

La industria 4.0 y las redes neuronales artificiales en la ingeniería industrial: Una revisión sistemática de la literatura

Industry 4.0 and artificial neural networks in industrial engineering: A systematic review of the literature

Marco Díaz-Martínez^{1,*}, Reina Román-Salinas¹, Gil Santana-Esparza¹, Mario Morales-Rodríguez²

¹Tecnológico Nacional de México-(ITSP-Pánuco). Prol. Avenida Artículo Tercero Constitución s/n, Solidaridad, 93998 Pánuco. México.

²Universidad Autónoma de Tamaulipas-Unidad Académica Multidisciplinaria, Reynosa, Aztlán

*Autor de correspondencia: marco.dm@panuco.tecnm.mx

Este documento posee una [licencia Creative Commons Reconocimiento/No Comercial 4.0 Internacional](#)



Recibido: 30 marzo 2023 Aceptado: 11 mayo 2023 Publicado: 15 mayo 2023

Resumen

Las redes neuronales artificiales (RNA) han presentado un papel importante con la entrada de la cuarta revolución industrial y las nuevas tecnologías para resolver problemas en diferentes áreas de la ingeniería industrial. Si bien la cuarta revolución industrial está muy ligada a la ingeniería industrial, las redes neuronales son muy complejas en comparación a los métodos tradicionales de control de procesos u optimización de procesos industriales. Se conoce muy poco de esta técnica y sus aplicaciones en el campo de la ingeniería industrial. La presente investigación tiene por objetivo realizar una revisión sistemática de la literatura para conocer las aplicaciones y usos de esta técnica de redes neuronales en la ingeniería industrial. Se incluyen un total de 48 obras científicas que están distribuidas de la siguiente forma: 1 en Redib, 7 en Taylor & Francis, 2 en Springer, 14 en Researchgate, 5 en Scielo, 1 en Dialnet, 3 en Ebsco, 7 en ScienceDirect, 1 en Redalyc, 3 en Google Académico y 4 en páginas web además de repositorios especializados en el tema. De estas obras científicas se encontró que las RNA son utilizadas para predecir y ayudar a diferentes campos de estudio de la ingeniería industrial, 10 aplicaciones en industria 4.0, 8 para aplicaciones en modelos y análisis 3D, 9 enfocados a análisis de cadena de suministro, 8 en Big Data y 13 aplicaciones en manufactura aditiva y máquinas herramientas.

Palabras clave: Industria 4.0, redes neuronales artificiales, ingeniería industrial.

Abstract

Artificial neural networks (RNA) have presented an important role with the entry of the fourth industrial revolution and new technologies to solve problems in different areas of industrial engineering. Although the fourth industrial revolution is closely linked to industrial engineering, neural networks are very complex compared to traditional methods of process control or optimization of industrial processes. Very little is known about this technique and its applications in the field of industrial engineering. The objective of this research is to carry out a systematic review of the literature to know the applications and uses of this technique of neural networks in industrial engineering. A total of 48 scientific works are included, distributed as follows: 1 in Redib, 7 in Taylor & Francis, 2 in Springer, 14 in Researchgate, 5 in Scielo, 1 in Dialnet, 3 in Ebsco, 7 in ScienceDirect, 1 in Redalyc, 3 in Google Scholar and 4 in web pages as well as

specialized repositories on the subject. Of these scientific works, it was found that ANN are used to predict and help different fields of study of industrial engineering, 10 applications in industry 4.0, 8 for applications in models and 3D analysis, 9 focused on supply chain analysis, 8 in Big Data and 13 applications in additive manufacturing and machine tools.

Keywords: Industry 4.0, artificial neural networks, industrial engineering.

1. Introducción

La industria 4.0 es la evolución a un mundo de nuevas tecnologías (Figura 1). La integración de toda la información produce una gran cantidad de información que ayuda a tener un mejor control de los procesos en tiempo real, permitiendo mantenimientos predictivos eficaces [1].



