https://repository.uaeh.edu.mx/revistas/index.php/sahagun/issue/archive

Ingenio y Conciencia Boletín Científico de la Escuela Superior Ciudad Sahagún

Publicación semestral, Vol. 12, No. 23 (2025) 38-44

ISSN: 2007-784X

Redes neuronales artificiales

Artificial neural networks

Martín Ortiz Domínguez [a]

Abstract:

A neural network is a software solution that uses machine learning algorithms to "mimic" the operations of the human brain. Neural networks process data more efficiently and offer better pattern recognition and problem-solving capabilities than traditional computers. Neural networks are also known as artificial neural networks (ANNs) or simulated neural networks (SNNs). Neural networks are a subtype of machine learning and an essential element of deep learning algorithms. Like its functionality, the architecture of a neural network is also based on the human brain. Its highly interconnected structure allows it to mimic the signaling processes of biological neurons. In summary, this article presents an introduction to artificial neural networks and also a general heuristic methodology for designing high-quality ANN solutions to various domain problems.

Keywords:

Algorithms, neural networks, machine learning, biological neuron

Resumen:

Una red neuronal es una solución de software que utiliza algoritmos de aprendizaje automático para «imitar» las operaciones del cerebro humano. Las redes neuronales procesan los datos de forma más eficiente y ofrecen mejores capacidades de reconocimiento de patrones y resolución de problemas que los ordenadores tradicionales. Las redes neuronales también se conocen como redes neuronales artificiales (RNA) o redes neuronales simuladas (SNN). Las redes neuronales son un subtipo de aprendizaje automático y un elemento esencial de los algoritmos de aprendizaje profundo. Al igual que su funcionalidad, la arquitectura de una red neuronal también se basa en el cerebro humano. Su estructura altamente interconectada le permite imitar los procesos de señalización de las neuronas biológicas. En resumen, este artículo presenta una introducción a las redes neuronales artificiales y también una metodología heurística general para diseñar soluciones RNA de alta calidad a diversos problemas de dominio.

Palabras Clave:

Algoritmos, redes neuronales, aprendizaje automático, neurona biológica

Introducción

Las redes neuronales son un subtipo de aprendizaje automático y un elemento esencial de los algoritmos de aprendizaje profundo. Al igual que su funcionalidad, la arquitectura de una red neuronal también se basa en el cerebro humano (ver Figura 1). Su estructura altamente interconectada le permite imitar los procesos de señalización de las neuronas biológicas. La arquitectura de una red neuronal consta de capas de nodos que se distribuyen en una capa de entrada, una o varias capas ocultas y una capa de salida. Los nodos son «neuronas artificiales» conectadas entre sí y asociadas a un peso y un umbral determinados. Cuando la salida de un nodo supera el umbral especificado, ese nodo se activa y sus datos se transmiten a la siguiente capa de la red. Si el valor umbral del nodo no se supera, los datos no se transmiten a la siguiente capa de la red (Abiodun et al., 2019; Singu, 2021).

[a] Autor de Correspondencia, Universidad Autónoma del Estado de Hidalgo | Escuela Superior de Ciudad Sahagún | Ciudad Sahagún-Hidalgo | México, https://orcid.org/0000-0003-4475-9804, Email: martin_ortiz@uaeh.edu.mx

Fecha de recepción: 02/11/2024, Fecha de aceptación: 06/11/2024, Fecha de publicación: 05/01/2025

