las células fotovoltaicas se diseñaban y optimizaban de acuerdo a modelos teóricos y métodos empíricos de prueba y error. Sin embargo, al incorporar la IA a este tipo de estudios, es posible mejorar la eficiencia de las células fotovoltaicas de forma más rápida, barata y precisa.

De esta forma, de los distintos aspectos de las placas solares a abordar, la eficiencia de las mismas es uno de los más importantes. Por ello, uno de los principales logros conseguidos son sistemas de control basados en IA que modifiquen en tiempo real las condiciones operativas de los paneles, mejorando por tanto el rendimiento de estos.

Por otro lado, dada la dependencia del rendimiento de estos paneles de las condiciones atmosféricas, poder realizar predicciones fiables de parámetros como la irradiancia sirve también para mejorar dicho rendimiento. De esta forma, el uso de IA para hacer estas predicciones supone también una optimización de los resultados y un aumento de la fiabilidad del sistema. Además, este tipo de algoritmo, permite ser alimentado con grandes conjuntos de datos, no solo sobre las condiciones climáticas, sino también con datos sobre rendimientos y sobre la configuración de los paneles, sirviendo como base de aprendizaje para los algoritmos. Así estos pueden identificar las relaciones e interdependencias entre todas ellas.

De acuerdo a esto, se presentan un listado de sistemas de control basados en IA para sistemas de energía solar fotovoltaica que están actualmente en estudio o bajo desarrollo:

- **Sistema de control de potencia, usando GA-Lógica difusa.** Este sistema de IA híbrido, que combina algoritmos genéticos con técnicas de lógica difusa de emplea para controlar las potencias activa y reactiva. De esta manera, se vio que el Compensador Síncrono Estático (STATCOM) absorbía en mayor medida la potencia reactiva, disminuyendo también la Distorsión Armónica Total (THD) para corriente continua, consiguiéndose así energía de mejor calidad.

- **Sistema de seguimiento de potencia de energía fotovoltaica, usando ANFIS.** Con este tipo de sistema, se consiguió un aumento de la potencia de salida del 97%, gracias a la capacidad del modelo ANFIS de adaptarse a las fluctuaciones de la irradiancia y la temperatura sin producir oscilaciones cerca del punto de máxima potencia en estado estacionario. En este caso, el coeficiente de determinación alcanzó valores cercanos a 1 ($R^2 \sim 99$ %) [41].
- **Sistema de extracción de parámetros operativos de paneles fotovoltaicos, usando ISOA.** En este caso, se modelaron células fotovoltaicas de silicio monocristalino, silicio amorfo y células fotovoltaicas RTC France, para modelos de diodo simple y doble. El algoritmo ISOA (*Improved Snake Optimization Algorithm*) que es de tipo genético, fue capaz de mejorar los resultados de los silicios monocristalinos del 16%, del 5,3% para los de silicio amorfo y tan solo de un 0,1% para los RTC France. Así, no se detectaron grandes diferencias de cálculo computacional para los casos de diodo simple o doble, con un tiempo de respuesta muy similar en ambos casos (entorno a 20 segundos). Los mejores resultados de este tipo de sistema son los conseguidos para los silicios monocristalinos, con un error muy bajo, a saber: $RMSE = 5{,}58 \times 10^{-4}$ [42].
- **Sistema de extracción de parámetros de células fotovoltaicas, usando ISCE.** En este tipo de sistemas, los sistemas de IA emplean algoritmos ISCE (*Improved Shuffled Complex Evolution Algorithm*) que es un algoritmo usado para problemas de optimización no lineal basado en algoritmos no evolutivos que emplean la técnica de enjambre. En este caso, se consiguen resultados precisos y confiables, con una respuesta del sistema eficiente y un error muy bajo ($RMSE = 9{,}860219 \times 10^{-4}$) [43]. De todos los algoritmos probados en este tipo de sistemas, los sistemas que emplearon ISCE lograron la mejor extracción de parámetros de paneles fotovoltaicos.
- **Sistema de predicción de potencia, usando SVR y BPNN.** En este caso, los resultados fueron precisos y se obtuvieron por tanto buenas predicciones. Además de esto, este tipo de sistemas cuenta con la ventaja competitiva de emplear técnicas de baja complejidad computacional, consiguiendo buenos resultados con modelos simples y de bajo coste. Los errores en este tipo de sistemas tuvieron unos valores aproximados de: rRMSE ~ 3%, RMSE = 0,133 en el caso de SVR y RMSE = 0,131 para las redes de retro propagación [44].
- **Sistema de predicción de potencia generada usando regresiones RF.** Para este tipo de sistemas tienen una mayor dificultad computacional, requieren una gran capacidad de procesamiento y suponen un mayor coste, por lo que no resultan competitivos como otros. Sin embargo, sí logran resultados precisos, logrando explicar la potencia generada de manera global, con periodicidad horaria y un error rRMSE = 7,23 % [45].
- **Sistema de seguimiento del punto de máxima potencia, usando GA**. Para ello, se consiguió realizar el seguimiento y control del sistema a partir de un microcontrolador configurado con algoritmos genéticos. En general, tiene un buen funcionamiento con un seguimiento solar correcto. Sin embargo, presenta algunas desviaciones hay días nublados. En este caso, STD ~ 1,55 [46].

4.1.1.2 Sistemas de control particularizados para energía eólica

Como se comentó anteriormente, las energías solar y eólica son las dos más importantes dentro del panorama de energías renovables actual. Concretamente, la energía eólica es que está experimentando un crecimiento más rápido a nivel mundial y la más limpia, gracias su producción de energía libre de contaminación de aire, agua, de sustancias tóxicas y peligrosas [24]. En comparación con la energía solar, la eólica permanece disponible durante todo el día, además de emitir menos CO_2 por KWh frente a los paneles solares.

A modo de ejemplo, las estadísticas en Estados Unidos sobre la producción de energía revelan que la energía eólica supuso un 8,4% de toda la producción a escala de servicios públicos en 2020, estando previsto que aumente un 20% para 2030 y un 35% para 2050 [22].

Sin embargo, son numerosos los factores que influyen en el funcionamiento de los aerogeneradores y, por tanto, en los sistemas empleados para controlarlos. En primer lugar, el viento empleado por los aerogeneradores influye de manera directa en la cantidad de energía que estos pueden producir. Dado que la velocidad de este viento no es lineal y depende de las condiciones meteorológicas, predecir cómo será este resulta de vital importancia para controlar adecuadamente la producción de energía en los sistemas eólicos y, por ende, mejorar el rendimiento, la estabilidad del sistema eléctrico, su fiabilidad y seguridad. En segundo lugar, existe otro *hándicap* a la hora de controlar la producción de energía con aerogeneradores que está relacionado con las corrientes de viento que se crean después de que el viento pase a través de las palas del rotor de la turbina, también denominada como "turbulencia de estela" (WTB) por sus siglas en inglés (*wake turbulence*), que es una turbulencia que se crea detrás de la turbina y afecta al flujo de aire aguas abajo. Además, la correcta ubicación de los aerogeneradores resulta fundamental para poder maximizar el rendimiento de las mismas, habiéndose usado hasta ahora modelos de predicción basados en modelos físicos y de estadística de acuerdo a los patrones del viento en las ubicaciones bajo estudio. Por otro lado, en los sistemas de energía renovable y, más concretamente, en las plantas eólicas, los costes asociados a la operación y mantenimiento suponen un factor crucial para que estas sean viables. Por ello, encontrar un equilibrio óptimo entre los costes asociados a los parámetros indicados anteriormente es necesario para hacerla competitiva frente a otras. Una de las formas de equilibrar estos costes para tener un LCOE (*Levelized Cost of Energy*), o en español, Coste Normalizado de la Energía, competitivo es hacer invertir en tareas de mantenimiento en los equipos. A modo de resumen, la Figura 4.6 muestra la relación entre el uso de la IA y las distintas formas en las que esta se aplica para mejorar el funcionamiento y control y de los sistemas de energía eólicos:

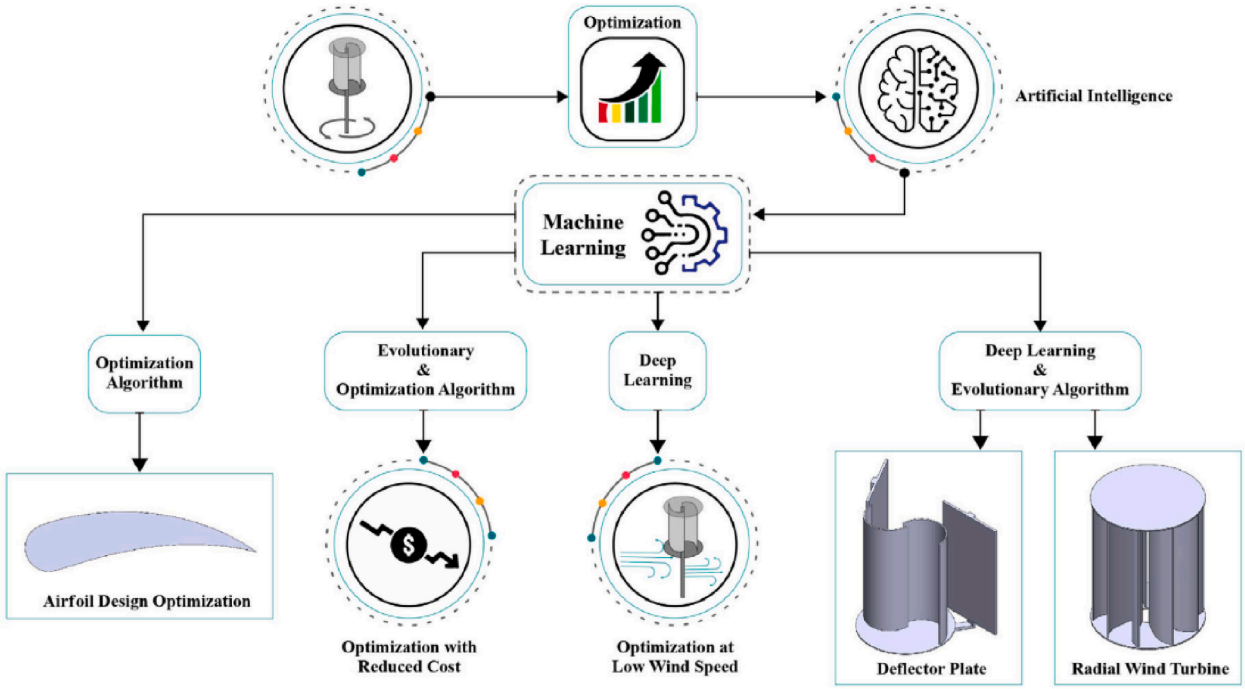


Figura 4.6 Uso de la IA en sistemas de energía eólica [4]

En concreto, las tareas de mantenimiento predictivo permiten maximizar tanto la disponibilidad como la productividad de la planta, evitando paradas no programadas y optimizando los tiempos de operación. Además, permiten alargar la vida útil de los equipos, mejorando el rendimiento, la seguridad operacional y reduciendo los costes. A modo de ejemplo, y para entender la importancia de detectar posibles fallos de

antemano, se propone analizar un pequeño caso de uso sobre un parque eólico en alta mar. Si se produce un fallo que no se ha detectado a priori, y este es en uno de los elementos principales del aerogenerador, esto puede desembocar a una parada de la planta de larga duración. En este caso, sería necesario diagnosticar el problema y buscar su causa raíz (mantenimiento correctivo), fabricar el componente necesario y transportarlo hasta la ubicación de la planta. Dada su localización, el uso de un buque con grúa integrada sería necesario para poder elevar el equipo para su correcta colocación. Dada la logística necesaria, los recursos invertidos en este correctivo y la parada de la planta, este tipo de averías resulta en pérdidas económicas de gran envergadura, que hacen del mantenimiento predictivo una necesidad en este tipo de sistemas.

De esta manera, y dada la importancia que tiene un buen control del funcionamiento de los aerogeneradores para este tipo de producción de potencia, se han integrado técnicas de IA para optimizar este. Algunos ejemplos de los algoritmos y modelos más empleados en este caso son las redes neuronales, las máquinas SVM y los algoritmos optimización por enjambre. Por una parte, las DNN se emplean para realizar predicciones. La IA persigue con esto conseguir aerogeneradores capaces de ajustarse a las corrientes y concentraciones de viento no lineales y variables en el tiempo. En este caso, el uso de redes neuronales ha conseguido resultados precisos, con errores de baja magnitud, prediciendo tanto la velocidad del viento como su densidad, además de la potencia generada. Por otro lado, las SVM y las redes CNN se han empleado mayormente para la detección de fallos. Por último, los algoritmos de optimización por enjambre, se emplean normalmente para optimizar los parámetros de las turbinas eólicas.

A continuación, se van a presentar distintos sistemas de control basados en IA para sistemas de energía eólica que se centran, principalmente, en realizar predicciones de la velocidad del viento, predicciones de producción de energía y aplicaciones para mantenimiento predictivo:

- **Sistemas de predicción de velocidad del viento.** Este tipo de sistemas están basados en redes neuronales y se han hecho estudios de dos tipos: una para DNN y otra para CNN. En el primer caso, se comparó el resultado de usar redes neuronales profundas con el uso de modelos WRF (*Weather Research and Forecasting*) para la predicción de la velocidad del viento en Arabia Saudí. Así, los resultados obtenidos para las DNN son de alta precisión, con un coeficiente de determinación $R^2 \sim 99\ \%$. Sin embargo, y como en otros sistemas parecidos vistos para las predicciones de energía solar, el inconveniente principal de estos modelos es la necesidad de grandes volúmenes de datos para que el algoritmo aprenda. En segundo lugar, los sistemas que emplean CNN han logrado también resultado de alta precisión con un MAE = 0,80 y un RMSE = 0,99 [47] para las predicciones a corto plazo, pero con peores resultados para aquellas a largo plazo.

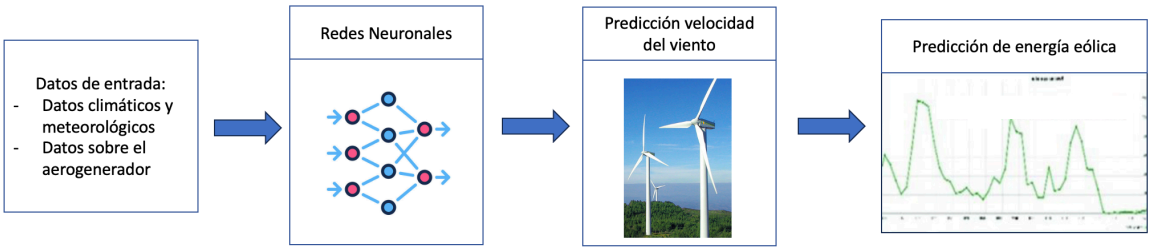


Figura 4.7 Esquema sobre la predicción de viento en sistemas eólicos y su utilidad

- **Sistema de control del potencial de energía eólica usando algoritmos de optimización por enjambre.** Los resultados para esto tipo de sistema fueron positivos, tanto para predicciones de velocidad del viento como de otros parámetros del sistema que permitan gestionar y controlar el funcionamiento del mismo. En este caso, una de las principales ventajas de los algoritmos por enjambres es su capacidad para eliminar el ruido de los datos de entrada para el entrenamiento del

algoritmo, depurando así los datos de velocidad del viento para su aprendizaje. A su vez, y como contrapartida de esta ventaja, el principal inconveniente es asegurar que los valores de entrada de velocidad permanecen inalterados tras la limpieza. En cualquier caso, y para este sistema, los errores tomaron unos valores de MAE ~ 0,108 y RMSE ~ 0,163 [48].

- **Sistema de control de turbinas eólicas con velocidad del viento variable y *pitch* variable usando aprendizaje por refuerzo.** Las turbinas eólicas de *pitch* variable son aquellas que cuentan con un sistema de regulación de potencia de la misma actuando sobre la posición de las palas del rotor respecto al viento. De esta manera, se comprueba que el uso de modelos de aprendizaje por refuerzo permite controlar el ángulo correctamente de acuerdo a las características del viento de entrada. Si bien los resultados fueron adecuados realizando simulaciones de distintas tipologías de viento, el principal inconveniente nace de una mala medición de las incertidumbres durante el estudio. En este caso el rRMSE ~ 3% [48].

- **Sistema de optimización de turbinas eólicas usando BPNN.** En este caso, se emplean redes neuronales de retro propagación de avance directo, de 4 capas. De esta manera, se compararon los resultados usando este tipo de redes con el resultado de métodos estadísticos, consiguiendo para el resultado de la densidad del viento un coeficiente de determinación R^2 ~ 99 %. Durante la ejecución del estudio, que tuvo una duración de 9 meses, se logró realizar predicciones de producción de potencia con un error promedio de 0,4% [49].

- **Sistemas de control para la generación de potencia en aerogeneradores.** Para este tipo de sistemas de control se ha empleado dos algoritmos: RNN y ARIMA. Dada la dependencia de los resultados y su precisión a las condiciones meteorológicas de cada ubicación, ambos métodos se han aplicado para los mismos datos de una planta de producción de energía eólica en Pakistán, para poder así comparar los resultados usando ambos métodos y comprobar cuál de los dos arroja los más precisos. En ambos casos, el primer caso es la recopilación de datos meteorológicos del parque eólico a estudiar, así como los datos del SCADA (*Supervisory Control and Data Acquisition*), que es el sistema de control de las turbinas eólicas. Estos datos de partida, recogían información sobre la velocidad y la dirección del viento, el clima, la temperatura, la humedad, la densidad del aire, el radio de las palas, la lluvia, etc. a lo largo de 30 días. Una vez recopilados todos estos datos y tras procesarlos para eliminar el posible ruido, se dividen en dos grupos, a saber: datos de entrenamiento y de prueba. Con los primeros, que representan el 80% de los datos recopilados, se entrena al algoritmo de IA y con el segundo, que suponen el 20% restante, se realizan las pruebas con las que conseguir los resultados deseados.