Fig.1 Industria 4.0 y las nuevas tecnologías

En el campo de los procesos de fabricación, avances de la ciencia y la tecnología apoyan continuamente el desarrollo de la industrialización en todo el mundo [2]. Una revolución industrial desde una perspectiva de la evolución tecnológica, se identifica en cuatro etapas comunes [3,4] en las que los primeros tres tomaron alrededor de dos siglos y son el resultado, respectivamente: 1) la introducción de agua y vapor en el funcionamiento de los procesos mecánicos; 2) la aplicación de tecnologías de producción en masa y 3) la combinación de electrónica y tecnologías de la información (TI) para generar un respaldo hacia la automatización de los procesos industriales y de fabricación [5]. Por otro lado, la intervención del Internet de las cosas (IoT) en los procesos industriales, así como a los ciber-sistemas (CPS), gobiernos e industrias de todo el mundo, han notado que son elementos importantes esta nueva revolución industrial 4.0 [6,7].

Por otro lado, las redes neuronales artificiales RNA (ANN- *Artificial Neural Networks*) representan un gran número de neuronas simuladas e interconectadas entre sí [8] (figura 2). De acuerdo con la empresa International Business Machines (IBM) en 2021, menciona que las redes neuronales son análisis de modelos sencillos sobre el desempeño del sistema nervioso o estructura de una red neuronal [9].

Las RNA se encuentran estructuradas por componentes que presentan un comportamiento de similitud en sus funciones más comunes. Estos componentes se encuentran organizados de una manera muy parecida a la del cerebro de una persona. Tienen la característica de aprender y obtener un conocimiento al exponerlas a estudiar, ejercitarse o experimentar. Es decir, que de acuerdo con el entrenamiento de las entradas tienen la capacidad de generar resultados o salidas lo más consistente posible. Ofrecen resultados correctos a posibles entradas que contienen una variación pequeña que

puedan ser ocasionados por aspectos frecuentes o relativos. También tienen la capacidad de aislar las cualidades o características de los objetos analizados y en algunos casos tienen la capacidad de aislar la esencia de las entradas que no presenten algún indicio o aspecto común [10].

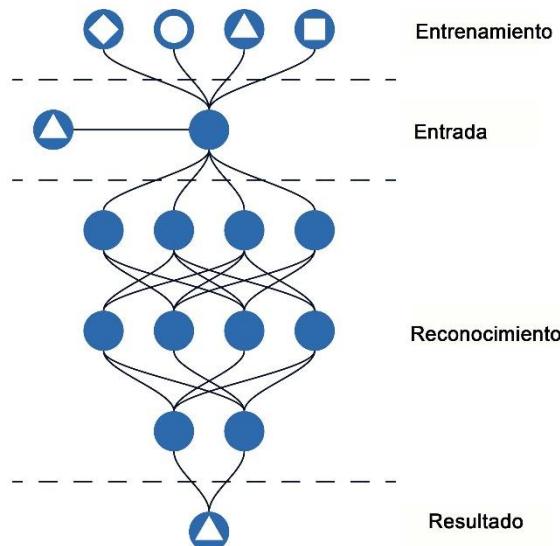


Fig.2 Fases de una red neuronal

Las ventajas de las redes neuronales es que presentan habilidades de aprendizaje y adaptación para realizar las actividades desde un conjunto de información representada como entradas que tienen la capacidad de auto-organizar y aprender las operaciones recibidas y aplicación de métodos matemáticos [11].

Existen algunos tipos de redes neuronales como Adeline (*Adaptive Linear*) y Madaline (*Multiple Adaptive Linear Element*). El primero tiene el objetivo de sumar los pesos de las entradas como patrones binarios con 0 y 1, este elemento es importante ya que será capaz de generar redes con mucha más complejidad. Madaline es considerada como la primera red neuronal de tipo multicapa y tiene el objetivo de dar solución a los problemas linealmente separables. También existe la red *Backpropagation*, que tiene la habilidad de analizar el aprendizaje de la asociación y comunicación de cada uno de los patrones que contiene la red [12]. Finalmente se tiene la red de tipo *perceptrón capa* el cuales se compone de varias neuronas, la cual facilita la comunicación a través del envío de señales interrelacionadas entre sí y que además no tiene la capacidad de reconocer características complejas [13].