DOI: https://doi.org/10.29057/escs.v12i23.14132

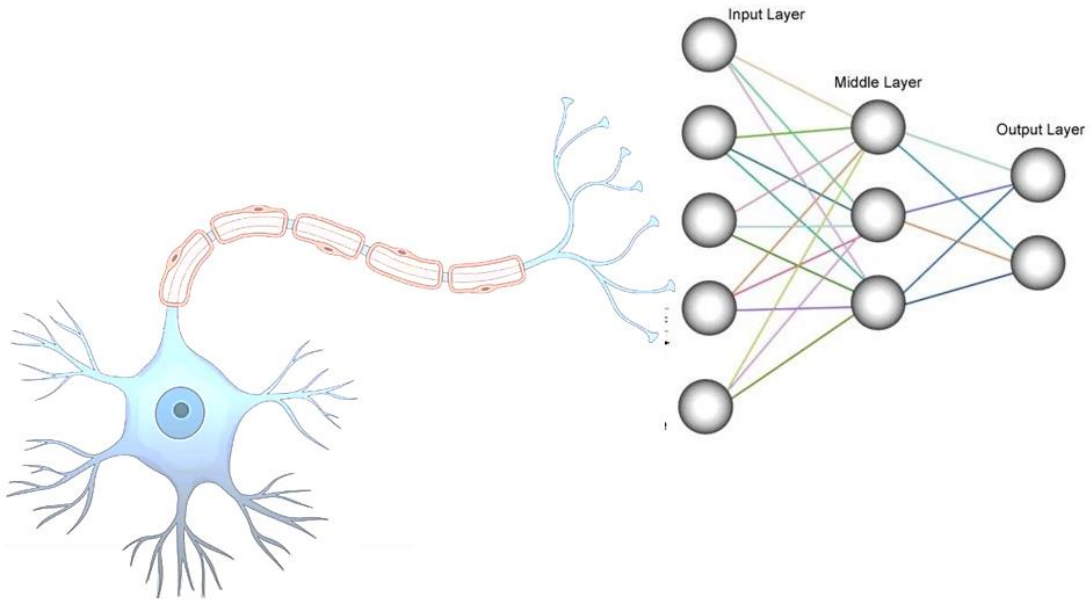

Figura 1. Arquitectura de una red neuronal. Fuente: elaboración propia.

A diferencia de las computadoras tradicionales, que procesan los datos secuencialmente, las redes neuronales pueden aprender y realizar varias tareas a la vez. En otras palabras, mientras las computadoras convencionales sólo siguen las instrucciones de su programación, las redes neuronales evolucionan continuamente mediante algoritmos avanzados. Puede decirse que las redes neuronales se «programan a sí mismos» para derivar soluciones a problemas nunca antes vistos.

Además, las computadoras tradicionales operan mediante funciones lógicas basadas en un conjunto específico de cálculos y reglas. En cambio, las redes neuronales pueden procesar funciones lógicas y entradas brutas como imágenes, vídeos y voz. Mientras que las computadoras tradicionales están listos para funcionar, las redes neuronales deben «entrenarse» con el tiempo para aumentar su precisión y eficacia. Perfeccionar la precisión de estas máquinas de aprendizaje es muy rentable y proporciona a los usuarios una potente herramienta informática para aplicaciones de inteligencia artificial (IA) y ciencias de la computación. Las redes neuronales son capaces de clasificar y agrupar datos a gran velocidad. Esto significa, entre otras cosas, que pueden completar el reconocimiento del habla y las imágenes en cuestión de minutos, en lugar de las horas que llevaría si lo realizaran expertos humanos. La red neuronal más utilizada hoy en día son los algoritmos de búsqueda de Google (Fan et al., 2019; Shams et al., 2019).

¿Cómo funciona una red neuronal?

La capacidad de una red neuronal para «pensar» ha revolucionado la informática tal y como la conocemos. Estas soluciones inteligentes son capaces de interpretar datos y tener en cuenta el contexto. Las redes neuronales siguen cuatro pasos fundamentales para funcionar con eficacia:

- La asociación o entrenamiento permite a las redes neuronales «recordar» patrones. Si al ordenador se le muestra un patrón desconocido, lo asociará con la coincidencia más cercana que tenga en su memoria.
- Clasificación u organización de datos o patrones en clases predefinidas.
- Agrupación o identificación de un aspecto único de cada instancia de datos para clasificarla incluso sin ningún otro contexto presente.
- Predicción, o producción de resultados esperados utilizando una entrada relevante, incluso cuando no se proporciona todo el contexto por adelantado.

Las redes neuronales necesitan un alto rendimiento para llevar a cabo estas funciones con precisión casi en tiempo real. Esto se consigue desplegando numerosos procesadores que funcionen en paralelo, organizados en niveles.

El proceso de creación de redes neuronales comienza con el primer nivel, que recibe los datos de entrada sin procesar. Se puede comparar con los nervios ópticos de un ser humano que recibe datos visuales. Después, cada nivel consecutivo recibe los resultados del anterior. Así hasta que la última capa procesa la información y produce el resultado. Cada nodo de procesamiento contiene su propia base de datos, que incluye todo lo que ha aprendido en el pasado y las reglas con las que fue programado originalmente o que ha desarrollado a lo largo del tiempo. Todos estos nodos y niveles están muy interconectados. El proceso de aprendizaje (también conocido como entrenamiento) comienza una vez que la red neuronal está estructurada para una aplicación específica. El entrenamiento puede ser supervisado o no supervisado. En el primero, se proporcionan a la red salidas correctas, ya sea mediante la entrega de la combinación de entrada y salida deseada o la evaluación manual del rendimiento de la red. Por otro lado, el entrenamiento no supervisado se produce cuando la red interpreta las entradas y genera resultados sin instrucciones ni apoyo externos.