    - Método RNN. Dentro de las redes neuronales recurrentes, se emplea concretamente el tipo GRU (*Gated Recurrent Unit*), o en español Unidades Recurrentes Cerradas. Estas, son un tipo de RNN muy similar a las LSTM que emplea "puertas" para controlar los flujos de información, con la diferencia de que las GRU se entrenan de manera más rápida que las LSTM. De esta manera, las redes tipo GRU solo cuentan con dos puertas, una de actualización y otra de reinicio, simplificando por tanto la complejidad a nivel computacional. La puerta de actualización es la encargada de sumar las entradas actuales con su propio peso al resultado de la capa oculta anterior y su peso. Así, permite controlar cuánto de las capas anteriores prevalece y cuánto del nuevo estado se debe incorporar al estado actual. Así, la red puede decidir cuánta información nueva pasa hacia adelante frente a la cantidad de información pasada que se sigue manteniendo. Este tipo de puertas se formulan de la siguiente manera:

$$u_t = \sigma(W_z \cdot (h_{t-1}, x_t))$$

La puerta de reinicio, por otro lado, controla cuánta información del estado anterior se olvida. Así, permita reestablecer la memoria de la red si es necesario. En este caso, la fórmula es:

$$r_t = \sigma(W_r \cdot (h_{t-1}, x_t))$$

Por último, una vez se han calculado las puertas de actualización y reinicio para un tiempo t, se calcula el denominado "estado oculto". Este, funciona como la memoria de la red, actualizándose cada vez que se procesa información de una puerta a otra. Así:

$$h_t = (1 - u_t) \cdot h_{t-1} + u_t \cdot \widetilde{h_t}$$

$$\widetilde{h_t} = \tanh\,(W \cdot (r_t \cdot h_{t-1}, x_t))$$

Donde:

- h_t: Es el nuevo estado oculto para tiempo t.
- u_t: Es la salida de la puerta actual (para tiempo t).
- r_t: Es la salida de la puerta de reinicio (para tiempo t).
- σ: Función que mantiene los valores de r_t entre 0 y 1.
- W_z: Matriz de pesos de la puerta de actualización.
- W_r: Matriz de pesos de la puerta de reinicio.
- h_{t-1}: Estado oculto anterior.
- x_t: Entrada actual.

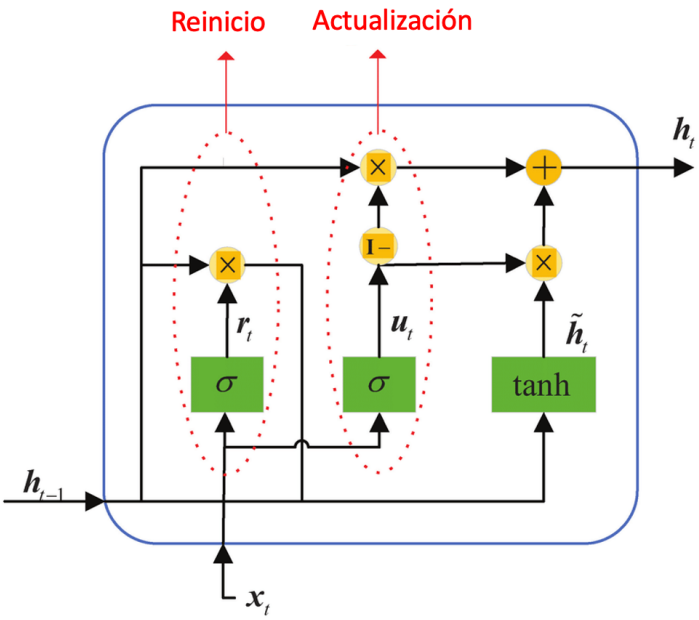


Figura 4.8 Esquema de red recurrente tipo GRU [50]

- Método ARIMA: El método ARIMA, ya mencionado con anterioridad, es un modelo estadístico que combina 3 elementos clave: las auto regresiones (AR), la Integración (I) Y la media móvil (MA). Así, se emplea para realizar predicciones con series temporales como

dato de partida. Está especialmente indicado para datos no estacionarios que cambian a lo largo del tiempo, de ahí su idoneidad para este tipo de predicciones con datos sujetos a la meteorología. De esta forma, los parámetros que modelan ARIMA son 3: *p, d* y *q*. En primer lugar, *p* representa el número de términos auto regresivos y permite establecer la relación entre un valor y sus valores anteriores. Por otro lado, *d* mide la cantidad de datos eliminados en los valores anteriores. Por último, *q* representa el número de términos de media móvil del modelo y sirve para ajustar la serie de acuerdo a los errores pasados.

Los resultados obtenidos para cada uno de los dos métodos concluyen lo siguiente:

- El método ARIMA permite modelar series temporales con un entrenamiento de alta duración. Supone un método robusto con gran capacidad para generalizar o extrapolar resultados, pero, como contra, depende de la estacionalidad y no dispone de memoria para retener todos los datos.
- El método GRU, también robusto, tiene un tiempo de entrenamiento menor que se ejecuta de manera más rápida, sí dispone de memoria y tiene una complejidad computacional menor.
- Los errores obtenidos con el método ARIMA son: MAE = 226,55; RMSE=397,64; MAPE = 475,75. Para el método GRU, por otro lado, son: MAE = 0,0371; RMSE=0,0479; MAPE = 0,456 [24].
- El método GRU, por tanto, obtiene unos resultados más precisos, con menores errores y unas características de funcionamiento mejores que las de ARIMA.

- **Sistema de mantenimiento predictive usando CNN:** Si bien en la mayoría de sistemas de control se presenta la IA como solución propuesta, en este tipo de sistema se plantea una solución híbrida en la que la IA colabore con los técnicos de mantenimiento expertos en el tema. En este caso, se emplearon redes convolucionales alimentadas con conjuntos de datos de imágenes etiquetadas. Estas, estaban realizadas con un endoscopio en aquellos rodamientos que hubieran fallado en un parque eólico. Concretamente, se recopilaron 2301 imágenes de 138 turbinas eólicas. Al conjugar el trabajo de 54 técnicos, divididos entre generalistas y especialistas en función de su nivel de *expertise*. Una vez obtenidos los resultados, se comprobó un aumento de la eficiencia del 25,3% en el trabajo de los generalistas asistidos por IA y un aumento de 6,4% de eficiencia en el trabajo de los especialistas [51]. Así, la IA supone un incremento en la eficacia de las tareas de mantenimiento predictivo, reduciendo el tiempo de inactividad de los parques eólicos por fallos mecánicos, en este caso.

4.1.2 Sistemas de control de energía geotérmica basados en IA

Los sistemas de energía geotérmicos se empezaron a emplear en el siglo XIX, aunque no fue hasta el siglo XX cuando se empezaron a desarrollar como una de las fuentes para producción de energía eléctrica de manera limpia. Sin embargo, problemas relacionados con el panorama económico en conjunción con otros de índole tecnológica y geológica llevaron a los sistemas geotérmicos a frenar su crecimiento. El desarrollo de los sistemas geotérmicos ha sido lento y, aunque han quedado relegados frente al crecimiento que han experimentado los sistemas energéticos solares y eólicos, también se han desarrollado varios sistemas de control basados en IA.

De esta manera, la IA se ha postulado como una manera de afrontar los desafíos que se encuentran en este tipo de sistemas y las incertidumbres relacionadas con los recursos geotérmicos. Así, a modo de ejemplo, la IA emplea datos tanto de la superficie como de las capas subterráneas para poder evaluar el potencial geotérmico de una determinada ubicación. A continuación, se presentan los distintos sistemas de control basados en IA que se han desarrollado o están actualmente bajo estudio:

- **Sistemas de predicción para bombas de calor geotérmicas usando DNN y SVM.** En este caso, se emplearon redes neuronales y SVM para predecir los parámetros necesarios para las bombas de calor, a saber: las temperaturas de las capas del suelo y su conductividad térmica. Si bien los resultados fueron precisos, con un coeficiente de determinación $R^2 > 0.99$ [52], las incertidumbres asociadas al conjunto de datos de entrada para entrenar al algoritmo suponen una limitación a la hora de emplear este sistema, siendo necesario depurar estos antes de alimentar al modelo.

- **Sistemas de predicción de temperatura subterránea usando SLFNN y BPNN.** Las redes SLFNN (*Single Layer Feedforward Neural Network*) son redes de alimentación directa y de una única capa, siendo una de las configuraciones de red más simples empleadas por la IA. Al conjugar su funcionamiento con las BPNN, se obtienen redes más robustas y complejas que pueden manejar problemas no lineales, mejorando el rendimiento de la red. A la hora de predecir la temperatura subterránea con esta conjunción de redes, se consiguieron resultados bastante precisos, con un coeficiente de determinación $R^2 = 0{,}97$ y un error RMSE $\sim 1{,}41$ [53]. La desventaja de este sistema es que, durante su estudio, el conjunto de datos empleado era relativamente pequeño, lo que no lo hace apto para sistemas más complejos con grandes volúmenes de datos.

- **Sistemas de control de la eficiencia operativa de plantas usando ML.** Existe un proyecto, denominado GOOML (*Geothermal Operational Optimization with Machine Learning*) promovido por el Laboratorio Nacional de Energías Renovables (NREL) de Estados Unidos. Este persigue optimizar los sistemas de control y operatividad de los sistemas geotérmicos a partir de técnicas de Machine Learning. Para ello, emplea RF, técnicas de agrupación, *k-means* y redes neuronales, combinadas con técnicas de regresión lineal. En este caso, se realizaron predicciones sobre el valor de masa extraída con un error MAE de 7,9%. En la Figura 4.9 se muestran los resultados de la masa extraída a lo largo de 3 años comparados con los resultados de la predicción. En este caso, el coeficiente de determinación tomó un valor de $R^2 > 0{,}97$ [54].

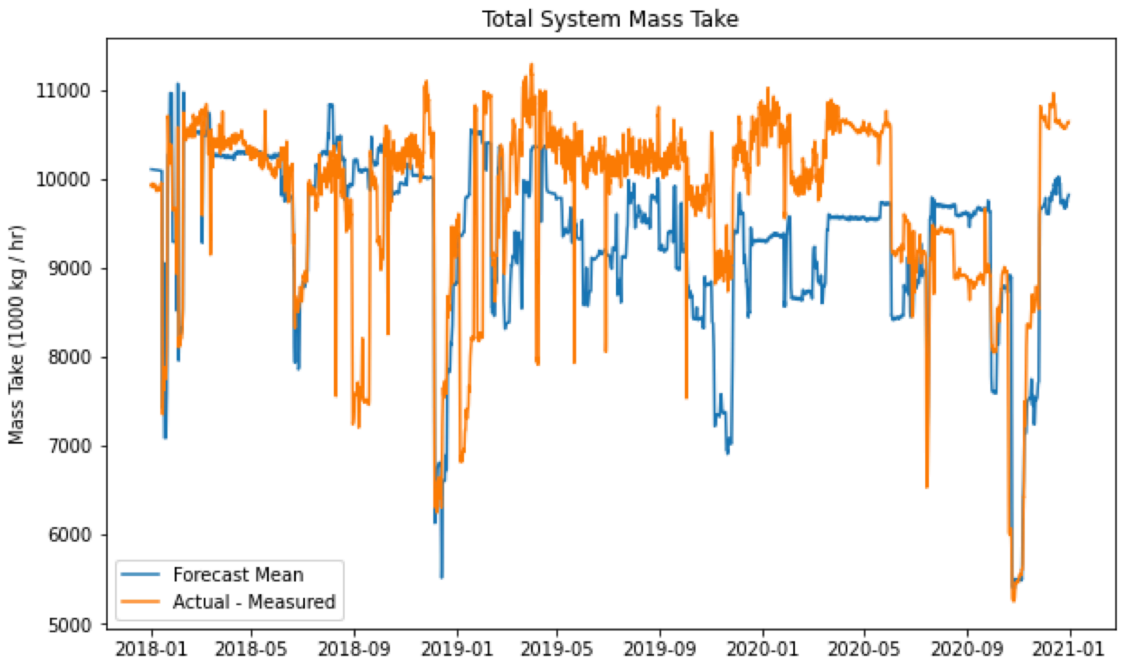


Figura 4.9 Gráfica con la medida real y predicha de la masa extraída [55]

- **Sistema basado en la optimización del sistema geotérmico usando lógica difusa.** El estudio realizado en este caso se desarrolló en Irán y empleó 5 parámetros de los sistemas energéticos, a saber: temperatura de la superficie terrestre, la litología (características físico químicas de las

rocas), características de la superficie, geomagnetismo y las fallas del terreno. En este caso, la lógica difusa sirvió para, en función de dichos parámetros, elegir las zonas potenciales para una óptima explotación geotérmica.

- **Sistema de control basado en el rendimiento de las bombas de calor geotérmicas usando ANFIS y DNN.** En este caso, conjugar ANFIS con redes neuronales profundas permitieron hacer predicciones muy precisas de los parámetros que miden el rendimiento de las bombas de calor. Concretamente, y en relación al COP (*Coefficient of Performance*) o en español, el Coeficiente de Rendimiento, de las bombas de calor, se alcanzó un valor de coeficiente de determinación de R^2 = 0,999 y un RMSE = 0,09601 [56].

4.1.3 Próximos pasos de la IA en las energías renovables

En los próximos años se espera que las energías renovables tengan una presencia predominante dentro del mix energético mundial, sirviendo como medio para descarbonizar la producción de energía eléctrica. Para poder lograr esto, el uso de tecnología innovadora y de vanguardia resulta fundamental, entre las que se incluye la IA. Existen ya ciertas tendencias que permiten prever esa integración de la IA en los sistemas de energía renovable y cómo será esta.

En primer lugar, uno de los principales campos de investigación actual en cuanto a la energía solar es el desarrollo de materiales más eficiente y diseño de células fotoeléctricas con mayor rendimiento. Para ello, la IA tiene un papel relevante a la hora de estudiar los distintos materiales posibles. Así, puede predecir sus propiedades, posibles rendimientos de cada uno función de la producción, el incremento de rendimiento que supondría cada uno y el estudio de viabilidad económica de cada solución en función de los costes y los beneficios esperados. Además, es posible también actuar sobre los materiales considerados para mejorar sus propiedades de acuerdo a las predicciones realizadas por los algoritmos de los sistemas de IA, gracias a los que se podrían fabricar materiales con mejores propiedades a nivel nano estructural.

Por otro lado, en cuanto a las tareas de mantenimiento predictivo en sistemas de energías renovables, la IA permitiría desplegar los sistemas de seguimiento y control de manera remota, a través de una nube, sin la necesidad de instalar físicamente dispositivos o sistemas tipo SCADA. Actualmente, este tipo de soluciones están siendo estudiadas, haciendo especial hincapié en desarrollar sistemas en la nube robustos y seguros ante posibles ataques de ciberseguridad.

Por último, existe un método de IA novedoso a día de hoy cuya implementación en sistemas de ER se está estudiando en la actualidad: Extreme Machine Learning (EML) para sistemas de energía solar. Este, es un tipo de aprendizaje automático que emplea redes neuronales con una única capa oculta, cuyos pesos ponderados se asignan de manera aleatoria. Supone una alternativa a las redes neuronales tradicionales por su rápido periodo de aprendizaje, su idoneidad para tratar grandes conjuntos de datos y su posibilidad de generalización a distintos tipos de sistemas. En la actualidad, el uso de EML está siendo estudiado, por ejemplo, para sistemas de energía solar en los que sea necesario completar los valores de irradiancia. Así, el uso de este modelo combinado con otros métodos matemáticos y estadísticos, permitiría reducir el tiempo de procesamiento, en comparación con el que se tendría con Machine Learning tradicional. En este caso, se han realizado pruebas experimentales en Tailandia con las que se han conseguido valores del coeficiente de determinación superiores a 0,9. Sin embargo, los resultados no son aún lo suficientemente precisos como para implantar el uso de este sistema de control, que aún debe ser refinado. Para ello, existen varias líneas de investigación abiertas enfocadas a:

- La mejora del modelo a partir de su combinación con algoritmos metaheurísticos.
- La inclusión de una segunda capa oculta para mejorar la precisión de los resultados.

- El uso de algoritmos de aprendizaje incremental de manera que, en lugar de entrenar los algoritmos una vez con el conjunto de datos inicial, realicen un aprendizaje continuo conforme le llegan nuevos datos.

En resumen, existen distintas vías de investigación para lograr una mejor integración de la IA en los sistemas de ER. Se persigue así mejorar su operatividad, eficiencia, reducir su coste y optimizar el funcionamiento de los sistemas de ER actuales, buscando una mayor precisión de los resultados y la reducción del tiempo computacional.

4.2. La IA y los sistemas de almacenamiento de energía

Los sistemas de almacenamiento de energía son aquellos destinados a conservar esta última, para usarla en un momento posterior. Los sistemas de almacenamiento de energía están estrechamente relacionados con los problemas descritos en el apartado anterior sobre la intermitencia de la energía solar o la energía eólica, permitiendo gestionar el desfase entre la oferta de la energía y la demanda de esta por parte de los consumidos. De esta manera, existen 6 formas principales de almacenar energía: sistemas de almacenamiento de energía térmica, batería, pilas de hidrógeno, volantes de inercia, supercondensadores y almacenamiento por bombeo hidroeléctrico. De estas, las dos primeras son las más destacadas en cuanto a avances en sistemas de predicción y control con IA. Por ello, se expondrán las principales técnicas de IA empleada de estas dos y cómo ha servido para optimizar su funcionamiento y rendimiento.