En ingeniería industrial e ingeniería de procesos industriales se han implementado las redes neuronales artificiales en áreas de control de procesos, calidad, análisis y detección de fallos operacionales [14].

El objetivo de esta investigación es analizar y conocer la importancia de las RNA, la industria 4.0 y su aplicación en ingeniería industrial; para lo cual se hizo una revisión sistemática de las investigaciones más relevantes donde se hayan aplicado modelos de RNA en diferentes áreas de la ingeniería industrial. De igual manera, se pretende identificar las ventajas de las RNA sobre las técnicas estadísticas más utilizadas, para así persuadir su utilización en la ingeniería industrial.

2. Revisión de la literatura

2.1 Redes neuronales en la industria 4.0

La empresa *Cibernos make IT easy* utiliza una forma adecuada de analizar el comportamiento de una máquina de producción y es escucharla en pleno funcionamiento, de igual manera en arranques y paradas. Con una red neuronal bien entrenada se puede hacer un análisis a la máquina y si está arrojando señales de un mal funcionamiento o indicios de posible avería de alto impacto [15].

Otra de las aportaciones relacionada con resultados en tiempo real en los procesos industriales es detectar un mal funcionamiento y la reducción de desperdicios de scrap de aluminio generados por los procesos de producción de inyección de fundición; en las empresas automotrices han utilizado las redes neuronales para realizar la predicción de los parámetros óptimos, logrando una reducción del 25% de los defectos relacionados como falta de material y fisuras. Se pudo visualizar gran utilidad la que representó el uso de la industria 4.0 y las redes neuronales [16].

Investigaciones realizadas por la Universidad Autónoma de Barcelona mencionan que con la aparición de la industria 4.0 y la intervención de las redes neuronales artificiales han impulsado a la generación de un nuevo entendimiento de los diferentes procesos industriales [17]. Se han desarrollado algoritmos basado en redes neuronales artificiales, que han sido entrenadas con el fin de identificar los procesos de manufactura aditiva óptimos para diferentes diseños de piezas desarrollados en sistemas CAD (Diseño asistido por computadora). Se utilizó un modelo de precisión de dos capas obteniendo un 90% de predicción, generando un aumento de factores de entrada. La industria 4.0 y las redes neuronales han sentado las bases para el desarrollo de un diseño cibernetico aditivo para sistemas de producción [18].

El análisis de la arquitectura de redes neuronales ha demostrado tener un rendimiento excepcional en los campos de la inteligencia artificial y el procesamiento de imágenes. Estas innovaciones han permitido una transición estable a la industria 4.0, que depende en gran medida de la automatización de tareas a través del aprendizaje profundo y la visión artificial [19].

En el trabajo de Bansond et al. [20]; se analizó, comparó y comprobó, ocho modelos de redes neuronales artificiales para el análisis y monitoreo de predicción la falla del sistema de la maquinaria de turbinas eólicas en función de las señales del sensor de los componentes internos y la temperatura, empleando un enfoque de modelo de aprendizaje con dos capas ocultas usando regresión lineal multicapa. El sistema desarrollado predijo la salida de temperatura del generador de las turbinas eólicas con una precisión del 99,8% con 2 meses de anticipación a la predicción de la medición. Esto ha creado un cambio en la forma en que los equipos industriales pueden monitorearse y diagnosticarse con la ayuda de las redes neuronales y la industria 4.0.

También otro de los trabajos relacionados con la industria 4.0, propone el uso de redes neuronales artificiales en modelos de simulación con eventos discretos para determinar la distribución actual del resultado de cada evento. Esto permite un modelado más realista y preciso del comportamiento estocástico utilizando datos actuales para predecir el futuro [21].