La adaptabilidad es una de las cualidades esenciales de una red neuronal. Esta característica permite que los algoritmos de aprendizaje automático se modifiquen a medida que aprenden de su entrenamiento y de las operaciones posteriores. Los modelos de aprendizaje se centran fundamentalmente en la ponderación de los flujos de entrada: cada nodo asigna un peso a los datos de entrada que recibe de los nodos precedentes. Las entradas que resultan decisivas para obtener las respuestas correctas reciben una mayor ponderación en los procesos posteriores. Además de su adaptabilidad, las redes neuronales aprovechan numerosos principios para definir sus reglas de funcionamiento y tomar decisiones. La lógica difusa, el entrenamiento basado en gradientes, los métodos bayesianos y los algoritmos genéticos intervienen en el proceso de toma de decisiones a nivel de nodo. Esto ayuda a los nodos individuales a decidir qué debe enviarse al siguiente nivel en función de las entradas recibidas del nivel anterior.

Las reglas básicas sobre las relaciones entre objetos también pueden ayudar a garantizar un modelado de datos de mayor calidad. Por ejemplo, una red neuronal de reconocimiento facial puede recibir instrucciones como «los dientes están siempre debajo de la nariz» o «las orejas están a cada lado de la cara». Añadir estas reglas manualmente puede ayudar a reducir el tiempo de entrenamiento y a crear un modelo de red neuronal más eficaz. Sin embargo, añadir reglas no siempre es bueno. Hacerlo también puede llevar a suposiciones incorrectas cuando el algoritmo intenta resolver problemas no relacionados con las reglas. Precargar el conjunto de reglas equivocado puede conducir a la creación de redes neuronales que proporcionen resultados irrelevantes, incorrectos, inútiles o contraproducentes. Por eso es esencial elegir con cuidado las reglas que se añaden al sistema. Aunque las redes neuronales, y especialmente el aprendizaje no supervisado, aún tienen un largo camino por recorrer antes de alcanzar la perfección, podríamos estar más cerca de lograr un avance definitivo de lo que pensamos. Es un hecho que las conexiones dentro de una red neuronal no son ni mucho menos tan numerosas o eficientes como las del cerebro humano. Sin embargo, la Ley de Moore, que establece que la potencia media de procesamiento de los ordenadores se duplicará cada dos años, sigue prosperando. Esta tendencia da una dirección definitiva a nuestras expectativas de la IA y las redes neuronales (Abiodun et al., 2019; Shams et al., 2019; Batina et al., 2019; Hancock and Khoshgoftaar, 2020).

Tipos de redes neuronales

Las redes neuronales se clasifican en función de varios factores, como su profundidad, el número de capas ocultas y las capacidades de E/S de cada nodo (ver Figura 2) (Janiesch et al., 2021; Ouali et al., 2021).

1. Redes neuronales convolucionales

Siendo un modelo de red neuronal muy popular, las redes neuronales convolucionales aprovechan un tipo de perceptrón multicapa e incluyen una o más capas convolucionales. Estas capas pueden estar agrupadas o totalmente conectadas. Este modelo de red neuronal utiliza principios del álgebra lineal, especialmente la multiplicación de matrices, para detectar y procesar patrones en las imágenes. Las capas convolucionales de este modelo pueden crear mapas de características que capturan un área específica dentro de una entrada visual. A continuación, el área se descompone y analiza para generar resultados valiosos. Las redes neuronales convolucionales son beneficiosas para las aplicaciones de reconocimiento de imágenes basadas en IA. Este tipo de red neuronal se utiliza habitualmente en casos de uso avanzados como el reconocimiento facial, el

procesamiento del lenguaje natural (NLP), el reconocimiento óptico de caracteres (OCR) y la clasificación de imágenes. También se utiliza para la identificación de paráfrasis y el procesamiento de señales.