4.2.1 Sistemas de almacenamiento de energía térmica y su relación con la IA

Los sistemas de almacenamiento de energía térmica, TESS por sus siglas en inglés (*Thermal Energy Storage Systems*), se han estudiado y controlado hasta ahora a partir de métodos tradicionales. Por una parte, en lo relativo a su rendimiento, los estudios llevados a cabo han empleado técnicas experimentales, simulaciones numéricas y modelos físicos, normalmente representados por CFD (*Computational Fluids Dynamics*), también conocida en español como fluidodinámica computacional. Por otro lado, en lo relativo a las técnicas de control, lo más habitual ha sido el empleo de sistemas de control automático con altos tiempos computacionales que solo se centran en el estado actual y no sirven para generar instrucciones de control que permitan operar totalmente los TESS de manera precisa. De esta forma, al no sacar el máximo partido de la operatividad de este tipo de sistemas de almacenamiento, no se aprovecha todo el potencial y las ventajas que brindan a nivel de reducción de costes y ahorro energético. Así, se ha detectado la necesidad de encontrar otro tipo de tecnología o técnica que permita exprimir todo el potencial de los TESS, optimizando el funcionamiento de estos, sus técnicas de control asociadas y maximizando, por ende, su rendimiento.

De esta manera, la IA se ha postulado como una buena alternativa para diseñar y controlar este tipo de sistemas. Entre sus principales ventajas, cabe destacar que permite mejorar los resultados obtenidos a base de modelos físicos, con menos recursos computacionales y de manera más rápida. Además, puede resolver problemas de programación no lineal, pese a la existencia de incertidumbres en los datos y sin necesidad de conocer el sistema físico para que el algoritmo pueda modelar la función objetivo. Así, las técnicas de IA empleadas para los TESS se dividen en 3 pilares fundamentales: predicción del rendimiento, optimización del diseño y control operativo, de los sistemas de almacenamiento.

Técnicas para la predicción del rendimiento

El rendimiento de los TESS depende de una serie de variables cuya relación con los parámetros a predecir es no lineal, por lo que la predicción del mismo resulta una tarea compleja. Sin embargo, el uso de técnicas de IA como las redes neuronales, los sistemas ANFIS y las máquinas SVM permiten realizar este tipo de

predicciones sin la necesidad de conocer el mecanismo físico del sistema de almacenamiento, basándose solo en los conjuntos de datos de entrada que se alimentan al algoritmo para que este aprenda a predecir las salidas correctas. Con el uso de este tipo de técnicas de IA no solo se consiguen resultados precisos, sino tiempos computacionales bajos y, por ende, menor coste de operación.

Si bien los sistemas de almacenamiento de energía se denominan TESS, de ahora en adelante se hará referencia al almacenamiento de energía *per se* como TES (*Thermal Energy Storage).* De esta manera, la técnica más empleada en términos generales para la predicción del rendimiento de TES, son las redes neuronales profundas de alimentación directa (FFNN), similares a la empleada para la predicción de temperatura subterránea en la energía geotérmica, con la diferencia de que estas tienen más de una capa oculta. Este tipo, multicapa, se las alternativas más adecuadas son RNN, LSTM o NARX. Las redes NARX (*Nonlinear Autoregressive with Exogenous Inputs*), también conocidas como Redes Autoregresivas No Lineales con Entradas Exógenas, permiten trabajar con sistemas dinámicos no lineales, tomando en consideración variables externas al sistema que le puedan influir. Este tipo de redes se han usado tanto para TES de energía sensible, (STES, *Sensible Thermal Energy Storage);* de energía latente, LTES (*Latent Thermal Energy Storage*) como de energía termoquímica*,* TCES *(Thermo-chemical Energy Storage*) [57].

Algunos ejemplos del uso de redes neuronales en sistemas predictivos son los sistemas de predicción de la fracción líquida y del número de Nusselt (Nu) durante el proceso de cambio de fase en un sistema de almacenamiento PCM (Material de Cambio de Fase) con espuma metálica y aleteado, o de la fracción solar de un sistema de almacenamiento térmico solar híbrido con agua y PCM.

Por otro lado, además del rendimiento, es posible predecir las propiedades termo físicas de los materiales empleados en este tipo de almacenamientos, mejorando así su rendimiento y disminuyendo su coste, dado el tiempo que se reduce frente al uso de técnicas experimentales.

Por último, aunque no de manera tan habitual, también se emplea ANFIS y SVM para la realización de predicciones. A modo de ejemplo, para el caso de ANFIS, se desarrolló un sistema de predicción de los parámetros de diseño de una torre de energía solar con un TESS de sal fundida. Por otro lado, combinando ANFIS con SVM, la predicción del rendimiento de un colector solar de placa con un sistema de almacenamiento de PCM con decahidrato de carbonato de sodio, supone otro ejemplo de este tipo de técnica [58].

Técnicas para la optimización del diseño

La optimización del diseño de los TESS persigue mejorar tres aspectos en relación los equipos: su rendimiento, su coste y el medio ambiente. Para tal fin, los métodos de optimización se basan en dos pasos: formular la función objetivo y encontrar la solución óptima dadas las condiciones de contorno. Si bien hasta ahora se habían empleado métodos físicos, la incorporación de técnicas de IA permite alcanzar estos objetivos de forma más rápida y eficaz. En este caso, los algoritmos empleados están basados en GA y en técnicas de optimización por enjambre de partículas.

En primer lugar, los algoritmos genéticos resultan los idóneos para este caso, pues se concibieron para resolver problemas de optimización de acuerdo a procesos de selección natural y conceptos genéticos. De hecho, las técnicas de GA permiten optimizar de acuerdo a una única variable o varias de ellas, empleando en el segundo caso algoritmos NGSA-II (Algoritmo Genético de Clasificación No Dominada II).

En el caso de optimización de una variable para el diseño de TESS, los GA han servido, por ejemplo, para optimizar intercambiadores con TESS a base de PCM. En este caso, el objetivo era optimizar la disposición del circuito de agua para maximizar la temperatura del agua de salida durante la descarga. Por otro lado, y en el caso de optimizar variables múltiples, los algoritmos genéticos se suelen emplear para encontrar el frente de Pareto. A modo de ejemplo, NGSA-II se empleó en un sistema de energía solar térmica de baja temperatura, compuesto por una caldera de respaldo y un tanque de almacenamiento. Al optimizar los distintos parámetros del sistema, fue posible reducir el volumen del tanque un 10,62% en Roma y 14,01%

en Trieste, dos ciudades italianas con diferentes características climatológicas [59]. Además, para este caso, se comparó también el uso de un depósito de agua tradicional con otro de PCM, comprobando que el frente de Pareto era muy similar para ambos y, por tanto, el uso de un PCM no resultaba óptimo.

Por otro lado, se ha hecho uso también de los GA para hacer optimización de variables múltiples, pero usando una metodología diferente. En este caso, primero se realiza una optimización simple encontrando los valores principales y después, esta solución se alimenta al algoritmo como datos de partida para realizar la optimización múltiple. Esta metodología se empleó en un sistema de energía solar térmico de uso doméstico apoyado con TESS. En este caso se perseguía optimizar parámetros medio ambientales con otros de coste, consiguiendo reducir el tiempo empleado en el segundo proceso de optimización hasta un 90% al emplear como datos de partida los de la primera.

Por último, se han empleado también algoritmos genéticos para optimizar TESS, sin que este tipo de sistema fuera uno de los parámetros principales. Así, alimentando al algoritmo con los datos de almacenamiento como variables de contorno, fue posible incluir el impacto del TESS en la función objetivo. Un ejemplo de este caso es el uso de tanques de agua en sistemas microchip para edificios residenciales.

La técnica de optimización por enjambre de partículas, por otro lado, si bien no se usa de forma tan general como los GA, es un algoritmo metaheurístico empleado también para la optimización del diseño de TESS. Así, a modo de ejemplo, este tipo de algoritmo se emplea para optimizar los parámetros de diseño almacenamiento de un sistema de aire acondicionado con almacenamiento de hielo.

Técnicas de control operativo

Como se vio en el apartado 3.3.4, una de las principales ventajas de la lógica difusa es la flexibilidad que proporciona al considerar que las hipótesis puedan ser parcialmente correctas y considerar la escala de grises que hay entre 0 y 1. De esta manera, permite manejar incertidumbres, imprecisiones y variaciones en las condiciones de operación, siendo todas estas características comunes en la operación de los TESS. Este tipo de sistemas de almacenamiento están sujetos a variaciones de la meteorología y el clima, así como de la demanda de energía y otras variables cuya modelación es más compleja. Por todo esto, el uso de controladores de lógica difusa (FLC) para TESS resulta más que adecuada. Este tipo de controlador permite mejorar la robustez y adaptabilidad del sistema, al poder trabajar con aproximaciones de datos. Además, no requieren de un modelo matemático preciso para poder tomar decisiones, facilitando su implementación. Así, pueden optimizar el uso de la energía almacenada, minimizando las pérdidas de energía y mejorando la eficiencia del sistema, con el consiguiente ahorro de energía y coste. Por último, cabe destacar la flexibilidad de los controladores de lógica difusa para adaptarse a las condiciones cambiantes de este tipo de sistemas, como las variaciones en la carga o las fluctuaciones en la generación de la energía renovable que estos soportan.

Existen diferentes ejemplos de sistemas de control para TESS, como el uso de dos FLC para maximizar el uso de energía solar en un sistema de secado integrado con TESS. En este caso, el secador funcionaba con LTES, de manera que uno de los controladores permitía ajustar el caudal del aire seco procedente del panel solar y acumulador y el otro controlaba el flujo de aire de la recirculación. Por otro lado, se han usado también FLC combinados con programación lineal entera para diseñar sistemas de ER de biomasa. En este caso, se realizó un estudio para seleccionar la ubicación y la capacidad del TESS, para poder minimizar el coste y la demanda de calor no satisfecha de manera simultánea. Así, la lógica difusa permitió en este caso manejar las condiciones de contorno y restricciones no definidas completamente. Otro ejemplo del uso de FLC, se aplica en el control de la temperatura de entrada de un HTF (Fluido de transferencia de calor) en un sistema de energía solar combinado con un LTES.

A modo de resumen, se muestran las distintas técnicas empleadas para cada uno de los pilares de los TESS en la Figura 4.10:

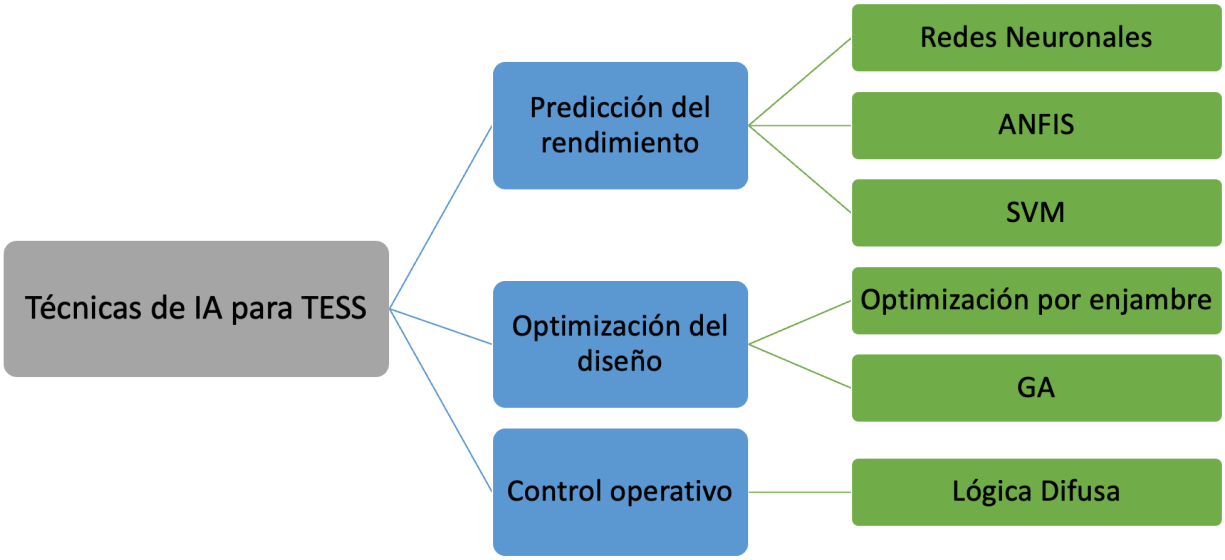


Figura 4.10 Técnicas de IA para TESS

4.2.2 Baterías y su relación con la IA

Las baterías recargables resultan fundamentales en el ámbito del almacenamiento de energía por varias razones. Por una parte, permiten el almacenamiento de energía renovable, permitiendo así solventar los problemas de intermitencia de varias de estas. Así, la energía se almacena en los momentos de alta producción, pero baja demanda, para ser consumida cuando sea necesaria. Esto permite aumentar la eficiencia y reducir los desperdicios de energía. Además, como consecuencia de esta primera ventaja, resulta posible reducir la dependencia de los combustibles fósiles, facilitando por tanto la transición que se comentaba en el apartado 2. Por otro lado, y como parte de dicha transición, las baterías recargables son vitales para los vehículos eléctricos (VE), pues permiten realizar ciclos de carga y almacenar la energía necesaria para el coche, reduciendo las emisiones de CO_2. Por último, y pese al alto coste de inversión que supone una batería recargable, estas se amortizan a largo plazo y sirven, además, de respaldo energético en situaciones de crisis.

De esta manera, las baterías recargables suponen una pieza clave dentro de la transición energética y la reducción de combustibles fósiles, la movilidad eléctrica y le eficiencia energética. Sin embargo, los métodos tradicionales tanto experimentales como de simulación han resultado hasta ahora insuficientes en este ámbito, presentando limitaciones tanto de tiempo como de recursos. Dado que el rendimiento de las baterías recargables actuales no es suficiente para satisfacer las demandas del mercado, es necesario aplicar otras técnicas que permitan mejorar este.

Gracias a la IA y, en particular, a las técnicas propias de Machine Learning para el análisis de datos, ha sido posible avanzar en este campo, ayudando a predecir los principales parámetros de las baterías, así como su estado de carga o su estado de salud; o detectando nuevos materiales que puedan aumentar su rendimiento.

Se pueden distinguir dos fases sobre los que actuar en el caso de las baterías recargables: el momento de su diseño, pudiendo actuar sobre los materiales empleados y sus propiedades; o sobre su vida útil, tomando acciones sobre su estado de carga, estado de salud y ciclo vida. Así, se distinguirán las dos fases para analizar qué uso se hace de la IA en cada una de ellas.

- Diseño de las baterías recargables: materiales y propiedades.

  Las baterías recargables están formadas por un ánodo, un cátodo y electrolito. El funcionamiento de los dos primeros varía en función del momento de uso de la batería, así durante el proceso de

descarga el ánodo libera los electrodos al circuito externo con la oxidación, y el cátodo realiza el proceso de reducción, recibiendo los electrodos del ánodo. Sin embargo, durante el proceso de carga, el funcionamiento es al contrario. Por otro lado, tanto en uno como en otro, el electrolito es el encargado de mover los iones entre el ánodo y el cátodo y viceversa. En función de los materiales empleados para estas tres partes, se obtendrá un mejor funcionamiento, dada la influencia del material en su capacidad, eficiencia, ciclo de vida, velocidad de carga y seguridad. Concretamente para el electrolito, el material elegido es de vital importancia, dado que será clave para el óptimo transporte de los iones. Los electrones líquidos, por una parte, tienen una alta conductividad; mientras que los sólidos, si bien tienen una conductividad menor, presentan una mayor seguridad en lo relativo a volatibilidad e inflamabilidad.

De esta manera, el uso de técnicas de Machine Learning permite seleccionar los materiales adecuados, predecir las propiedades de estos y optimizar los parámetros experimentales de los nuevos materiales ahora bajo estudio, especialmente para el caso de los electrolitos. Los electrolitos líquidos, por una parte, se encuentran aún en una etapa temprana en el estudio de uso de algoritmos de Machine Learning. Los principales estudios se centran en la selección de los aditivos que pueden mejorar el transporte de iones, empleándose técnicas de regresión lineal múltiple, método LASSO y procesos gaussianos. En el caso de los electrolitos sólidos, por otro lado, los estudios se centran en polímeros orgánicos e inorgánicos. En el caso de los electrolitos poliméricos orgánicos, se emplean redes CNN para mejorar la eficiencia y precisión en la predicción de propiedades como la conductividad eléctrica. Además, sirven para detectar espacios poliméricos amorfos, logrando una precisión comparable a la de los resultados de las simulaciones de dinámica molecular, pero con un tiempo de simulación más bajo. Para los polímeros inorgánicos, se emplean también redes CNN, así como algoritmos de agrupación, *k-means* y SVM para analizar conjuntos de datos formados por un gran número de variables y clasificarlos.

Por otro lado, es también habitual el uso de técnicas de aprendizaje generativo (IA generativa) y técnicas de aprendizaje no supervisado para la optimización de nuevos materiales. Por una parte, la IA generativa, emplea GAN y autocodificadores para generar nuevos puntos de datos. Esto permite realizar combinaciones con estos para descubrir configuraciones de nuevos materiales con mayor densidad de energía, mayor vida útil y más seguros. Además, la IA generativa permite también realizar simulaciones con compuestos químicos nuevos para predecir sus propiedades electroquímicas, como su voltaje o su capacidad. Esto permite acelerar el descubrimiento de nuevos materiales además de optimizar el uso de los ya existentes.

Por último, en cuanto al aprendizaje no supervisado, este permite identificar patrones y correlaciones en grandes volúmenes de datos sobre las propiedades químicas de los materiales, reduciendo la dimensionalidad de los mismos a conjuntos más simples y de más fácil interpretación. Empleando, a su vez, técnicas de agrupación, es posible categorizar dichas propiedades estableciendo patrones en los distintos materiales de acuerdo a sus parecidos y diferencias en rendimiento. Esto, si bien puede parecer trivial, resulta de gran interés, pues la relación existente entre el material de las baterías y el rendimiento de las mismas es complejo y no lineal.