Antes de la llegada de la cuarta revolución industrial se tenían problemas como la automatización de voz y reconocimiento de imágenes, a pesar de muchos logros en estos campos los problemas cotidianos de gestión siguen siendo los mismos, que suelen evadir la aplicación de métodos formales y se pueden tratar estos problemas mediante la aplicación de un tipo específico de redes neuronales autoejecutables (SEN) y la intervención la industria 4.0 que ayudan a tener un modelo

más simple de diferentes problemas comerciales cotidianos, así como la análisis y agrupación de datos complejos [22].

Arbella et al. [23] realizaron una investigación relacionada con el monitoreo de las condiciones de las turbinas de viento, aplicando técnicas como las redes neuronales y la intervención de la industria 4.0 para definir modelos matemáticos para predecir, modificar, validar y optimizar comportamientos técnicos. También utilizaron métodos de pronóstico y software de diseño por computadora (CAD-CAE), con el fin de validar los valores del estado térmico de las turbinas.

También ha impulsado avances en el desarrollo de plataformas relacionadas con los vehículos guiados automatizados (AGV), la intervención de sensores y redes neuronales para aplicaciones de industria 4.0.

Otro de los temas sobre los cuales las redes neuronales y la industrial 4.0 han participado es en el mejoramiento del rendimiento de radiofrecuencia donde el autor Simon et al. [24], implementa elementos del IoT en el diseño de un vehículo guiado automatizado (AGV) como el ESP32, que es un 2.4 Chip Wi-Fi de GHz y Bluetooth, diseñado con una potencia de tecnología muy bajo TSMC de 40 nm. Este chip está diseñado para ofrecer el mejor rendimiento de radiofrecuencia (RF), demostrando flexibilidad, versatilidad y confiabilidad en una variedad de aplicaciones y perfiles. También se utilizó un chip de modo dual integrada ESP32 que está diseñado para dispositivos móviles, portátiles e Internet de las cosas (IoT). Las características involucran una planificación inteligente de rutas y navegación AGV que debe adaptarse al movimiento y seguridad en entornos desconocidos, los cuales pueden presentar obstáculos relacionados con el tamaño y forma arbitrarios que puedan moverse. La intervención de las redes neuronales en este trabajo ayudó a determinar una dirección segura en todo el entorno de movimiento y puntos de la ruta evitando obstáculos.

2.2 Redes neuronales y el modelado en 3D

2.2.1 Modelado en 3D de tumores cerebrales

Serna et al. [25] presentan una metodología para el modelado en 3D de tumores cerebrales con redes neuronales de tipo gas (NGN). Se desarrolló en dos etapas: entrenamiento fuera de línea y adaptación en línea. Se utilizó una base de datos compuesta de 7 x 104 marcos que corresponde a 4.86 horas de trabajo para análisis de la información. Se utilizó solo el 10% de los datos para el inicio y 90% para adaptación del modelo. Este trabajo muestra una solución sencilla y eficiente al problema de la adquisición y modelado de información 3D sin supervisión para tumores cerebrales.

2.2.2 Modelado e impresión 3D de mano robótica

Otra de las aplicaciones del modelado en 3D es un prototipo de mano robótica controlada a través de señales cerebrales, utilizando redes neuronales. En esta investigación se procedió a realizar un entrenamiento a partir de una muestra inicial de trece personas, utilizando el sensor no invasivo Mindwave Mobile 2. Logrando una precisión del 77% como una primera aproximación con el objetivo de brindar a las personas una mayor calidad de vida [26].

En el año de 2020, se desarrolló un algoritmo basado en redes neuronales y sensores de señal muscular tipo (EMG), capaces de generar un accionamiento de una pequeña prótesis robótica modelada e impresa en 3D. Estos elementos han optimizado la capacidad de poder tener un mejor control y hacer mucho más fácil el manejo de la prótesis. El número de muestras y el tiempo que se toma para realizar el muestreo dependerá la velocidad de aprendizaje de la red neuronal. Los datos obtenidos son almacenados en dos grupos donde el primer grupo está basado en el entrenamiento

de la red neuronal y el segundo se encarga de la validación de la información de ésta. Contar con una calidad de la base de datos ayuda de manera muy notable en el entrenamiento de la red neuronal para que responda siempre de forma adecuada a las necesidades del usuario final [27].