2. Redes neuronales deconvolucionales

Las redes neuronales deconvolucionales funcionan según los mismos principios que las redes convolucionales, pero a la inversa. Esta aplicación específica de la IA tiene como objetivo detectar señales o rasgos perdidos que pueden haber sido descartados previamente por carecer de importancia mientras la red neuronal convolucional ejecutaba la tarea que le había sido asignada. Las redes neuronales de deconvolución son útiles para diversas aplicaciones, como el análisis y la síntesis de imágenes.

3. Redes neuronales recurrentes

Este complejo modelo de red neuronal funciona guardando la salida generada por sus nodos procesadores y retroalimentándolos al algoritmo. Este proceso permite a las redes neuronales recurrentes mejorar su capacidad de predicción. En este modelo de red neuronal, cada nodo se comporta como una célula de memoria. Estas células trabajan para garantizar un cálculo y una ejecución inteligentes procesando los datos que reciben. Sin embargo, lo que diferencia a este modelo es su capacidad para recoger y reutilizar todos los datos procesados. Una de las características fundamentales de una red neuronal recurrente es la existencia de un potente bucle de retroalimentación. Estas redes neuronales pueden «autoaprender» de sus errores. Si se hace una predicción incorrecta, el sistema aprende de la retroalimentación y se esfuerza por hacer la predicción correcta mientras pasa los datos por el algoritmo la segunda vez. Las redes neuronales recurrentes se utilizan habitualmente en aplicaciones de texto a voz y en predicciones de ventas y bolsa.

4. Redes neuronales feed-forward

Esta sencilla variante de red neuronal hace pasar los datos en una sola dirección a través de varios nodos de procesamiento hasta que los datos llegan al nodo de salida. Las redes neuronales feed-forward están diseñadas para procesar grandes volúmenes de datos «ruidosos» y crear salidas «limpias». Este tipo de red neuronal también se conoce como modelo de perceptrones multicapa (MLP). La arquitectura de una red neuronal feed-forward incluye la capa de entrada, una o más capas ocultas y la capa de salida. A pesar de su nombre alternativo, estos modelos utilizan neuronas sigmoidales en lugar de perceptrones, lo que les permite abordar problemas no lineales del mundo real. Las redes neuronales feed-forward son la base del reconocimiento facial, el procesamiento del lenguaje natural, la visión por ordenador y otros modelos de redes neuronales.

5. Redes neuronales modulares

Las redes neuronales modulares constan de una serie de redes neuronales independientes cuyas operaciones son supervisadas por un intermediario. Cada red independiente es un «módulo» que utiliza distintas entradas para completar una parte concreta del objetivo general de la red más grande.Los módulos no se comunican entre sí ni interfieren en los procesos de los demás mientras se realiza el cálculo. Esto hace que la realización de procesos computacionales extensos y complejos sea más eficiente y rápida.

6. Redes generativas adversariales

Las redes generativas adversariales son una solución de modelado generativo que aprovecha las redes neuronales convolucionales y otras ofertas de aprendizaje profundo para automatizar el descubrimiento de patrones en los datos. El modelado generativo utiliza el aprendizaje no supervisado para generar conclusiones plausibles a partir de un conjunto de datos original. Las redes generativas adversariales entrenan modelos generativos creando un «problema de aprendizaje supervisado» que contiene un modelo generador y un modelo discriminador. El primero está preparado para desarrollar nuevas conclusiones a partir de la entrada. Al mismo tiempo, el segundo se esfuerza por etiquetar las conclusiones generadas como «reales» (procedentes del conjunto de datos) o «falsas» (generadas por el algoritmo). Una vez que el modelo discriminador etiqueta erróneamente las conclusiones generadas aproximadamente la mitad de las veces, el modelo generador produce conclusiones plausibles.