- Funcionamiento de las baterías recargables.

  En este caso, las técnicas de IA se centran en la operación de las baterías, siendo habitual el uso de técnicas de aprendizaje supervisado. El aprendizaje supervisado, que se alimenta con datos etiquetados para hacer predicciones o clasificaciones, permite optimizar los sistemas de gestión de baterías, por sus siglas en inglés BMS (*Battery Management System*). El objetivo de BMS es asegurar la correcta operación de las baterías, mejorando su estabilidad y seguridad a través de

actividades de monitoreo, protección y control. El objetivo, en este caso, es conseguir sistemas de BMS inteligentes que eliminen las limitaciones del BMS tradicional. Para ello, se aplican técnicas de IA en dos de los componentes principales de BMS: el estado de carga de la batería SOC (*State of Charge*) y el estado de salud de la batería SOH (*State of Health*).

El SOC de la batería es un método de evaluación de la batería que se suele expresar como un porcentaje sobre la cantidad de energía restante disponible. Este método está destinado a evitar la sobrecarga y la sobre descarga, para evitar daños en la batería. Para mejorar este, se suelen emplear redes neuronales, regresión de procesos gaussianos, SVM y árboles de decisión. Entre estos, cabe destacar el SVM por su capacidad para generalizar problemas de clasificación (usando técnicas de aprendizaje supervisado con datos etiquetados). Por otro lado, se han realizado también estudios empleando LTSM, CNN, *boosting*, BPNN y RBFNN para realizar predicciones de SOC.

El SOH, por último, indica si hay cambios en la capacidad de almacenamiento de la batería, debido a desgaste por el paso del tiempo o daños físicos. En este caso, también se han empleado técnicas de IA para predecir el SOH, como CNN, RF, SVM y algoritmos genéticos, entre otros. Además, al igual que para el SOC, los datos empleados para entrenar a los algoritmos pueden ser tanto experimentales como computacionales, siendo además muy parecidos en un caso y otro el tipo de datos necesarios de entrada.

A modo de resumen, se esquematizan las dos categorías dentro de las baterías recargables y las técnicas de IA empleadas en cada una de ellas (Figura 4.11):

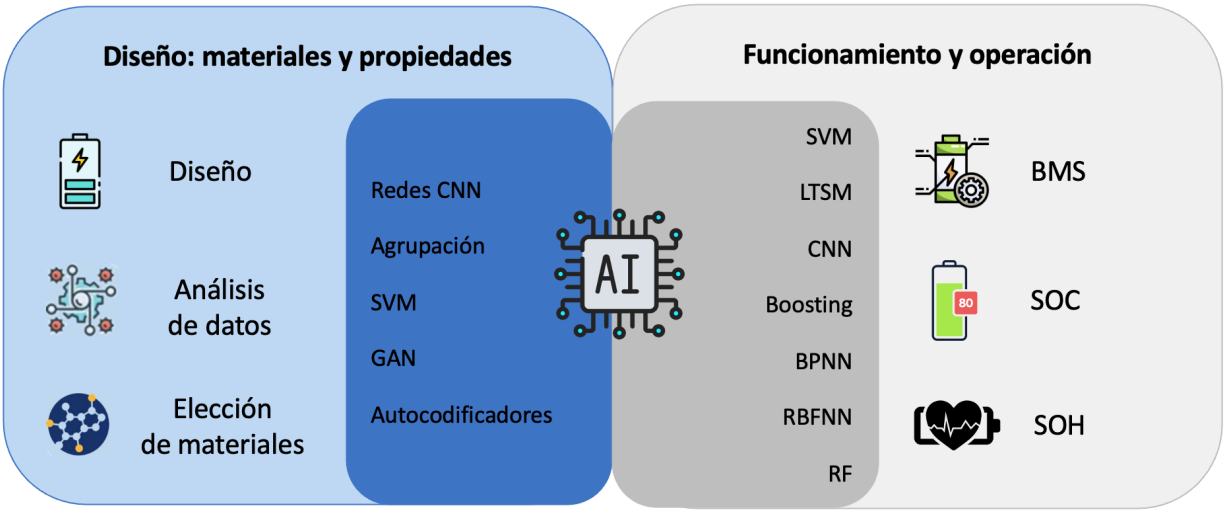


Figura 4.11 Tipos de aprendizaje de IA empleadas para las baterías recargables

4.3. La IA y el confort térmico en edificios

A día de hoy, dentro del total de la energía producida a nivel mundial, el consumo energético de los edificios representa el 40% [60]. De ese porcentaje, buena parte de la energía consumida está destinada a conseguir confort térmico. Debido al cambio climático, y pese a las medidas descritas en el apartado 2, el año 2023 ha sido registrado como el año más caluroso en la historia de la Tierra, con un aumento de temperatura de 1,48 ºC [61]. De esta manera, y con las temperaturas medias actuales, conseguir un buen confort térmico resulta crucial para preservar la salud y el bienestar de las personas, así como su productividad. Por esto, la Organización Mundial de la Salud (OMS) ha establecido unas directrices mínimas sobre los sistemas HVAC (*Heat, Ventilation and Air Conditioning),* o en español Calefacción, Ventilación y Aire Acondicionado. Así, se exige una ventilación de 10 litros por persona para espacios interiores y una temperatura interior de entre 18 y 24 ºC para mantener el confort térmico.

En la actualidad, y en aras de conseguir dicho confort, grandes potencias mundiales como Estados Unidos o Japón tienen integrados en la mayoría de sus edificios sistemas HVAC, impactando por tanto la demanda máxima de energía. Sin embargo, según la AIE, otros países con un menor número de sistemas de climatización instalados aumentarán su consumo eléctrico en un 45% para 2050 [62]. Esto, a modo de ejemplo, refleja la importancia de conseguir sistemas de climatización energéticamente eficientes, que minimicen el consumo de energía y sus pérdidas sin comprometer las condiciones de confort. Así, ser capaz de reducir el consumo energético a la par que se mantienen condiciones de confort supone un problema de optimización que ha venido tratando con métodos tradicionales.

Por una parte, a la hora de evaluar si unas determinadas condiciones eran o no de confort, se ha empleado el método de opinión media estimada, más conocida como PMV (*Predicted Mean Vote*). Este, se basa en evaluar el confort térmico en base a la temperatura del aire, temperatura radiante, humedad relativa, calidad del aire y a dos parámetros personales: la actividad y la indumentaria. Sin embargo, si bien se ha empleado en diferentes estándares como EN ISO 7730 o CEN CR 1752, no resulta del todo fiable debido a la subjetividad de su proceso. Por otro lado, y de cara a controlar las condiciones del local, se han venido empleando métodos de control tradicionales como pueden ser controladores ON/OFF, controladores PI (Proporcional Integral) o PID (Proporcional Integral Derivativo). Estos sistemas, si bien han permitido reducir parcialmente el consumo de energía, suelen ser imprecisos y superar los valores del termostato, generando así desperdicios de energía. Por todo esto, se plantea como solución el uso de IA para poder optimizar el consumo de energía frente a los parámetros de confort.

Durante las últimas décadas se comenzó ya a emplear la IA para lograr alcanzar el equilibrio entre el consumo y el confort. En la década de los 90, por ejemplo, se empezaron a usar algoritmos evolutivos para optimizar el uso de los controladores. Además, se han usado también redes neuronales y técnicas de lógica difusa para tratar de mejorar la eficiencia energética. Sin embargo, si bien constituían ya los primeros pasos hacia un control inteligente de los sistemas de climatización, su uso era aún algo aislado.

De esta forma, el estudio e investigación de este tipo de tecnología ha incrementado a lo largo de los últimos años. El objetivo de la IA, por tanto, es el de conseguir edificios inteligentes que puedan ajustar la temperatura, la ventilación, así como otros parámetros para lograr un consumo de energía óptimo sin romper el confort térmico de los usuarios. Además, este tipo de sistemas permite, no solo controlar estos parámetros en tiempo real, sino también contar con las preferencias de los usuarios a nivel histórico como parte del aprendizaje del algoritmo.

A continuación, se exponen las principales técnicas de control basadas en IA para el control térmico de edificios, así como los sistemas predictivos de fallo de este tipo de instalaciones, quedando fuera del alcance de este documento las etapas de diseño y construcción de los edificios y los consumos energéticos asociados a esas fases.

4.3.1 Sistemas de control para la operación de HVAC

A lo largo del ciclo de vida útil de un edificio, si bien se han mencionado etapas previas como el diseño o la fabricación, la etapa de operación y mantenimiento es la más extensa en el tiempo, hasta el desmantelamiento del mismo. Así, de toda la energía consumida a lo largo de dicho ciclo, en el periodo de operación se consume hasta un 90% de dicho total [17]. Por ello, y dado el peso de los sistemas HVAC en dicho porcentaje, resulta de especial importancia la eficiencia energética de estos durante dicha fase.

Como se ha comentado anteriormente, si bien los controladores PI y PID son más sencillos y fáciles de implementar, tienen un rendimiento peor que los inteligentes cuando se trata de procesos dinámicos y con variables no lineales. Si bien hay cierta unanimidad en este sentido, el estudio y aplicación de los controladores inteligentes para sistemas de control y monitorización de confort térmico no está del todo

maduro. Existen numerosos artículos de investigación sobre control de edificios y confort térmico, por separado, pero no son tantos los que aúnan ambos conceptos empleando IA, siendo aún necesaria más investigación y análisis de los resultados experimentales del uso de este tipo de controladores una vez implementados para verificar su rendimiento. De esta forma, se exponen a continuación los principales sistemas de monitoreo y control estudiados a día de hoy, aún no siendo un alto número los integrados totalmente en el control de los edificios y contando con margen de mejora.

- Sistemas de control predictivos.

Los sistemas de control predictivos son los que emplean MPC (*Model Predictive Control*), es decir, basan sus predicciones en modelos matemáticos. A diferencia de los controladores tradicionales comentados anteriormente como el PID, los MPC no ajustan su salida solo en base a los errores actuales, sino que realizan predicciones a futuro de acuerdo a los objetivos y condiciones de contorno a largo plazo.

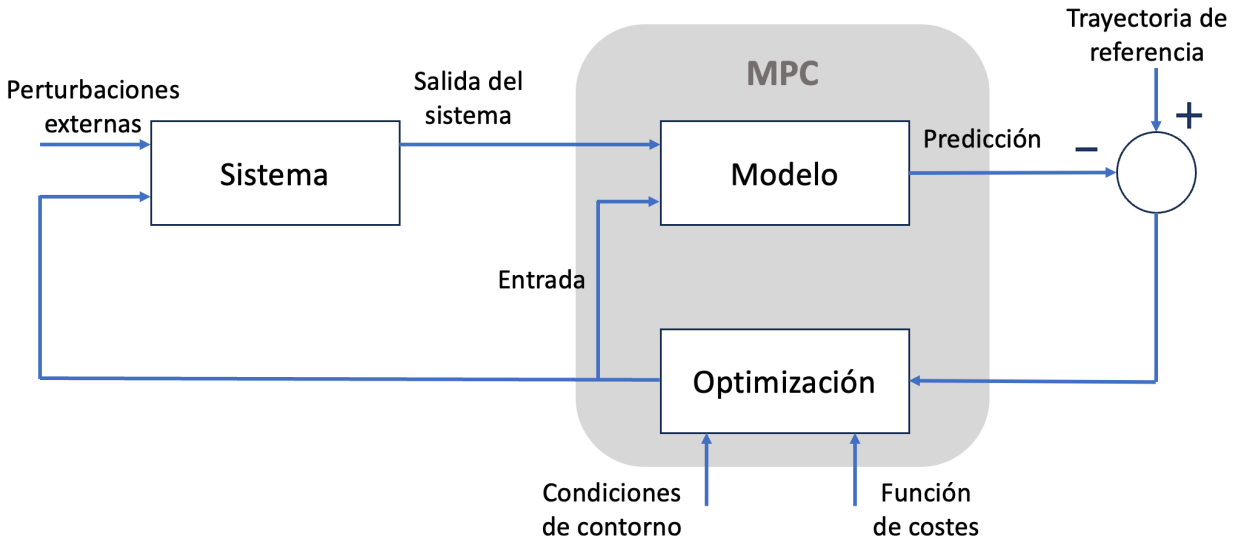


Figura 4.12 Diagrama de funcionamiento de MPC

De esta forma, se usan en el control de sistemas HVAC para mejorar el confort a la par que se reducen costes, resultando especialmente adecuados pues tienen en cuenta no solo las condiciones del sistema como la temperatura, humedad o calidad del aire, sino que pueden integrar otros parámetros variables como las condiciones climáticas o la ocupación. Además, este tipo de controlador se integra habitualmente con técnicas de IA que logran mejorar su funcionamiento. Así, a nivel del modelo, este se puede crear o mejorar gracias a distintas técnicas de Machine Learning. Por otro lado, y en los relativo a la optimización, esta se puede también mejorar a través de GA, optimización por enjambre de partículas o modelos metaheurísticos, lo que resulta de especial interés para este tipo de sistemas en los que no solo hay una variable a optimizar, sino que existen múltiples variables que entran en conflicto. Por último, la integración de IA permite a los modelos MPC una mayor capacidad de adaptación y flexibilidad en tiempo real, así como una mayor precisión en sus predicciones. Así sería posible, por tanto, que el propio sistema aprendiera a predecir la variación de la ocupación y combinarlo con información sobre el clima o el uso de la energía para así actuar sobre el sistema HVAC y garantizar el confort con un menor gasto de energía.

De esta manera, existe una sinergia entre los modelos MPC y la IA que hace posible conseguir sistemas más precisos y con una mayor complejidad, que hagan viable optimizar el consumo de energía a la par que el confort térmico. Así, son diversos los estudios e investigaciones que integran ambos, para conseguir este objetivo. Se destacan a continuación varios de ellos:

Por una parte, se estudió el control predictivo combinado con el uso de redes neuronales en comparación con otros métodos no predictivos para edificios de uso no residencial. En primer lugar, se realizó la

comparación de este método híbrido con uno tradicional que se limitaba a mantener el funcionamiento del sistema HVAC en modo continuo. En este caso de obtuvo, para el sistema combinado, un ahorro de energía de entre 20 y 140,5 Wh/día m². En segundo lugar, se comparó este con un sistema cuyo funcionamiento dependía exclusivamente del nivel de ocupación. En este caso, el ahorro de energía se encontraba entre 6,4 y 82,3 Wh/día m², ambos tanto para modo invierno y modo verano [63]. Además, y en el caso de las redes neuronales, existe otro estudio en el que se compara el uso de estas frente a otros MPC empleando distintas técnicas de Machine Learning, obteniendo un ahorro de energía de hasta el 46% con el uso de redes [64].Por otro lado, el uso de MPC se ha combinado también con redes RBFNN durante un estudio en un edificio de uso universitario. En este caso, el ahorro de energía alcanzó el 50%, manteniendo a su vez el confort térmico de los ocupantes [65]. Por último, y en el caso de edificios de oficinas, se estudió la predicción de la carga de enfriamiento a partir de este tipo de sistemas combinados, así como se empleó también para la predicción del nivel de ocupación de acuerdo a los cambios de luz, humedad o del nivel de CO_2, captado a través del uso de sensores que alimentan los datos como entrada al algoritmo de IA.

De esta manera, el uso de MPC combinados con métodos de IA como las redes neuronales, está ya investigado por diversos autores y se ha comprobado que supone una reducción de los costes de operación de entre el 9,1 y el 14,6% [66]. Sin embargo, sigue siendo necesario un mayor número de estudios que comprueben su funcionamiento a largo plazo y su rendimiento una vez implantados.

- Sistemas de control por lógica difusa.

Este tipo de sistema de control, ya comentado en las técnicas de control operativo para los TESS, es ideal para situaciones en las que no se conocen modelos matemáticos precisos y variables no lineales. De esta manera, las principales ventajas de usar FLC para sistemas HVAC son las siguiente:

  - Los FLC permiten controlar sistemas en los la información no es del todo precisa. Dado que los sistemas HVAC trabajan con condiciones variables y difíciles de modelar, el uso de este tipo controlador permite tener en cuenta las variaciones de la temperatura exterior, los niveles de ocupación o la humedad de manera flexible.

  - El tipo de respuesta que generan los FLC se caracteriza por dos rasgos ideales para su uso con sistemas HVAC. Por una parte, la salida se va actualizando en tiempo real gracias al *feedback* aportado por los usuarios, aportando un dinamismo y una flexibilidad ideal para el confort térmico de los ocupantes. Por otro lado, las variaciones de esta respuesta en tiempo real se realizan de forma continua y gradual, sin cambios bruscos que puedan afectar al confort térmico, ya sea por temperatura o por el ruido de los sistemas al aumentar revoluciones o parar de manera repentina. Además, la rápida capacidad de adaptación en del sistema a las condiciones cambiantes permiten conseguir una eficiencia energética superior a la que se alcanzarían con controladores tradicionales, tipo PID.

  - Este tipo de controlador, si bien es capaz de adaptar de manera gradual el funcionamiento del sistema a las necesidades, permite también gestionar el encendido y apagado de los equipos para conseguir ahorros energéticos cuando sea posible. Por último, y para lograr este tipo de funcionamiento, consideran no solo una variable, sino varias de manera simultánea, tomando decisiones por tanto de acuerdo a un conjunto de factores que permiten equilibrar la relación entre confort térmico y consumo energético de manera óptima.