Yanga et al. [28] mencionan que los brazos robóticos son poderosos asistentes en muchos entornos de producción industrial y se ejecutan periódicamente de acuerdo con acciones. Contar con una arquitectura de aprendizaje profundo basada en convolución 3D para el reconocimiento de acciones anormales y una capa convolucional 3D puede extraer las características espaciales y temporales de los movimientos del brazo robótico.

2.2.3 Extracción de objetos y procesamiento de imágenes en 3D

Una investigación desarrollada por [29]; presenta una técnica que puede extraer en 3D objetos mediante el análisis y procesamiento de imágenes mediante una línea de luz. Mediante el uso de redes neuronales que tiene la capacidad de reconstruir la forma en 3D del objeto. La generación de la red neuronal está basada en capas, conexiones que reciben la información para ser procesada y obtener imágenes de los objetos de acuerdo con las dimensiones determinadas por la línea de luz. Este método es de una alta precisión ya que es una técnica que se genera a partir del valor *rms* (raíz cuadrática media / root medium square) y tiene la capacidad de presentar una alta precisión en los resultados ya que no existe posibilidad de errores de mediciones externas o ajenas al modelo.

La impresión 3D se ha vuelto popular recientemente debido a sus excepcionales ventajas sobre los procesos de fabricación convencionales. Sin embargo, el proceso de impresión 3D es difícil de optimizar, ya que influye en las propiedades y el tiempo de uso de piezas impresas [30].

Otra de las investigaciones alineadas a las redes neuronales y la 3D fue la del autor [31], quien realizó una propuesta de arquitectura de representación de ocupación volumétrica utilizando redes neuronales convolucional 3D y poder reconocer objetos en tiempo real. En este trabajo se utilizaron sensores de alcance de tipo LiDAR y RGBD las cuales son muy eficaces para la obtención de la información 3D.

2.2.4 Detección de imágenes de vehículos aéreos basada en mapas 3D

Javadi et al. [32] realizaron una investigación sobre la detección de objetos en imágenes aéreas, particularmente de vehículos y las aplicaciones de detección remota, incluida la gestión del tráfico, la planificación urbana, la utilización de espacios de estacionamiento, la vigilancia y la búsqueda y rescate. En este artículo, se investigó la capacidad de los mapas de características tridimensionales (3D) para mejorar el rendimiento de la red neuronal profunda (DNN) para la detección de vehículos generando mapas de profundidad 3D utilizando pares de imágenes aéreas y su desplazamiento de paralaje. Se entrenó una red neuronal completamente conectada (fcNN) en mapas de características 3D de camiones, semirremolques y remolques. Luego se propuso una cascada de estas redes para detectar vehículos en imágenes aéreas. Una vez que la DNN detectó una región, se usaron coordenadas y niveles de confianza para extraer las características 3D correspondientes. En consecuencia, el sistema propuesto pudo eliminar con éxito del 72.22 % al 100 % de los falsos positivos de las salidas de la DNN. Estos resultados indican la importancia de la utilización de características 3D para mejorar la detección de objetos en imágenes aéreas para futuras investigaciones.

2.3 Redes neuronales y la gestión de la cadena de suministro

2.3.1 Planificación, control de la demanda y mejoramiento de los niveles de inventarios en la cadena de suministro

Las organizaciones necesitan tener suficiente información para poder tomar las mejores decisiones y puedan satisfacer a los clientes, siendo una prioridad latente. Las organizaciones están cada día buscando nuevas técnicas que logren un mejor control de la planificación y de calidad en los planes de producción que den respuesta a los cambios repentinos de la demanda. Para lograr estos objetivos [33] desarrolló un sistema que puede pronosticar la demanda en la cadena de suministro basado en redes neuronales y lógica difusa. Con la implementación de este sistema se quiere lograr la prevención de la demanda y con la intervención de las redes neuronales podrán tener una solución adecuada y controlar de una manera estable la prevención de demanda. Las organizaciones han encontrado que las redes neuronales son una ventaja en el entorno empresarial y con la previsión de tomar las mejores decisiones respecto a la fabricación y gestión de inventarios [34]. Otra de las áreas donde también ha tenido participación las redes neuronales en el campo de la cadena de suministro es para la predicción del consumo de los materiales y repuestos.