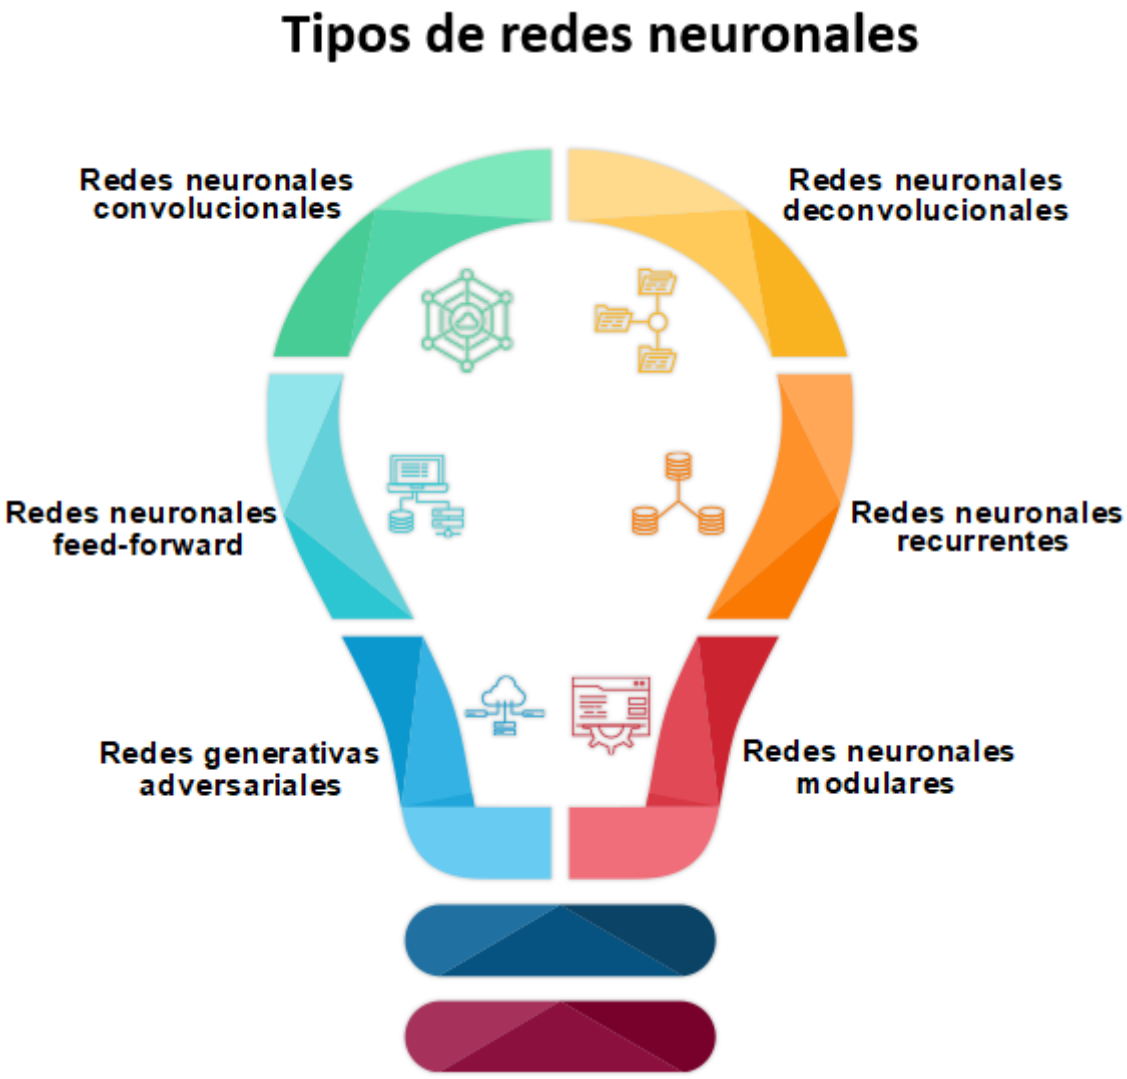

Figura 2. Tipos de redes neuronales. Fuente: elaboración propia.

Las 8 principales aplicaciones de las redes neuronales en 2024

Desde las finanzas y las redes sociales hasta la ley y el orden, las redes neuronales están hoy en todas partes. Estas son las ocho principales aplicaciones de las redes neuronales en 2024 (Pedro et al., 2020; Narkhede et al., 2022; Zhou et al., 2021; Bejani and Ghatee, 2021).

1. Ley y orden

Aunque su uso está restringido en ciertas jurisdicciones, los sistemas de reconocimiento facial están ganando popularidad como forma sólida de vigilancia. Estas soluciones cotejan rostros humanos con una base de datos de imágenes digitales. Además de alertar a las autoridades sobre la presencia de fugitivos y hacer cumplir los mandatos sobre máscaras, esta oferta de redes neuronales también es útil para permitir la entrada selectiva a lugares físicos sensibles, como una oficina. Las redes neuronales convolucionales son las más utilizadas para esta aplicación, ya que este subtipo de red neuronal es apto para el procesamiento de imágenes.