De esta manera, y de acuerdo a lo expuesto en el apartado 3.3.4, la arquitectura de un FLC se corresponde con los principales elementos de un sistema de lógica difusa, a saber: fuzzificación, base de reglas, motor de inferencia y defuzzificación. Así, el módulo de fuzzificación recibe los datos medidos por los sensores respecto a las variables de su entorno, junto con el error, que es la diferencia entre el valor deseado (preciso)

y el medido por los sensores. Una vez en el módulo de fuzzificación, estos valores se convierten en difusos. A modo de ejemplo, si lo que mide el sensor es una temperatura deseada con un valor de 18 ºC, el fuzzificador traduce ese valor preciso a uno del tipo de "temperatura fresca" dentro de un conjunto de valores difusos. Una vez realizada esta transformación, el motor de inferencia aplica la base de reglas para generar otras salidas, también difusas. Así, y para este ejemplo, traduce la información difusa sobre la temperatura a una salida difusa sobre el funcionamiento del sistema, como puede ser la velocidad del ventilador o el caudal de aire de impulsión. A continuación, el módulo de defuzzificación traduce esta salida a un valor preciso para ajustar el parámetro de operación del sistema HVAC. De esta forma, los controladores FLC logran un confort térmico óptimo mientras reducen el consumo de la energía.

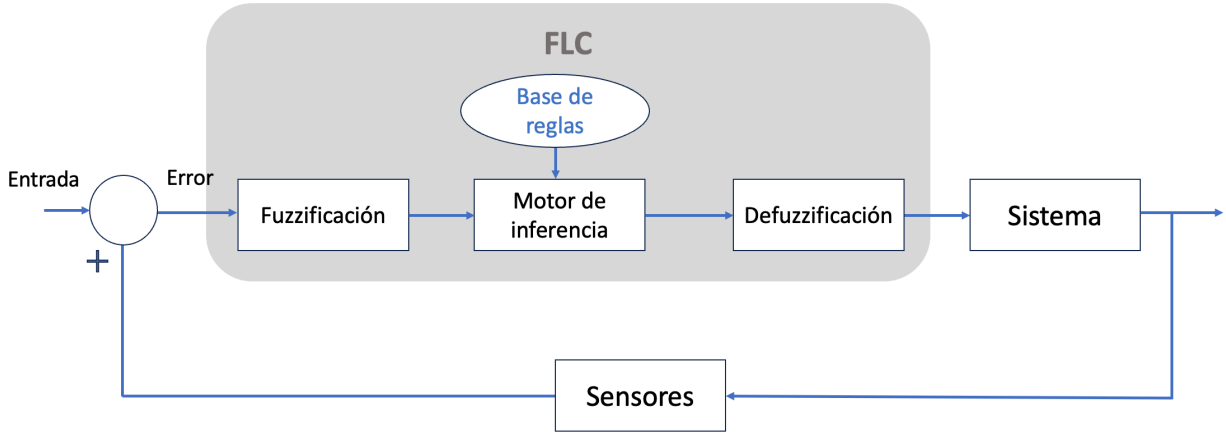


Figura 4.13 Diagrama de funcionamiento de FLC

Existen también estudios en los que se investiga el uso de este tipo de controlador, así como su rendimiento, frente a otros tradicionales. A modo de ejemplo, se realizó un estudio para comparar el consumo de un sistema HVAC en ambos casos, comprobándose un rendimiento mejor en el caso del de lógica difusa. Además, al comparar el uso de este tipo de controlador con otro de tipo ON/OFF se comprobó una reducción del consumo de energía del 16,1 % en verano y del 18,1 % en invierno usando el primero [67].

Otro ejemplo es el uso de redes neuronales en conjunción con controladores difusos para controlar la temperatura de aire interior. En este caso, el estudio se basaba en el uso de una red neuronal NARX para predecir la temperatura que después se alimentaba al controlador, con el objetivo de gestionar tanto el apagado o encendido del equipo como la velocidad del aire de impulsión. A la hora de analizar los resultados, la aproximación de la red se consideró adecuada, así como los resultados de regulación de velocidad del aire. Además, el controlador FLC puedo aprender gracias a la retroalimentación del sistema con las preferencias de los ocupantes. Sin embargo, no se cuantificó ahorro de energía asociado a la mejora de rendimiento.

- Sistemas de control adaptativos

Por último, existe un tipo de control denominado "adaptativo" que se ajusta a los parámetros del sistema que sean variables. De esta manera, y al contario que los modelos predictivos, no se basan en un modelo fijo para realizar predicciones, sino que se va ajustando en tiempo real de acuerdo a los cambios del sistema

Al combinar el control adaptativo con las técnicas de IA se consigue que los ajustes realizados en tiempo real sean a su vez inteligentes. Para ello, y así optimizar el rendimiento del sistema se suelen emplear técnicas de Machine Learning como el aprendizaje por refuerzo. Sin embargo, el principal inconveniente de este tipo de sistemas es que, si bien permiten optimizar el confort energético respecto a otros sistemas de control tradicionales, no aseguran una disminución del consumo de energía. Si bien es un tipo de control

prometedor y digo de mención en este apartado, actualmente no suponen una solución adecuada para alcanzar el punto óptimo entre confort térmico de los ocupantes y eficiencia energética.

4.3.2 Sistemas de control para el mantenimiento predictivo de HVAC

En cuanto al mantenimiento predictivo de los equipos de HVAC se emplean unos sistemas de control basados en la detección y diagnóstico de fallos, más conocido como FDD por sus siglas en inglés (*Fault Detection and Diagnosis*). Estos, permiten identificar fallos en este tipo de sistemas en etapas tempranas, antes de que desemboquen en una avería de mayor envergadura. De esta forma, permiten monitorear el funcionamiento de los equipos de manera continua para detectar anomalías respecto al funcionamiento estándar esperado. El uso de este tipo de sistema de control permite mejorar la eficiencia de los equipos, pues ciertos fallos pueden desembocar en el desperdicio de energía y, gracias a su detección temprana, hacer un mejor uso de esta. Por otro lado, reducen los costes de las tareas de mantenimiento a la par que alargan la vida útil de los equipos. Esto se debe, precisamente, a la detección temprana de los errores, pues permite actuar en un momento en el que la avería aún no se ha producido y es posible tomar medidas antes de proceder a hacer reparaciones, evitando así el sobrecoste de esta. Por último, los sistemas FDD permiten también mejorar el confort de los ocupantes, gracias al correcto funcionamiento de los equipos de acuerdo a los parámetros y las necesidades establecidas. De esta manera, y de la misma manera que era el principal objetivo de los sistemas de control durante la operación, los FDD resultan de vital importancia para alcanzar el objetivo de mantener el confort térmico de los ocupantes junto con una disminución del consumo de energía, alcanzando eficiencia energética. De ahí, la importancia de este tipo de sistemas y la relevancia de estos para ser también incluidos en este apartado.

Para detectar estos fallos con antelación, los sistemas FDD emplean algoritmos y técnicas, como el aprendizaje automático, así como otras técnicas propias de la IA. Además, existen otros sistemas que, en lugar de usar IA se basan modelos físicos tradicionales. A modo de resumen, se esquematizan los tipos de técnicas empleadas en los FDD en la Figura 4.14

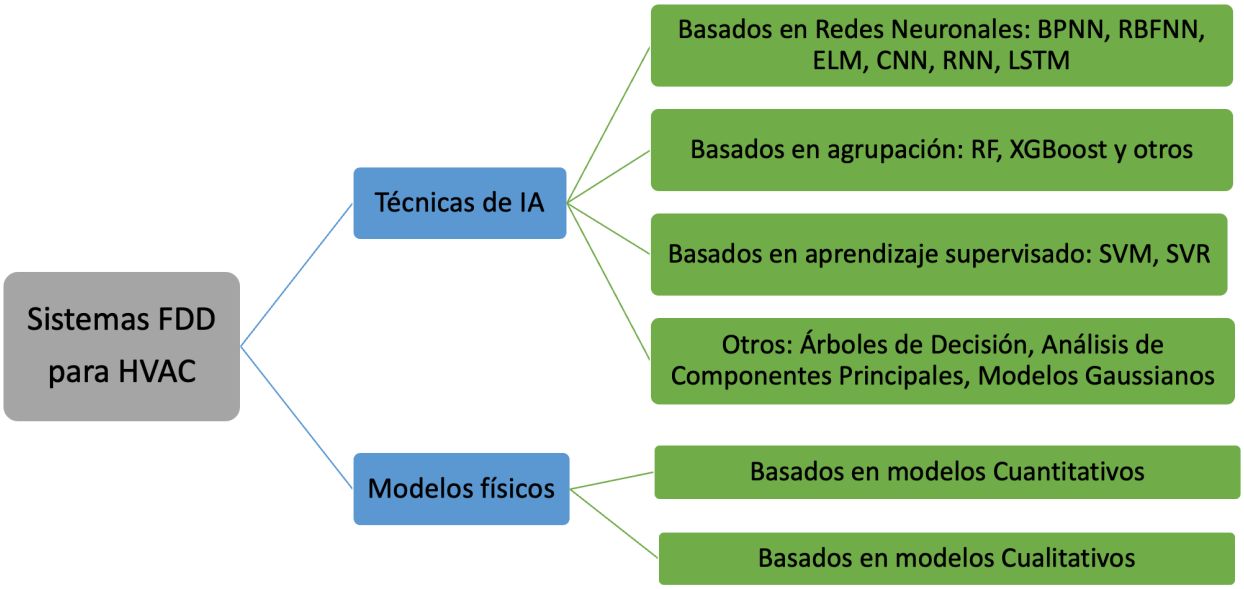


Figura 4.14 Sistemas FDD para HVAC

En lo relativo a las técnicas de IA empleadas, se comentan a continuación algunas de ellas:

En primer lugar aparecen las redes neuronales, destacando las CNN, RNN, LSTM, BPNN, RBFN y ELM. En este caso, las redes neuronales suponen una solución más compleja y completa que otras técnicas de

Machine Learning como las máquinas de Boltzmann (DBM), preferibles por su adaptabilidad y sus capacidades de ajuste de funciones. De entre las redes mencionadas, las recurrentes y las convolucionales son las más empleadas en los últimos años para los sistemas FDD, gracias a su alto rendimiento para tareas específicas, frente a las DBM. Si bien no son la mejor solución cuando el volumen de datos a tratar es reducido, suponen una buena solución a largo plazo dada la tendencia que se está experimentando hacia grandes conjuntos de datos en el desarrollo de la tecnología *Big Data*. De esta manera, las DBM, si bien son más sencillas no estarían tan preparadas como las redes neuronales para manejar grandes conjuntos de datos.

En el caso de las redes RNN, se encontraron ciertos problemas para que pudieran retener información durante largo periodos de tiempo, algo necesario para la gestión del histórico de fallos a largo plazo en los sistemas FDD. De esta forma, y para mejorar su funcionamiento, se combinó su uso con el de las LSTM, solucionando así la problemática en este tipo de casos, siendo más empleadas estas que las RNN simples para este tipo de sistemas. Además, existen también estudios que han combinado el uso de redes LSTM con otras técnicas de IA, como los algoritmos GA, para poder entrenar y optimizar el modelo y encontrar una arquitectura de red neuronal óptima. Así, este tipo de redes se emplean en sistemas VRF (Sistemas de Refrigerante Variable), UTA (Unidad de Tratamiento de Aire) y enfriadoras.

Para las redes CNN, por otro lado, se han empleado tanto redes en una como en dos dimensiones. En el caso de las redes de una dimensión, el número de parámetros necesarios es menor que para las de dos dimensiones, implicando por tanto menos cálculos y menos entrenamiento en el primer caso. Sin embargo, para las de dos dimensiones, una vez los datos se transforman de una a dos dimensiones, es posible capturar una mayor cantidad de datos. De esta manera, se han realizado estudios para sistemas HVAC, UTAs y enfriadoras tanto para redes de una como de dos dimensiones.

Además, se han empleado también redes BPNN dada su capacidad para aprender de relaciones no lineales, lo que es idóneo para la detección de diagnóstico de fallos, por ser una tipología de problema complejo en el que no tienen por qué producirse patrones y relaciones lineales. Las redes RBFN, por otro lado, se han usado también en los sistemas FDD en los casos en los que se podía emplear un sistema más simple y rápido, con diversos mínimos locales. Así, y para las RBFN, se han combinado estas también con otras técnicas como algoritmos GA para mejorar su funcionamiento en el caso de sistemas más complejos.

Por otro lado, y para las máquinas SVM, estas son capaces de clasificar los modelos de manera precisa, así como realizar tareas de generalización, mientras que las redes neuronales no permiten realizar estos dos tipos de tareas de manera equilibrada. Este tipo de técnica se suele emplear en UTAS y enfriadoras, combinando en algunas ocasiones esta técnica con el uso de métodos de análisis de datos basados en *Big Data* para mejorar el rendimiento.

Por último, y para comparar las técnicas de IA por las basadas en modelos físicos, es necesario primero detallar los tipos de modelos físicos empleados para los sistemas FDD. Por una parte, están los basados en modelos cuantitativos y, por otro lado, los basados en modelos cualitativos. En ambos casos, se comparan datos frutos de la predicción con los deseados, para después analizar la comparativa entre ambos una vez se han recopilado. La diferencia entre ambos es la manera en la que se predicen los datos, usando un modelo de referencia del sistema basados en un criterio cuantitativo o cualitativo, respectivamente. De esta forma, al comparar estos métodos con las técnicas de IA descritas con anterioridad, los modelos físicos han presentado una menor precisión y una mayor dependencia del conocimiento de expertos, especialmente en el caso de los cualitativos. Así, si bien los FDD que emplean técnicas de IA han arrojado mejores resultados en cuanto a rendimiento, aún necesitan un mayor estudio y desarrollo para entornos dinámicos y situaciones no lineales, que aún no permiten usar este tipo de técnicas de manera generalizada para la detección y diagnóstico de fallos de los sistemas HVAC.

4.4. La IA y las Smart Grid

En los apartados anteriores se ha visto el uso de la IA para gestionar y controlar sistemas de energía renovable, como la solar, eólica o geotérmica; el uso para los sistemas de almacenamiento de energía y para los sistemas de climatización. Pues bien, la gestión eficiente y sostenible de la energía, desde su generación hasta su consumo, pasando por su almacenamiento y distribución se conoce como "Smart Energy". Esta, integrando técnicas de IA en su desarrollo, permite optimizar el uso de los recursos a lo largo de todas esas etapas de gestión energética, reduciendo los costes y los desperdicios de energía. El uso de Smart Energy permite una transición energética óptima, consiguiendo un panorama energético más robusto, limpio, inteligente y descarbonizado.

Por otro lado, las Smart Grids, también conocidas en español como redes inteligentes, son otro pilar fundamental dentro de la transición energética. Esta, al contrario que la red eléctrica convencional, permite que la electricidad circule de forma bidireccional de forma que los consumidores se pueden convertir también en productores de energía (Figura 4.15). De esta manera, permiten equilibrar los desequilibrios que se producen entre la oferta y la demanda de energía a lo largo del día. Esto, supone una modernización de la red eléctrica, gracias a la integración de tecnologías digitales e innovadoras, como la IA, convirtiéndose en una pieza clave dentro de la transición energética.

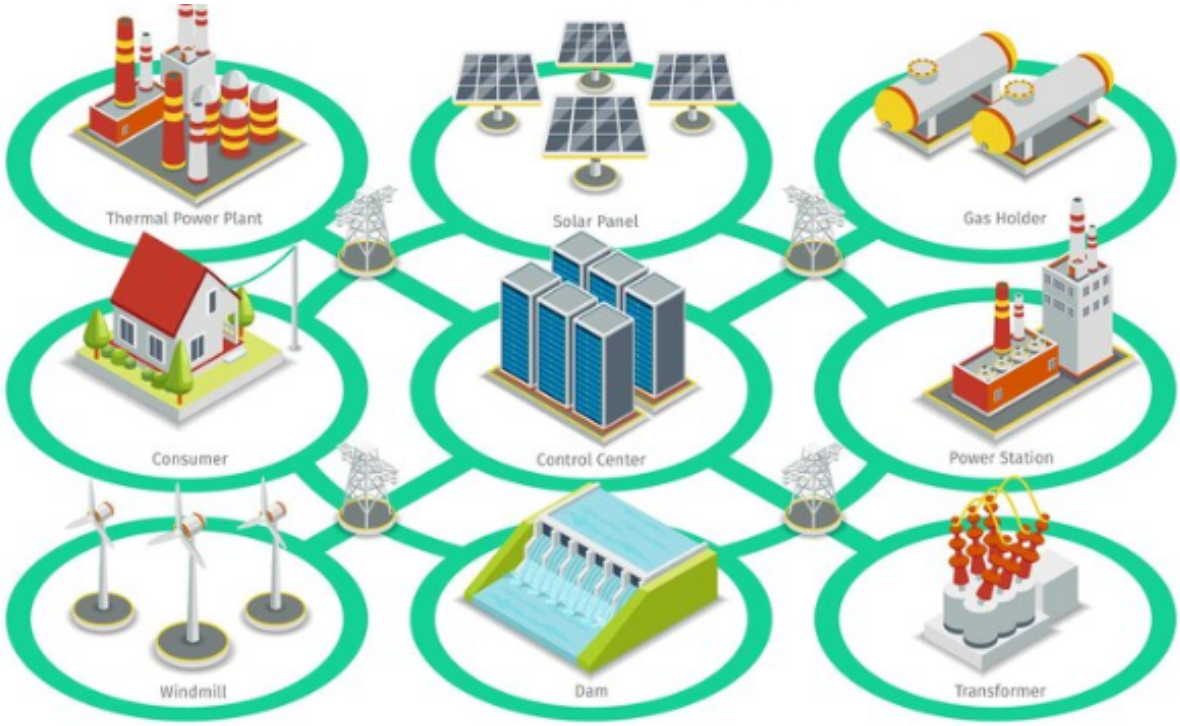


Figura 4.15 Esquema de ejemplo de Smart Grid [68]

Al unir ambos conceptos, Smart Energy y Smart Grid, resulta inevitable encontrar similitudes. Así, ambas están estrechamente relacionadas, pues persiguen la eficiencia energética a través del uso inteligente y sostenible de los recursos, a partir de tecnología de vanguardia. Las Smart Grids, en este caso, son un componente dentro de la estrategia Smart Energy, que se centra principalmente en la infraestructura de la red eléctrica. Si bien ambas persiguen optimizar los recursos e integrar las energías renovables, la estrategia Smart Energy se basa en los datos que se recogen en las Smart Grids para poder hacer un uso inteligente de la energía. De esta manera, el uso de técnicas de IA en el caso de las redes inteligentes resulta clave para hacer esto posible, permitiendo a este tipo de redes gestionar la energía de manera eficiente, optimizar el sistema eléctrico, gestionar las fluctuaciones en la oferta y la demanda y su desfase; así como conseguir

una red eléctrica inteligente en el que las energías renovables se logran integrar correctamente pese a su variabilidad. Así, a continuación, se ven las principales técnicas de IA empleadas actualmente en Smart Grid para la consecución de todos estos objetivos.