En la investigación de [35] desarrolló un trabajo que determina la importancia de las redes neuronales y que son una herramienta eficiente para el pronóstico de diferentes materiales y repuestos que son mucho mejores que las técnicas de pronóstico existentes. De acuerdo con los resultados el autor menciona que contar con una buena planificación de consumos se puede considerar como una ventaja competitiva, reducir costos de oportunidad y mejores niveles de inventarios.

Otro de los trabajos aplicados a las organizaciones que están relacionados con redes neuronales y la cadena de suministro es un procedimiento para efectuar el pronóstico de la demanda en una empresa dedicada a la comercialización y distribución de medicamentos. Este procedimiento cuanta con tres fases. La primera fase de análisis compila la información para la aplicación del instrumento principalmente utilizando el análisis de Pareto y la obtención de dicha información dependerá de las variables como: precio del producto, tipo de cliente, segmentación de mercado y oportunidades de los suministros para fabricación y ofertas. La segunda fase es trabajar con un tipo de arquitectura de una red neuronal perceptrón multicapa (RNAPM) con una salida entrenada por retropropagación del error. La tercera fase se encarga de detectar las desviaciones existentes en los resultados obtenidos, es decir, pronosticar la cantidad de demanda y reducir el margen de error. Este modelo es confiable para devenir en un recurso de fácil aplicación [36].

2.3.2 Control de la cadena de suministro en la industria de circulación comercial

El control y regulación de la cadena de suministro puede proporcionar un financiamiento adecuado para pequeñas y medianas empresas en la industria de circulación comercial. Es necesario analizar las causas de los riesgos en la financiación de la cadena de suministro de la industria de circulación comercial y medir estos riesgos mediante el establecimiento de un sistema de evaluación del riesgo crediticio con la intervención de redes neuronales.

De acuerdo con [37]; realizó una investigación donde establece un sistema de índice de alerta temprana de riesgo financiero de la cadena de suministro, que incluye 4 indicadores de primer nivel y 29 indicadores de tercer nivel. La metodología consiste en la construcción de un modelo de alerta temprana de riesgo financiero de la cadena de suministro de la industria de circulación comercial, y el índice de evaluación se mide por el método de análisis de componentes principales.

Finalmente, se seleccionan los datos relevantes de las empresas de circulación comercial para hacer un análisis empírico del modelo. La conclusión muestra, que el modelo de alerta temprana de riesgos financieros de la cadena de suministro y las medidas de control de riesgos establecidas en este artículo, tienen cierto valor de referencia para que la industria de circulación comercial lleve a cabo el financiamiento de la cadena de suministro. También proporciona orientación para que las empresas de circulación comercial aborden los riesgos financieros de la cadena de suministro de manera efectiva.

2.3.3 Análisis de riesgos crediticios sobre el financiamiento de la cadena de suministro

El autor [38] realizó un trabajo para poder evaluar el proceso de evaluación de riesgo crediticio sobre el financiamiento de la cadena de suministro, utilizando el método de máquina de intervención de vectores de soporte y redes neuronales. Los resultados obtenidos indicaron que la brecha de capacidad en las empresas fue relativamente grande con una desviación estándar mayor al 30%, presentaron buena calidad en sus inventarios. El algoritmo utilizado en el método de máquina de vector presentó un resultado de 76.27% y la precisión de la red neuronal fue de 89.83%. Todos estos resultados tienen el propósito de reducir la probabilidad de daño en las ganancias de un banco y el aumento de la rentabilidad de este. La evaluación del riesgo financiero de la cadena de suministro de las PYME (pequeña y media empresa), se explora principalmente a partir de la perspectiva de los bancos. Los resultados pueden proporcionar apoyo teórico para reducir la probabilidad de daño a las ganancias del banco y el aumento de la rentabilidad de éste. También las organizaciones han notado una optimización en sus diferentes procesos de la cadena de suministro con la intervención de redes neuronales, que han mejorado la sostenibilidad en los diferentes niveles y campos de acción de la cadena de suministro para controlar posibles riesgos y prevenirlos [39].