Un gran volumen de imágenes se almacena en la base de datos y se procesa posteriormente durante el aprendizaje. Para garantizar evaluaciones eficaces, se utilizan capas de muestreo en la red neuronal. Esto ayuda a optimizar los modelos y garantizar resultados precisos.

2. Finanzas

En el pasado, los mercados financieros estaban sujetos a riesgos casi imposibles de predecir. Hoy esto ya no es así: las redes neuronales han contribuido a mitigar notablemente la elevada volatilidad de los mercados bursátiles. Las redes neuronales perceptrón multicapa se utilizan para ayudar a los ejecutivos financieros a hacer predicciones bursátiles precisas en tiempo real. Estas soluciones utilizan el rendimiento pasado de las acciones, los ratios sin ánimo de lucro y los rendimientos anuales para proporcionar resultados correctos.

3. Los medios sociales

En el mundo pospandémico, las redes sociales han llegado a casi todos los nichos de la vida humana. Los usuarios a menudo se maravillan de cómo las plataformas de medios sociales pueden «leerles la mente», aunque en realidad tienen que agradecérselo a las redes neuronales. El análisis del comportamiento de los usuarios es una aplicación popular de las herramientas de redes neuronales. Las redes neuronales procesan y analizan cada minuto grandes volúmenes de contenidos generados por los usuarios. El objetivo es obtener información valiosa de cada pulsación que el usuario hace en la aplicación. Esta información se utiliza después para enviar anuncios específicos basados en la actividad, las preferencias y los hábitos de consumo del usuario.

4. Aeroespacial

Las redes neuronales desempeñan un papel fundamental en toda la industria aeroespacial, desde la ingeniería hasta el vuelo. Durante el proceso de fabricación, las redes neuronales se despliegan para un diagnóstico de fallos impecable, ya que el más mínimo defecto en un avión podría provocar la pérdida de cientos de vidas.

En la fase de formación de los operadores, estos sistemas se utilizan en el modelado de simulaciones dinámicas críticas para garantizar que la tripulación conoce adecuadamente el funcionamiento de los vuelos en la vida real. Por último, durante un vuelo, los algoritmos de redes neuronales refuerzan la seguridad de los pasajeros garantizando el funcionamiento preciso y la seguridad de los sistemas de piloto automático.

5. Defensa

En 2024 se produjo un aumento de la inestabilidad geopolítica en Asia y Europa, por lo que las soluciones de defensa probadas están adquiriendo una gran importancia para todos los países. Una postura de defensa sólida permite a un país obtener un reconocimiento favorable en la escena mundial. Las redes neuronales desempeñan un papel cada vez más valioso en las operaciones de defensa de las naciones con ejércitos tecnológicamente avanzados. Los ejércitos de Estados Unidos, Reino Unido y Japón ya utilizan soluciones de redes neuronales para desarrollar potentes estrategias de defensa. En el ejército, las redes neuronales se utilizan en la localización de objetos, el análisis de ataques armados, la logística, el control automatizado de drones y las patrullas aéreas y marítimas. Por ejemplo, se despliegan vehículos autónomos equipados con soluciones de redes neuronales convolucionales para buscar minas submarinas.

6. Sanidad

Las pruebas basadas en imágenes son un pilar básico de la industria sanitaria, que aprovecha la destreza de procesamiento de imágenes de las redes neuronales convolucionales para detectar enfermedades. Este tipo de redes neuronales se utiliza en diversas aplicaciones sanitarias de vanguardia, como el procesamiento de radiografías, tomografías computarizadas y ecografías. Los datos recogidos en las pruebas de imagen médica mencionadas se analizan mediante soluciones automatizadas para proporcionar información médica procesable. Además, las redes neuronales generativas se están utilizando en la investigación para el descubrimiento de fármacos. Estas soluciones simplifican la clasificación de las distintas categorías de fármacos. Se descubren nuevas combinaciones de fármacos fusionando rápidamente las propiedades de varios elementos y comunicando los resultados.

7. Análisis de firmas y caligrafía

Las soluciones de verificación de firmas basadas en IA se están convirtiendo poco a poco en la norma en los ámbitos financiero, administrativo y afines. Las instituciones financieras y las burocracias confían en la verificación de firmas para comprobar la identidad de los usuarios finales y evitar transacciones fraudulentas. Hasta la década pasada, el análisis de firmas por parte de personal administrativo humano era la norma para

verificar la autenticidad de la documentación, lo que facilitaba la comisión de fraudes. Sin embargo, con la llegada de las redes neuronales para la verificación de firmas, diferenciar entre firmas auténticas y falsificadas (tanto en línea como fuera de línea) se ha vuelto más accesible. El análisis de la escritura manuscrita es una aplicación relacionada de las redes neuronales que desempeña un papel vital en la investigación forense. El análisis de escritura a mano basado en IA se utiliza para evaluar documentos manuscritos con numerosos fines, como la verificación de identidad y el análisis del comportamiento.