4.4.1 Técnicas de IA para Migrogrids

Para comenzar, se va a abordar el uso que se hace de la IA para la gestión de las Microgrids o microrredes. Estas, son redes eléctricas que pueden trabajar tanto conectadas a la red eléctrica como de manera independiente. Así, antes de profundizar en las técnicas de IA para Smart Grid, se hará una breve descripción de las que se emplean en estas, que pueden considerarse como una pieza del puzle que compone a la Smart Grid general.

Las principales características de las microrredes, ya sea operando de forma autónoma o integrada en la red inteligente, se basan en el concepto de generación local de energía. Si bien la manera tradicional de distribuir energía se basaba en una red que distribuye la energía eléctrica desde grandes plantas generadoras hasta los puntos de consumo, el objetivo a día de hoy es virar hacia un sistema descentralizado en el que la energía se genere cerca de los puntos de consumo, apoyados con el uso de sistemas de almacenamiento en cada punto. Las microrredes, por tanto, suponen una forma de generación de energía fundamental para el nuevo esquema de distribución objetivo, e ideal para integrar las energías renovables en este nuevo esquema.

Las microrredes son comunes en el caso de pequeños complejos, como pueden ser universidades, hospitales, comunidades o poblaciones pequeñas y, como se ha comentado anteriormente, permiten funcionar en dos modos. Por una parte, está el modo de funcionamiento con conexión a la red. Este, implica no solo que la microgrid esté conectada a la red principal, sino que permite el intercambio de energía con ella, convirtiendo a los consumidores en productores. Por otro lado, el modo aislado, permite a las microrredes funcionar de manera independiente, lo que resulta de especial interés en caso de fallos o averías en la red principal, que interrumpan la distribución. En cualquier caso, las microrredes deben contar con un sistema de control que permita gestionar la relación entre la energía ofertada, demandada y la almacenada. Es aquí, donde la IA gana especial relevancia, empleándose mayormente para las predicciones de consumo y carga de la red, así como para las predicciones en relación a su uso de energías renovables. De esta manera, se presentan a continuación las principales técnicas de IA empleadas para estas redes.

Sistemas de control basados en IA para la gestión de Microgrids

Uno de los principales sistemas de control empleado para la gestión de microrredes es el visto ya para el control predictivo de los sistemas HVAC: los controladores MPC combinados con IA. De esta manera, su funcionamiento es muy similar al de la Figura 4.12. De esta manera, y como se vio, los MPC no ajustan su salida solo en base a los errores actuales, sino que realizan predicciones a futuro de acuerdo a los objetivos y condiciones de contorno a largo plazo. Particularizando el uso de MPC al caso de las microgrids, las principales de su uso en este ámbito, son las siguientes:

- Su capacidad de hacer ajustes en tiempo real permite mejorar la gestión energética en las microrredes, porque actúa de manera continua sobre el sistema para mejorar la eficiencia.
- La mejora de eficiencia actuando en tiempo real permite también reducir los costes, como consecuencia del ahorro energético, así como manejar las incertidumbres para los sistemas con múltiples entradas y salidas.
- Permite mantener la estabilidad de la red y disminuir la demanda máxima gracias a su capacidad para ir ajustando su comportamiento en lo relativo a producción y consumo de acuerdo a las pese a contar con unas condiciones de contorno variables.

- Su carácter predictivo, por último, permite prevenir la ocurrencia de fallos o averías en la red, sirviendo también para reducir los costes de mantenimiento y alargar la vida útil del sistema.

Al combinar este tipo de controlador con las redes LTSM se consigue un modelo de trabajo que permite mejorar tanto la precisión de las predicciones como el rendimiento durante el funcionamiento de la microrred. Esto se debe a que, gracias al uso de redes neuronales, se consiguen mejoras en ciertos aspectos de los controladores MPC, optimizando así el funcionamiento de estos. La integración de IA en los MPC permite a estos mejorar su precisión, trabajar con modelos más complejos y hacerlos aún más flexibles para los cambios que gestionan en tiempo real. Esto, en el ámbito de las microrredes, abre la puerta a un mejor control de las fluctuaciones de la demanda de energía y su gestión con la energía producida y almacenada.

A continuación, se describe a modo de ejemplo, un sistema de predicción del consumo energético basado en este tipo de tecnología, estudiado en 2022. En este caso, se van a comparar los valores reales de consumo de energía eléctrica usando controladores MPC con LTSM, en un entorno residencial. De esta forma, se hace un estudio del consumo energético de 15 viviendas a lo largo de un año, con datos recogidos cada media hora, en una ciudad de Marruecos.

Durante la fase de aprendizaje, se realizó una proporción 80-20 en la que, del total de datos recogidos, se dedicó un 20% a esta fase, empleando una red de retro propagación para tal fin.

Al analizar los datos de consumo real frente a su predicción (Figura 4.16), se comprueba el alto grado de precisión del controlador, con un bajo MSE. De esta manera, se confirma la capacidad de los controladores FLC con LTSM para predecir los patrones de demanda y mejorar, por ende, la fiabilidad energética y la eficiencia.

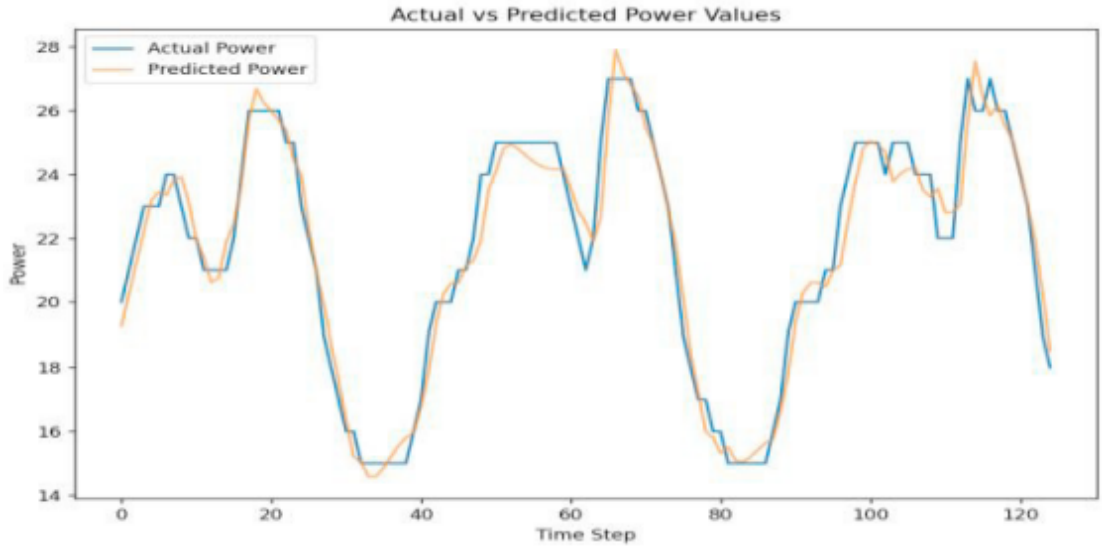


Figura 4.16 Comparación entre valor real y predicción [18]

Sistemas de control basados en IA para la gestión de Microgrids que emplean fuentes renovables

Al margen de los controladores MPC empleados en las microgrids de manera general, cuando estas emplean ER como fuente de energía, existen también otros sistemas control y otras técnicas de IA que se emplean para gestionar estos. A modo de resumen, los principales objetivos del uso de sistemas de control basados en IA en este caso son:

- Realizar predicciones de generación de ER, especialmente solar y eólica, dada su variabilidad.

- Preservar la seguridad del sistema, tanto la seguridad cibernética como antes posibles fallos o averías, desde un punto de vista predictivo.
- Mejorar el rendimiento del sistema y así como llevar a cabo su gestión y monitoreo en tiempo real.
- Emplear técnicas de IA, como redes neuronales, para modelar elementos del sistema y realizar simulaciones.
- Realizar predicciones sobre el consumo de la red y programar la generación y el almacenamiento de energía de fuentes renovables, de acuerdo a esto.

Las técnicas de IA empleadas en este caso se pueden resumir en el uso de Machine Learning y Sistemas Expertos. De esta manera, se describen a continuación los principales modelos estudiados hasta la fecha para el caso de energía solar en microrredes:

- **Sistema de control de microrredes basado en la extracción de parámetros usando algoritmos metaheurísticos.** En este caso se emplearon algoritmos metaheurísticos, concretamente BFO (*Bacterial Foraging Optimization*), conocido en español como Optimización por Forrajeo de Bacterias. Este, es un algoritmo bioinspirado que se basa en las bacterias E. Coli y su comportamiento para buscar alimento. Así, y siguiendo dicho patrón, es adecuado para solucionar problemas de optimización complejos. De esta manera, se comprobó que, al emplear este método de control, los resultados obtenidos eran más precisos que los conseguidos con otros métodos de optimización tradicionales.

- **Sistema de control sobre la generación de energía en microrredes que emplean energía solar, usando algoritmo de optimización por enjambre.** Este tipo de sistema de control, por otro lado, estaba destinado a planificar la gestión de la energía solar para con la microrred. Para ello, se comparó el uso del algoritmo de optimización por enjambre con otros tradicionales, consiguiendo para el primero una mayor reducción de emisiones y una mejor gestión de la energía.

- **Sistema de control de microrredes que emplean energía solar fotovoltaica, usando GA.** En este caso, se comprobó la reducción de los costes de operación, así como una mejora del rendimiento del sistema, además de mejorar el consumo de energía de la red logrando un coeficiente de determinación de $R^2 = 0{,}98$ [69].

- **Sistema de control de microrredes que emplean energía solar fotovoltaica, usando RF y SVM.** Si bien en el caso anterior se emplearon algoritmos genéticos, ahora se usa tanto RF como SVM para realizar predicciones de irradiación solar y de temperatura para sistemas fotovoltaicos que operan junto a una microrred. Al comparar estos como métodos tradicionales, como regresiones lineales, se obtuvieron predicciones más precisas al usar IA. Por otro lado, y comparado ambas técnicas de IA entre ellas, los resultados obtenidos con SVM resultaron ser ligeramente más precisos que los conseguidos con la técnica de Random Forest.

- **Sistema de control de microrredes que emplean energía solar usando Machine Learning.** En este caso, se emplearon algoritmos de aprendizaje supervisado, concretamente modelos de árbol de regresión, una variante de los árboles de decisión, más adecuados que estos para la predicción de valores continuos. El algoritmo se basaba en dos variables clave para realizar las predicciones: la humedad y la hora del día. Así, si bien las predicciones resultaron ser lo suficientemente precisas, se detectaron ciertos problemas a la hora de extrapolar este sistema a regiones con un clima muy diferente al de la zona del estudio.

- **Sistema de control de microrredes usando Machine Learning.** Por último, se estudió el uso de aprendizaje por refuerzo para gestionar el uso de microrredes alimentadas por ER. En este caso, se estudió el comportamiento de la microrred ante variaciones operativas de carga y de fluctuaciones en la línea, consiguiendo un RMSE ~ 4% [70].

4.4.2 Técnicas de IA para Smart Grids

Ya se ha comentado anteriormente la relación existente entre las microrredes y las redes inteligentes, así como la relevancia de estas en la deseada generación distribuida. De esta manera, las técnicas de IA empleadas en las Smart Grids son muy similares a las empleadas en las microgrids, centrándose en el uso de MPC, LTSM, así como técnicas de Machine Learning relacionadas, como el aprendizaje por refuerzo o redes neuronales como las CNN. En este caso, las redes CNN se usan, por ejemplo, para realizar predicciones sobre la generación de energías renovables para sistemas híbridos en los que las Smart Grids se combinan con múltiples fuentes de ER.

Por tanto, y dada la similitud entre las técnicas de IA empleadas para microrredes y para redes inteligentes, el objetivo de este apartado no es volver a enunciar estos, sino exponer el uso de una tecnología más que, combinada con la IA, supone una mejora en el uso de las redes inteligentes. Así, a lo largo del siguiente apartado, se verán las principales ventajas de combinar la IA con la tecnología Blockchain (Figura 4.17), así como los principales ejemplos de esta unión.

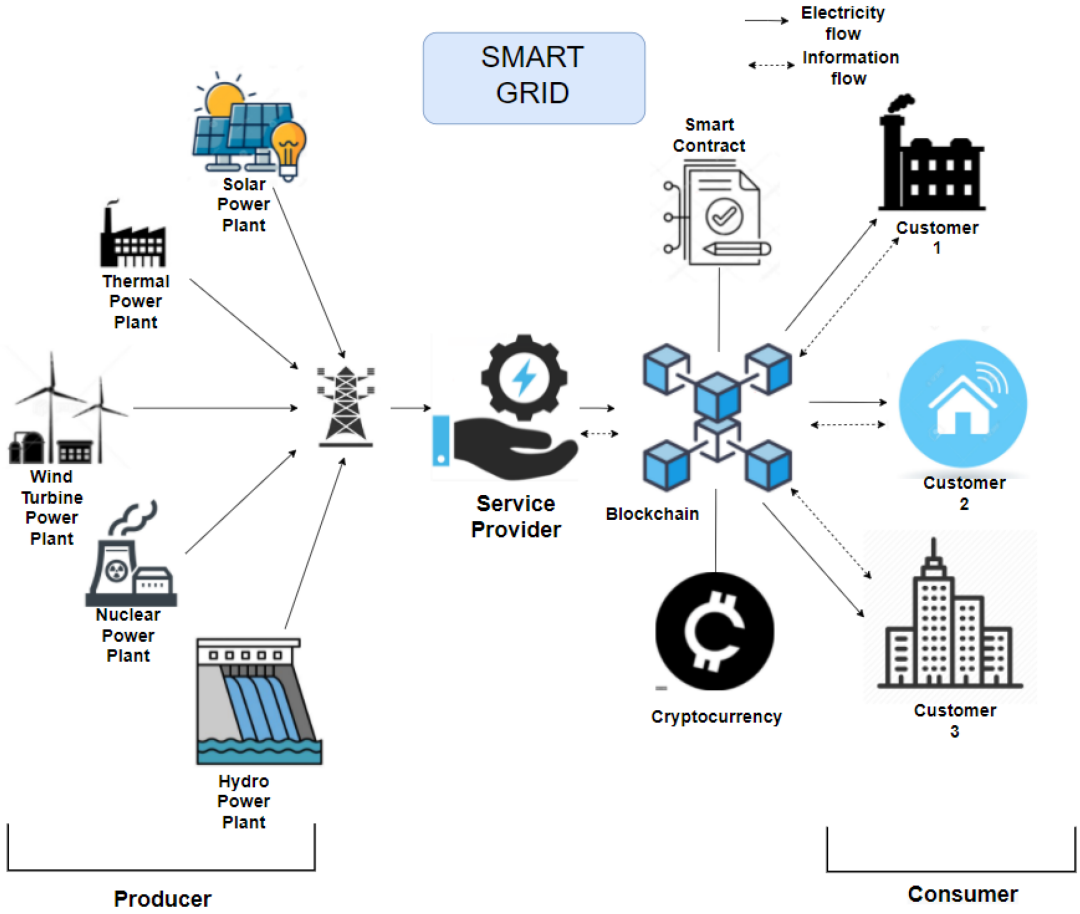


Figura 4.17 Integración de la tecnología blockchain en una Smart Grid [71]

La tecnología blockchain, o cadena de bloques, permite crear bases de datos de información de manera ordenada e innovadora, para poder transmitirla y registrarla. El registro de la información, aparte de caracterizarse por su seguridad, se realiza de manera ordenada en bloques que se añaden de manera secuencial. Así, cada bloque, incluye su propio paquete de información, dato de tiempo y su relación con el bloque anterior a él. Entre las principales ventajas de la tecnología blockchain, destacan la trazabilidad de la información, que no puede ser alterada ni tampoco eliminada, evitando así las pérdidas de datos. Además, asegura la transparencia y la seguridad, al recoger toda la información de todas las transacciones

en cada bloque. Por último, no necesita de intermediarios ni una entidad central que controle su funcionamiento, asegurando así un registro de la información descentralizado y que asegura la privacidad de los participantes.

Existe, de esta manera, una interrelación entre las cadenas bloques, su combinación con la IA y el papel que ambas juegan en la transformación digital y la transición energética. En primer lugar, el uso de blockchain permite mejorar los modelos empleados en la IA, pues pueden usar la información almacenada en la cadena de bloques para aprender y generar resultados más precisos. La IA, por otro lado, puede mejorar la descentralización ya existente en las cadenas de bloques, al incorporar la toma de decisiones inteligentes. Además, la IA puede optimizar estos procesos en base a su capacidad de análisis de predictivo, ayudando a predecir fallos.

En lo relativo a la transición energética, la tecnología blockchain hace posible la descentralización de la energía y que sistemas como las Smart Grids, puedan funcionar gracias a la dualidad de los consumidores que se pueden convertir en productores. Además, los sistemas de cadena de bloques, gracias a su trazabilidad, permiten conocer el origen de la energía a utilizar, así como sus procesos de trading (compra-venta), fomentando así la generación y el uso de energías renovables y garantizando, en tal caso, que son energías limpias. Así, la unión de las Smart Grids con las cadenas de bloque, permiten la digitalización de los sistemas energéticos, mejorado por ende la forma en la que es gestionado, la integración de fuentes de ER y la seguridad del mismo.

Así, mientras que la transición energética persigue alcanzar un panorama más limpio y verde con menos emisiones, la transformación digital se complementa con esta para lograr este objetivo, empleando técnicas como la IA y, usando la tecnología de blockchain en este caso, como medio para hacer posible esta transformación desde el punto de vista tecnológico.

De esta manera, las técnicas de IA empleadas para este tipo de redes con blockchain, se basa en Machine Learning y el aprendizaje supervisado, no supervisado y por refuerzo, que se alimentan de los grandes volúmenes de datos fruto de las mediciones de las redes inteligentes. Gracias a esto, es posible mejorar la escalabilidad de los sistemas y reducir el tiempo computacional, al combinar estas técnicas con algoritmos de optimización.

A modo de ejemplo, este tipo de aprendizajes se ha empleado para minimizar los costes en Smart Grids alimentadas con ER, consiguiendo mejores resultados que los obtenidos solo con algoritmos metaheurísticos. En particular, el aprendizaje por refuerzo se ha empleado de múltiples formas para mejorar el funcionamiento de las redes inteligentes. En primer lugar, se ha usado para programar el uso de baterías y bombas de calor de una microrred, consiguiendo mejores resultados de eficiencia computacional que el caso de algoritmos tradicionales. Además, ha permitido también controlar un grupo de cargas y dispositivos de almacenamiento al combinarlo con algoritmos. Por otro lado, se ha usado también para cuadrar los desfases de oferta y demanda de usuarios finales, no solo reduciendo costes sino mejorando el equilibrio de carga, así como para gestionar la demanda de energía, mejorando la flexibilidad de esta de cara a los consumidores.

Por último, otra técnica de la IA empleada para las redes inteligentes, es el uso de redes neuronales para el control de los picos de la demanda, uno de los desafíos principales de esta tecnología investigado a día de hoy. Así, al emplear redes neuronales profundas para gestionar y combinarlos con otros métodos de optimización tradicionales como el modelo aditivo generalizado (GAM), se consiguen resultados de alta precisión con datos de partida de baja resolución.

IA en Smart Grids: Niveles de implementación

En cualquier caso, y de cara a implementar las técnicas de IA en las redes inteligentes, este proceso se puede realizar en 4 niveles diferentes, a saber: autónomo, prescriptivo, predictivo y de respuesta; ordenados de mayor a menor de acuerdo a su nivel de automatización y autonomía (Figura 4.18).

El primero nivel, el autónomo, es aquel en el que el sistema funciona de manera completamente automática, siendo la IA la responsable de tomar todas las decisiones en lo relativo a decisiones de control, gestión y optimización de la red. En este caso, no solo se incluye la gestión completa de la red sino también su proceso de auto curación, por el que la IA sería responsable de solventar los problemas encontrados sin la necesidad de intervención humana. El segundo nivel, el prescriptivo, emplea optimización de software para poder automatizar ciertas tareas a través de la IA, para así minimizar los cortes e interrupciones del servicio. El tercer nivel, el predictivo, emplea las técnicas de IA para tomar decisiones en tiempo real sobre la generación y la demanda gracias al análisis de datos de la red. Por último, el cuarto nivel, el de respuesta, se caracteriza por el uso de IA para solucionar problemas en el sistema eléctrico una vez estos han sido notificados.

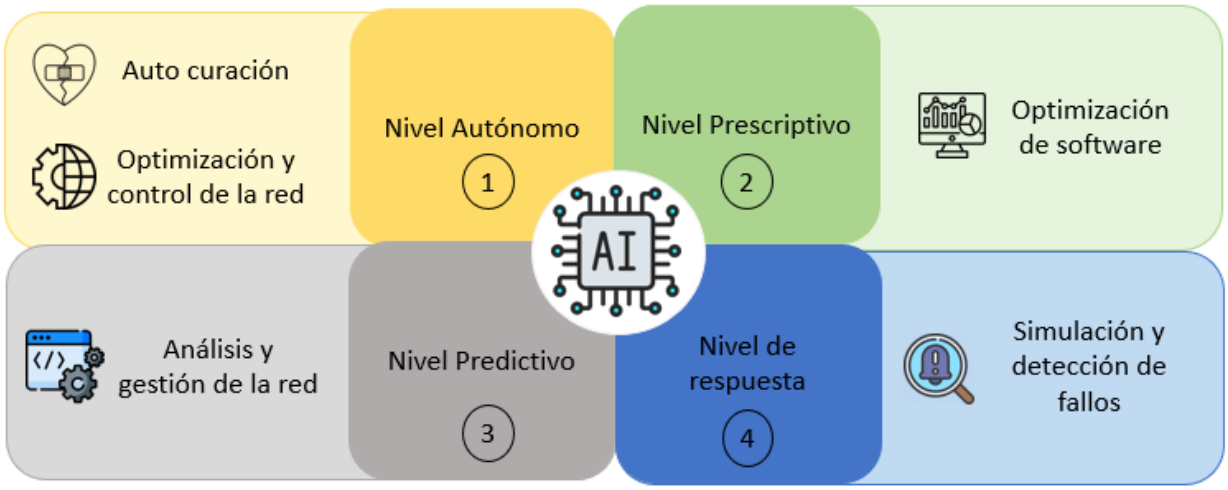


Figura 4.18 Usos de la IA para cada nivel

De esta forma, al combinar el uso de la IA con las redes inteligentes y la tecnología blockchain se consigue mejorar la automatización, la eficiencia computacional, la escalabilidad y la adaptabilidad de los sistemas, logrando redes que toman decisiones de manera automática y coordinadas con otros sistemas eléctricos, adaptándose a los cambios sucedidos en tiempo real. Por otro lado, y aunque son diversas sus ventajas, es necesario contar de partida con un gran volumen de datos históricos para entrenar los modelos y obtener resultados precisos. Además, es necesario entrenar a dichos modelos para que sean conocedores de las restricciones físicas de la red y la incorporen como parte de sus algoritmos en la resolución de problemas.

En cualquier caso, si bien es aún necesario solventar algunos problemas y superar ciertos desafíos, el uso de blockchain y técnicas de IA en las Smart Grids supone un avance significativo en la transición energética hacia una gestión más segura, autónoma y eficiente de los sistemas eléctricos. Así, se facilita la descarbonización del sistema eléctrico, gracias a la integración de las energías renovables, con un sistema eléctrico menos dependiente de los combustibles fósiles, más resiliente y con una mejor distribución y consumo de energía.

5 CONCLUSIONES

"De lejos, el mayor peligro de la inteligencia artificial es que las personas concluyan demasiado pronto que la entienden."- Eliezer Yudkowsky

La transición energética actual fomenta el uso de medidas que permitan transformar el panorama energético actual hacia uno más limpio, eficiente y resiliente. Fruto de los avances tecnológicos y la transformación digital, la IA se ha convertido en una pieza clave de la misma, sirviendo como medio para optimizar y modernizar la manera en la que se gestionan y controlan los sistemas energéticos. La IA permite mejorar la eficiencia energética para diferentes tipos de tecnologías del sector energético, convirtiéndose en una herramienta clave de la transición hacia un futuro energético más sostenible y menos dependiente de los combustibles fósiles.

En primer lugar, y en relación a las energías renovables, la IA permite gestionar la operación de estas optimizando su rendimiento y permitiendo solventar los principales desafíos que han presentado hasta ahora. En el caso de la energía solar y eólica, las dos fuentes renovables con más proyección a día de hoy, los principales problemas encontrados hasta ahora han sido su intermitencia y variabilidad. La IA, en este caso, permite solventar estos, permitiendo por tanto un abastecimiento energético más fiable y seguro. Además, no solo hace posible poner solución a estos problemas, sino que permite optimizar el diseño de las mismas, su ubicación y disposición, así como la forma en la que estas operan de acuerdo a las condiciones climáticas.

En lo relativo al almacenamiento de energía, el uso de IA permite mejorar el funcionamiento de los mismos, realizando predicciones de su rendimiento, optimizando su diseño y realizando tareas de control predictivo. Así, y para el caso de las baterías, la IA consigue alargar la vida útil de estas y disminuir su desgaste, haciendo posible una mejor gestión de la demanda, en la que las baterías sirven de apoyo cuando sea necesario.

Por otro lado, en relación a los sistemas de climatización, el uso de la IA permite mejorar la eficiencia energética de esta sin perjudicar el confort térmico de los ocupantes. De esta manera, su uso sirve para gestionar y controlar la operación de este tipo de sistemas, tomando en consideración tanto las preferencias

de los ocupantes, aprendidas a base de histórico, y realizando ajustes a tiempo real para reducir costes y mejorar el ahorro energético.

Por último, se realiza también un breve análisis del uso de la IA para las redes inteligentes, dada la relevancia de estas en el sector energético y la transición actual. En este caso, la combinación de la IA con la tecnología blockchain presenta numerosas ventajas, como la mejora en la integración de las energías renovables para solventar las fluctuaciones en la demanda de energía eléctrica, ayudando a garantizar el suministro. Así, permite optimizar el uso de una generación energética distribuida y descentralizada de manera segura, transparente y autónoma.

Sin embargo, si bien son numerosas las ventajas del uso de la IA en este sector, también se presentan algunos inconvenientes en forma de obstáculos que habría que corregir para hacer un óptimo uso de la misma. De esta forma, los principales desafíos que enfrenta la IA en el sector energético se pueden resumir en tres aspectos fundamentales:

En primer lugar, y para lograr un funcionamiento de la IA adecuado en los sistemas energéticos, es necesario alimentar los algoritmos con grandes volúmenes de datos para que estos puedan completar su fase de aprendizaje. Por lo tanto, no solo es importante la cantidad de estos datos sino la calidad de los mismos, debiendo ser precisos y estar en muchas ocasiones bien estructurados. De lo contrario, no solo no se consiguen resultados lo suficientemente precisos, sino que los algoritmos pueden propones soluciones erróneas. De esta manera, no siempre es posible contar con cantidades de datos de tal calidad, suponiendo un pequeño obstáculo a salvar para que la IA sea utilizada correctamente en este sector. Además, es fundamental garantizar la seguridad y privacidad de los datos, para así evitar que se comentan infracciones con graves consecuencias para el sector.

En segundo lugar, dado el reciente avance de la IA en los últimos años, aún no existe un marco regulador completo que permita implementar este tipo de tecnologías de manera segura y reglada en el sector energético. Así, dado el rápido avance tecnológico frente a la velocidad de marcos legislativos, aún se está trabajando en la generación de normativas a nivel internacional que aseguren un uso de la IA enfocado al bien común y, en especial, a aquellas regiones en las que el impacto del cambio climático es mayor.

Por último, tras la existencia de dos inviernos previos, la posibilidad de la venida de un tercero resulta probable y está siendo barajada por numerosos expertos. Hasta ahora los inviernos se han caracterizado por la consecución de dos hechos: un primer avance significativo en el campo de la IA, continuado de un estancamiento provocado por expectativas demasiado altas. Pues bien, actualmente ha habido un fuerte avance de la IA en los últimos años, por lo que un tercer invierno ahora implicaría de nuevo otro estancamiento en el avance de este tipo de tecnologías, de la mano de una disminución de la financiación y una disminución del interés de los usuarios.

En resumen, el uso de la IA en el sector energético supone un antes y un después en la forma de gestionar y controlar este tipo de sistemas, contribuyendo a la creación de un mundo más sostenible, eficiente y resiliente, frenando así el cambio climático. Sin embargo, y aunque son muchas las oportunidades de mejora en eficiencia energética que conlleva el uso de la IA, aún existen ciertos riesgos y desafíos que solventar, tanto desde el punto de vista tecnológico, como normativo y de financiación. De esta manera, resulta fundamental que se promueva la colaboración entre todas las partes involucradas para solventar estos problemas y garantizar que la integración de la IA en el sector energético se realice de manera segura, efectiva y equitativa, garantizando un futuro sostenible para las próximas generaciones.

REFERENCIAS

[1] «La Asamblea General adopta la Agenda 2030 para el Desarrollo Sostenible - Desarrollo Sostenible». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/

[2] «Energía - Desarrollo Sostenible». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.un.org/sustainabledevelopment/es/energy/

[3] «Cambio climático - Desarrollo Sostenible». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.un.org/sustainabledevelopment/es/climate-change-2/

[4] A. Bennagi, O. AlHousrya, D. T. Cotfas, y P. A. Cotfas, «Comprehensive study of the artificial intelligence applied in renewable energy», *Energy Strategy Reviews*, vol. 54, p. 101446, jul. 2024, doi: 10.1016/J.ESR.2024.101446.

[5] «When Artificial Intelligence Mimics the Human Brain | Psychology Today». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.psychologytoday.com/intl/blog/the-digital-self/202311/when-artificial-intelligence-mimics-the-human-brain

[6] «Por qué la IA adaptativa es importante para tu empresa». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.gartner.es/es/articulos/por-que-la-ia-adaptativa-es-importante-para-tu-empresa

[7] A. Abeliuk y C. Gutiérrez, «Inteligencia Artificial El primer programa de IA».

[8] «What is the Turing Test? | Definition from TechTarget». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.techtarget.com/searchenterpriseai/definition/Turing-test

[9] A. Author, «Is the Next Winter Coming for AI? The Elements of Making Secure and Robust AI».

[10] «Bagging v/s Boosting. Bagging and boosting are both ensemble… | by Roshmita Dey | Medium». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://medium.com/@roshmitadey/bagging-v-s-boosting-be765c970fd1

[11] «Redes Neuronales Profundas - sitiobigdata.com». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://sitiobigdata.com/2019/12/24/redes-neuronales-profundas/

[12] «Expert Systems in Artificial Intelligence - Javatpoint». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.javatpoint.com/expert-systems-in-artificial-intelligence

[13] P. Europeo - wwweuroparleuropaeu, «Ley de IA de la UE: primera normativa sobre inteligencia artificial | Noticias | Parlamento Europeo».

[14] S. Elkateb, A. Métwalli, A. Shendy, y A. E. B. Abu-Elanien, «Machine learning and IoT – Based predictive maintenance approach for industrial applications», *Alexandria Engineering Journal*, vol. 88, pp. 298-309, feb. 2024, doi: 10.1016/j.aej.2023.12.065.

[15] S. Sankarananth, M. Karthiga, E. Suganya, S. Sountharrajan, y D. P. Bavirisetti, «AI-enabled metaheuristic optimization for predictive management of renewable energy production in smart grids», *Energy Reports*, vol. 10, pp. 1299-1312, nov. 2023, doi: 10.1016/J.EGYR.2023.08.005.

[16] P. Bajpai y V. Dash, «Hybrid renewable energy systems for power generation in stand-alone applications: A review», junio de 2012. doi: 10.1016/j.rser.2012.02.009.

[17] R. O. Yussuf y O. S. Asfour, «Applications of artificial intelligence for energy efficiency throughout the building lifecycle: An overview», *Energy Build*, vol. 305, p. 113903, feb. 2024, doi: 10.1016/J.ENBUILD.2024.113903.

[18] S. Dankir, V. Puig, R. Lasri, Y. Maatoui, y H. Chekenbah, «Empowering Microgrid Energy Management with Artificial Intelligence and Model Predictive Control», *IFAC-PapersOnLine*, vol. 58, n.º 13, pp. 436-441, 2024, doi: 10.1016/j.ifacol.2024.07.521.

[19] M. Li, N. Mour, y L. Smith, «Machine learning based on reinforcement learning for smart grids: Predictive analytics in renewable energy management», *Sustain Cities Soc*, vol. 109, ago. 2024, doi: 10.1016/j.scs.2024.105510.

[20] M. AlShafeey y C. Csaki, «Adaptive machine learning for forecasting in wind energy: A dynamic, multi-algorithmic approach for short and long-term predictions», *Heliyon*, vol. 10, n.º 15, p. e34807, ago. 2024, doi: 10.1016/j.heliyon.2024.e34807.

[21] L. Zheng *et al.*, «Artificial intelligence-driven rechargeable batteries in multiple fields of development and application towards energy storage», 10 de diciembre de 2023, *Elsevier Ltd*. doi: 10.1016/j.est.2023.108926.

[22] B. O. Abisoye, Y. Sun, y W. Zenghui, «A survey of artificial intelligence methods for renewable energy forecasting: Methodologies and insights», *Renewable Energy Focus*, vol. 48, p. 100529, mar. 2024, doi: 10.1016/J.REF.2023.100529.

[23] Q. Chen y K. A. Folly, «Application of Artificial Intelligence for EV Charging and Discharging Scheduling and Dynamic Pricing: A Review», 1 de enero de 2023, *MDPI*. doi: 10.3390/en16010146.

[24] S. Qureshi, F. Shaikh, L. Kumar, F. Ali, M. Awais, y A. E. Gürel, «Short-term forecasting of wind power generation using artificial intelligence», *Environmental Challenges*, vol. 11, p. 100722, abr. 2023, doi: 10.1016/J.ENVC.2023.100722.

[25] M. A. M. Ramli, S. Twaha, y Y. A. Al-Turki, «Investigating the performance of support vector machine and artificial neural networks in predicting solar radiation on a tilted surface: Saudi Arabia case study», *Energy Convers Manag*, vol. 105, pp. 442-452, ago. 2015, doi: 10.1016/j.enconman.2015.07.083.

[26] L. Sun y Y. Sun, «Photovoltaic Power Forecasting based on Artificial Neural Network and Ultraviolet Index», *International Journal of Computing*, vol. 21, n.º 2, pp. 153-158, 2022, doi: 10.47839/ijc.21.2.2583.

[27] J. Wu y C. K. Chan, «Prediction of hourly solar radiation with multi-model framework», *Energy Convers Manag*, vol. 76, pp. 347-355, 2013, doi: 10.1016/j.enconman.2013.07.067.