8. Meteorología

La meteorología es una parte vital de la vida diaria, ya que ayuda a la gente a prepararse con antelación para las condiciones meteorológicas que se avecinan e incluso a predecir la posibilidad de desastres naturales. Con la entrada de las redes neuronales en el campo de la meteorología, las previsiones meteorológicas son más precisas. Se están utilizando redes neuronales convolucionales, perceptrones multicapa y redes neuronales recurrentes para aumentar la precisión de las previsiones meteorológicas. Se está demostrando que los modelos de redes neuronales multicapa predicen el tiempo con precisión hasta con 15 días de antelación. Datos como la humedad relativa, la temperatura del aire, las radiaciones solares y la velocidad del viento se utilizan para entrenar modelos de redes neuronales para aplicaciones meteorológicas. También se están combinando distintos tipos de redes neuronales para predecir el tiempo con exactitud.

Conclusiones

Las redes neuronales son una aplicación disruptiva de la inteligencia artificial, que permite utilizar los poderes de resolución de problemas del aprendizaje profundo para mejorar nuestra calidad de vida. Las técnicas de redes neuronales se utilizan cada vez más para abordar retos abstractos, como el diseño de fármacos, el procesamiento del lenguaje natural y la verificación de firmas. A medida que las redes neuronales sigan haciéndose más rápidas y precisas, en el futuro, el progreso tecnológico de la humanidad se verá reforzado de forma significativa.

Referencias

Abiodun, I. Oludare, J. Aman, E. Abiodun Esther Omolara, K. Victoria Dada, A. Malah Umar, U. Linus Okafor, H. Arshad, (2019) A. Aminu Kazaure, U. Gana, and M. Ubale Kiru, "Comprehensive review of artificial neural network applications to pattern recognition," IEEE Access, vol. 7, pp. 158820-158846.

Batina, L., Bhasin , S., Jap, D. and Picek , S., (2019). "CSI NN: Reverse engineering of neural network architectures through electromagnetic side channel," 2019.

Bejani, M. M. and Ghatee, M., (2021). "A systematic review on overfitting control in shallow and deep neural networks," Artificial Intelligence Review, pp. 1-48.

Fan ,F., Xiong, J., Li, M. and Wang, G., (2021) "On interpretability of artificial neural networks: A survey," IEEE Transactions on Radiation and Plasma Medical Sciences, vol. 5, no. 6, pp. 741-760.

Hancock, J. T. and Khoshgoftaar, T. M., (2020) "Survey on categorical data for neural networks," Journal of Big Data, no. 1, pp. 1-41.

Janiesch, A., Zschech, P., and Heinrich, K., (2021). "Machine learning and deep learning," Electronic Markets, vol. 31, no. 3, pp. 685-695.

Ouali, Y., Hudelot, C. and Tami, M., (2020). "An overview of deep semi-supervised learning," arXiv preprint arXiv:2006.05278.

Pedro, O. P., Almahairi, A., Benmalek, R., Golemo, F. and Courville, A. C., (2020). "Unsupervised learning of dense visual representations," Advances in Neural Information Processing Systems 33, pp. 4489-4500.

Narkhede, M. V., Bartakke, P. P. and Sutaone, M. S., (2022). "A review on weight initialization strategies for neural networks," Artificial Intelligence Review, vol. 55, no. 1, pp. 291-322.

Singu S. (2021), "Comparative Analysis of Artificial Neural Networks," International Journal of Machine Learning for Sustainable Development, vol. 3, no. 4.

Shams, S., Jahani, A., Kalantary, S., M. Moeinaddini, and Khorasani, N., (2021). "The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO2 concentration," Urban Climate, vol. 37, p. 100837.

Zhou, F., Xu, X., Trajcevski, G. and Zhang, K., (2021). "A survey of information cascade analysis: Models, predictions, and recent advances," ACM Computing Surveys (CSUR), vol. 54, no. 2, pp. 1-36.