[28] G. T. Chandra Sekhar, H. S. Behera, J. Nayak, B. Naik, y D. Pelusi, «Lecture Notes in Electrical Engineering 702 Intelligent Computing in Control and Communication Proceeding of the First International Conference on Intelligent Computing in Control and Communication (ICCC 2020)». [En línea]. Disponible en: http://www.springer.com/series/7818

[29] J. Piri, S. Shamshirband, D. Petković, C. W. Tong, y M. H. U. Rehman, «Prediction of the solar radiation on the Earth using support vector regression technique», *Infrared Phys Technol*, vol. 68, pp. 179-185, 2015, doi: 10.1016/j.infrared.2014.12.006.

[30] A. Rafati, M. Joorabian, E. Mashhour, y H. R. Shaker, «High dimensional very short-term solar power forecasting based on a data-driven heuristic method», *Energy*, vol. 219, mar. 2021, doi: 10.1016/j.energy.2020.119647.

[31] P. H. Kuo y C. J. Huang, «A green energy application in energy management systems by an artificial intelligence-based solar radiation forecasting model», *Energies (Basel)*, vol. 11, n.º 4, abr. 2018, doi: 10.3390/en11040819.

[32] Z. Qadir *et al.*, «Predicting the energy output of hybrid PV–wind renewable energy system using feature selection technique for smart grids», *Energy Reports*, vol. 7, pp. 8465-8475, nov. 2021, doi: 10.1016/j.egyr.2021.01.018.

[33] G. López y P. Arboleya, «Short-term wind speed forecasting over complex terrain using linear regression models and multivariable LSTM and NARX networks in the Andes Mountains, Ecuador», *Renew Energy*, vol. 183, pp. 351-368, ene. 2022, doi: 10.1016/j.renene.2021.10.070.

[34] G. Mallesham, S. Mishra, y A. N. Jha, «Automatic generation control of microgrid using artificial intelligence techniques», *IEEE Power and Energy Society General Meeting*, 2012, doi: 10.1109/PESGM.2012.6345404.

[35] S. Kiwan, M. Al-Nimr, y I. Salim, «A hybrid solar chimney/photovoltaic thermal system for direct electric power production and water distillation», *Sustainable Energy Technologies and Assessments*, vol. 38, abr. 2020, doi: 10.1016/j.seta.2020.100680.

[36] C. M. dos Santos, J. F. Escobedo, A. de Souza, M. B. P. da Silva, y F. Aristone, «Prediction of solar direct beam transmittance derived from global irradiation and sunshine duration using anfis», *Int J Hydrogen Energy*, vol. 46, n.º 55, pp. 27905-27921, ago. 2021, doi: 10.1016/J.IJHYDENE.2021.06.044.

[37] K. Mohammadi, S. Shamshirband, A. Kamsin, P. C. Lai, y Z. Mansor, «Identifying the most significant input parameters for predicting global solar radiation using an ANFIS selection procedure», *Renewable and Sustainable Energy Reviews*, vol. 63, pp. 423-434, sep. 2016, doi: 10.1016/J.RSER.2016.05.065.

[38] A. Dahmani, Y. Ammi, S. Hanini, M. R. Yaiche, y H. Zentou, «Prediction of Hourly Global Solar Radiation: Comparison of Neural Networks / Bootstrap Aggregating», *Kemija u industriji*, n.º 3-4, mar. 2023, doi: 10.15255/KUI.2022.065.

[39] Y. Shaiek, M. Ben Smida, A. Sakly, y M. F. Mimouni, «Comparison between conventional methods and GA approach for maximum power point tracking of shaded solar PV

generators», *Solar Energy*, vol. 90, pp. 107-122, abr. 2013, doi: 10.1016/J.SOLENER.2013.01.005.

[40] Y. Xie, Y. Ishida, J. Hu, y A. Mochida, «A backpropagation neural network improved by a genetic algorithm for predicting the mean radiant temperature around buildings within the long-term period of the near future», *Build Simul*, vol. 15, n.º 3, pp. 473-492, mar. 2022, doi: 10.1007/S12273-021-0823-6/METRICS.

[41] A. Abubakar, C. F. M. Almeida, y M. Gemignani, «Review of Artificial Intelligence-Based Failure Detection and Diagnosis Methods for Solar Photovoltaic Systems», *Machines 2021, Vol. 9, Page 328*, vol. 9, n.º 12, p. 328, dic. 2021, doi: 10.3390/MACHINES9120328.

[42] R. K. Kharb, S. L. Shimi, S. Chatterji, y M. F. Ansari, «Modeling of solar PV module and maximum power point tracking using ANFIS», *Renewable and Sustainable Energy Reviews*, vol. 33, pp. 602-612, may 2014, doi: 10.1016/J.RSER.2014.02.014.

[43] V. Lo Brano, G. Ciulla, y M. Di Falco, «Artificial Neural Networks to Predict the Power Output of a PV Panel», *International Journal of Photoenergy*, vol. 2014, n.º 1, p. 193083, ene. 2014, doi: 10.1155/2014/193083.

[44] X. Gao *et al.*, «Parameter extraction of solar cell models using improved shuffled complex evolution algorithm», *Energy Convers Manag*, vol. 157, pp. 460-479, feb. 2018, doi: 10.1016/J.ENCONMAN.2017.12.033.

[45] U. K. Das *et al.*, «SVR-Based Model to Forecast PV Power Generation under Different Weather Conditions», *Energies 2017, Vol. 10, Page 876*, vol. 10, n.º 7, p. 876, jun. 2017, doi: 10.3390/EN10070876.

[46] X. Xue, «Prediction of daily diffuse solar radiation using artificial neural networks», *Int J Hydrogen Energy*, vol. 42, n.º 47, pp. 28214-28221, nov. 2017, doi: 10.1016/J.IJHYDENE.2017.09.150.

[47] A. Saenz-Aguirre, E. Zulueta, U. Fernandez-Gamiz, J. Lozano, y J. M. Lopez-Guede, «Artificial Neural Network Based Reinforcement Learning for Wind Turbine Yaw Control», *Energies 2019, Vol. 12, Page 436*, vol. 12, n.º 3, p. 436, ene. 2019, doi: 10.3390/EN12030436.

[48] T. Brahimi, «Using Artificial Intelligence to Predict Wind Speed for Energy Application in Saudi Arabia», *Energies 2019, Vol. 12, Page 4669*, vol. 12, n.º 24, p. 4669, dic. 2019, doi: 10.3390/EN12244669.

[49] D. Mazzeo *et al.*, «Artificial intelligence application for the performance prediction of a clean energy community», *Energy*, vol. 232, p. 120999, oct. 2021, doi: 10.1016/J.ENERGY.2021.120999.

[50] H. Shi, L. Wang, R. Scherer, M. Wozniak, P. Zhang, y W. Wei, «Short-Term Load Forecasting Based on Adabelief Optimized Temporal Convolutional Network and Gated Recurrent Unit Hybrid Neural Network», *IEEE Access*, vol. 9, pp. 66965-66981, 2021, doi: 10.1109/ACCESS.2021.3076313.

[51] W. Shin, J. Han, y W. Rhee, «AI-assistance for predictive maintenance of renewable energy systems», *Energy*, vol. 221, p. 119775, abr. 2021, doi: 10.1016/J.ENERGY.2021.119775.

[52] Y. Song, S. Wu, y Y. Y. Yan, «Control strategies for indoor environment quality and energy efficiency-a review», *International Journal of Low-Carbon Technologies*, vol. 10, n.º 3, pp. 305-312, jul. 2013, doi: 10.1093/IJLCT/CTT051.

[53] K. Almutairi, «Applications of intelligent techniques in modeling geothermal heat pumps: an updated review», *International Journal of Low-Carbon Technologies*, vol. 17, pp. 910-918, feb. 2022, doi: 10.1093/IJLCT/CTAC061.

[54] K. Utkarsh, A. Trivedi, D. Srinivasan, y T. Reindl, «A Consensus-Based Distributed Computational Intelligence Technique for Real-Time Optimal Control in Smart Distribution Grids», *IEEE Trans Emerg Top Comput Intell*, vol. 1, n.º 1, pp. 51-60, feb. 2017, doi: 10.1109/TETCI.2016.2635130.

[55] P. Siratovich *et al.*, «GOOML - Finding Optimization Opportunities for Geothermal Operations: Preprint», 2022, Accedido: 30 de agosto de 2024. [En línea]. Disponible en: www.nrel.gov/publications.

[56] M. Heydari Aghagol, R. Hamidi, y M. Reza Heyhat, «Assess the potential of geothermal resources using fuzzy logic and binary index overlay (Case Study: South Khorasan province, eastern Iran)», *Journal of Tethys*, vol. 4, n.º 3, pp. 221-241.

[57] Z. He, W. Guo, y P. Zhang, «Performance prediction, optimal design and operational control of thermal energy storage using artificial intelligence methods», 1 de marzo de 2022, *Elsevier Ltd*. doi: 10.1016/j.rser.2021.111977.

[58] Y. Varol, A. Koca, H. F. Oztop, y E. Avci, «Forecasting of thermal energy storage performance of Phase Change Material in a solar collector using soft computing techniques», *Expert Syst Appl*, vol. 37, n.º 4, pp. 2724-2732, abr. 2010, doi: 10.1016/j.eswa.2009.08.007.

[59] Z. He, W. Guo, y P. Zhang, «Performance prediction, optimal design and operational control of thermal energy storage using artificial intelligence methods», *Renewable and Sustainable Energy Reviews*, vol. 156, p. 111977, mar. 2022, doi: 10.1016/J.RSER.2021.111977.

[60] J. Ngarambe, G. Y. Yun, y M. Santamouris, «The use of artificial intelligence (AI) methods in the prediction of thermal comfort in buildings: energy implications of AI-based thermal comfort controls», *Energy Build*, vol. 211, p. 109807, mar. 2020, doi: 10.1016/J.ENBUILD.2020.109807.

[61] O. Khan, M. Parvez, M. Seraj, Z. Yahya, Y. Devarajan, y B. Nagappan, «Optimising building heat load prediction using advanced control strategies and Artificial Intelligence for HVAC system», *Thermal Science and Engineering Progress*, vol. 49, p. 102484, mar. 2024, doi: 10.1016/J.TSEP.2024.102484.

[62] G. Halhoul Merabet *et al.*, «Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques», *Renewable and Sustainable Energy Reviews*, vol. 144, p. 110969, jul. 2021, doi: 10.1016/J.RSER.2021.110969.

[63] A. Garnier, J. Eynard, M. Caussanel, y S. Grieu, «Predictive Control of Multizone HVAC Systems in Non-residential Buildings», *IFAC Proceedings Volumes*, vol. 47, n.º 3, pp. 12080-12085, ene. 2014, doi: 10.3182/20140824-6-ZA-1003.01826.

[64] A. Yayla *et al.*, «Artificial Intelligence (AI)-Based Occupant-Centric Heating Ventilation and Air Conditioning (HVAC) Control System for Multi-Zone Commercial Buildings»,

Sustainability 2022, Vol. 14, Page 16107, vol. 14, n.º 23, p. 16107, dic. 2022, doi: 10.3390/SU142316107.

[65] P. M. Ferreira, A. E. Ruano, S. Silva, y E. Z. E. Conceição, «Neural networks based predictive control for thermal comfort and energy savings in public buildings», *Energy Build*, vol. 55, pp. 238-251, dic. 2012, doi: 10.1016/J.ENBUILD.2012.08.002.

[66] D. Lee, R. Ooka, Y. Matsuda, S. Ikeda, y W. Choi, «Experimental analysis of artificial intelligence-based model predictive control for thermal energy storage under different cooling load conditions», *Sustain Cities Soc*, vol. 79, p. 103700, abr. 2022, doi: 10.1016/J.SCS.2022.103700.

[67] S. Hussain, H. A. Gabbar, D. Bondarenko, F. Musharavati, y S. Pokharel, «Comfort-based fuzzy control optimization for energy conservation in HVAC systems», *Control Eng Pract*, vol. 32, pp. 172-182, nov. 2014, doi: 10.1016/J.CONENGPRAC.2014.08.007.

[68] «Diagrama de red inteligente. Red de comunicación inteligente, ciudad de tecnología inteligente, red eléctrica inteligente, ilustración de red inteligente de energía | Vector Gratis». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://www.freepik.es/vector-gratis/diagrama-red-inteligente-red-comunicacion-inteligente-ciudad-tecnologia-inteligente-red-electrica-inteligente-ilustracion-red-inteligente-energia_13437767.htm#query=smart%20grid&position=0&from_view=keyword&track=ais_hybrid&uuid=5bcd1c52-85f3-4456-8710-cda22097735d

[69] D. R. Nair, M. G. Nair, y T. Thakur, «A Smart Microgrid System with Artificial Intelligence for Power-Sharing and Power Quality Improvement», *Energies 2022, Vol. 15, Page 5409*, vol. 15, n.º 15, p. 5409, jul. 2022, doi: 10.3390/EN15155409.

[70] F. Rodríguez, A. Fleetwood, A. Galarza, y L. Fontán, «Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control», *Renew Energy*, vol. 126, pp. 855-864, oct. 2018, doi: 10.1016/j.renene.2018.03.070.

[71] M. M. M. Al Moti *et al.*, «Blockchain Based Smart-Grid Stackelberg Model for Electricity Trading and Price Forecasting Using Reinforcement Learning», *Applied Sciences (Switzerland)*, vol. 12, n.º 10, may 2022, doi: 10.3390/app12105144.

[72] «U.S. Officially Rejoins the Paris Agreement - U.S. Embassy & Consulates in Brazil». Accedido: 30 de agosto de 2024. [En línea]. Disponible en: https://br.usembassy.gov/u-s-officially-rejoins-the-paris-agreement/

GLOSARIO

AIE
Agencia Internacional de la Energía 30
ANFIS
Sistema de Inferencia Neuro-Difuso Adaptativo 62
API
Interfaz de Programación de Aplicaciones 39
AR
Auto regresión 74
ARIMA
Media móvil integrada autorregresiva 62
ARMA
Media Móvil Auto Regresiva 65
BANN
Redes Agregadas de Arranque 62
BFO
Optimización por Forrajeo de Bacterias 93
BFS
Breadth-First Search 42
BMS
Sistema de Gestión de Baterías 82
BPNM
Redes de Retro propagación 50
CDN
Contribución Determinada a Nivel Nacional 27
CFD
Fluidodinámica Computacional 78
CMLP
Perceptrón de Cascada Multicapa 69
CNN
Red Neuronal Convolucional 43
COP
Coeficiente de Rendimiento 77
DBM
Máquinas Boltzmann 89
DFS
Depth-First Search 42
DNN
Red Neuronal Profunda 49
EML
Extreme Machine Learning 77
ER

Energías Renovables 59
FDD
Detección y Diagnóstico de Fallos 88
FLC
Controladores de Lógica Difusa 80
GA
Algoritmos Genéticos 62
GAM
Modelo Aditivo Generalizado 95
GAN
Red Generativa Antagónica 50
GMDHNN
Redes basadas en el Método de Grupo de Manejo de Datos 62
GNL
Generación Natural del Lenguaje 44
GPU
Unidad de Procesamiento Gráfico 38
GRU
Unidades Recurrentes Cerradas 50
I
Integración 74
IA
Inteligencia Artificial 33
IoE
Internet de la Energía 63
IoT
Internet de las Cosas 63
ISCE
Improved Shuffled Complex Evolution Algorithm 70
ISOA
Improved Snake Optimization Algorithm 70
LCOE
Coste Normalizado de la Energía 71
LM
Levenberg-Marquardt 65
LTES
Almacenamiento de Energía Latente 79
LTSM
Redes de Memoria de Corto-Largo Plazo 50
MA
Media Móvil 74
MAE
Error Absoluto Medio 67
MAPE
Error Porcentual Absoluto Medio 67
MPC
Método Predictivo de Control basado en Modelos 85
NARX
Redes Autoregresivas No Lineales con Entradas Exógenas 79
NGSA-II
Algoritmo Genético de Clasificación No Dominada II 79

NREL
Laboratorio Nacional de Energías Renovables 76
Nu
Nusselt 79
ODS
Objetivos de Desarrollo Sostenible 27
ONU
Organización de las Naciones Unidas 27
PCM
Material de Cambio de Fase 79
PI
Proporcional Integral 84
PID
Proporcional Integral Derivativo 84
PMV
Opinión Media Estimada 84
PNL
Procesamiento Natural del Lenguaje 36
RBFNN
Redes de Función de Base Radial 62
RF
Random Forest 48
rMBE
Sesgo Medio Relativo 67
RMSE
Error Cuadrático Medio 67
RNN
Red Neuronal Recurrente 43
rRMSE
Error Relativo Cuadrático Medio 67
SARIMA
Media Móvil integrada Autorregresiva Estacional 62
SCADA
Supervisory Control and Data Acquisition 73
SCCP
Planta de Chimenea Solar 68
SLFNN
Red de Capa Única y Alimentación Directa 76
SOC
Estado de Carga 83
STATCOM
Compensador Síncrono Estático 69
STD
Desviación estándar 67
STES
Almacenamiento de Energía Sensible 79
SVR
Regresión con Máquinas de Soporte Vectorial 65
TCES
Almacenamiento de Energía Termoquímica 79
TDNN
Red Neuronal de Retardo Temporal 65
TES

Almacenamiento de Energía Térmica 79
TESS
Sistema de Almacenamiento de Energía 78
THD
Distorsión Armónica Total 69
TPU
Unidad de Procesamiento Tensor 38
UE
Unión Europea 55
UTA
Unidad de Tratamiento de Aire 89
VE
Vehículo Eléctrico 81
VRF
Sistemas de Refrigerante Variable 89
WRF
Weather Research and Forecasting 72
WTB
Turbulencia de estela 71