2.3.4 Transformación digital como impacto en la cadena de suministro de fabricación

Este tema ha generado controversias entre los gerentes y directivos dedicados a analizar nuevas estrategias en el ramo manufacturero. La importancia de la transformación digital tiene origen en la digitalización de la cadena de suministro de fabricación (CSF). El autor menciona que es de suma importancia identificar y predecir los factores asociados al riesgo hacia una transformación digital. En este trabajo, se realizó un análisis de componentes principales para crear la estructura de una red neuronal de retropropagación (BPNN) para mejorar la eficiencia de la velocidad y entrenamiento de las capas de la red neuronal. Los resultaron mostraron que la intervención de las redes neuronales presenta un buen efecto predictivo, y que, con el análisis de componentes principales, se logra un buen efecto de evaluación para una transformación digital fluida [40].

2.3.5 Mejoramiento de algoritmos para el diseño de cadenas de suministro a gran escala

En la siguiente investigación el autor [41] menciona que el sistema de gestión de la cadena de suministro puede ayudar a que una organización trabaje de manera rápida y adecuada, comenzando con la comprensión fundamental de cada idea, incluyendo producción, inventario, ubicación y transporte. El autor propone un método basado en FPGA (Field Programmable Gate Arrays) y redes neuronales para la gestión de la cadena de suministro. El resultado de la implementación de esta metodología dio como resultado que la cadena de suministro pueda ser flexiblemente al igual que el plan del ejecutivo, y que las operaciones sean las más adecuadas sin mucho esfuerzo, limitar la confusión y que pueda ser resuelta en un breve período.

2.4 Redes neuronales y Big Data

El autor [42] menciona que, gracias al Big Data, la inteligencia artificial y redes neuronales son capaces de generar características dinámicas con tendencias importantes como la predicción y sustento en la toma de decisiones. En temas de producción tienen la capacidad de conocer mejor el mercado, cliente, los productos y servicios ofrecidos por una empresa. De igual manera, tener una mejor visión de mejores estrategias de negocio y poder predecir el comportamiento.

Los procesos de fabricación generan una gran cantidad de información, las cuales pueden aumentar y proporcionar información para aumentar la producción y generar ventajas competitivas a través de la mejora continua. La intervención de redes neuronales, Big Data y algoritmos han venido a generar una ventaja competitiva del fabricante a través de la mejora, sostenibilidad, flexibilidad y productividad de las operaciones [43].

2.4.1 *Las ciudades inteligentes y el mejoramiento de Big Data*

Una de las tecnologías que involucra la industria 4.0 es Big Data, la cual ha ido evolucionando en sus relaciones con la manufactura, control y programación inteligente, permitiendo un vínculo entre los equipos físicos y virtuales mediante sistemas ciber-físicos (CPS) que han marcado una producción industrial 4.0 [44].

Al-Badi et al. [45] realizó un estudio en el que se elabora un modelo de red neuronal para ciudades inteligentes, que consta de algunas variables predictoras que están basadas en el desarrollo sostenible de ciudades inteligentes. Los resultados obtenidos se analizaron en un modelo de red neuronal. Las variables que contribuyen al desarrollo sostenible en ciudades inteligentes son Big data en economía con un resultado de 0.299, Big data en gobernanza con un 0.251, Big data en urbanismo 0.225, y Big data en gestión de recursos con 0.224. Este modelo de red neuronal fue capaz de predecir correctamente el 60 % durante la formación y el 72.6 % durante las pruebas para el desarrollo sostenible en ciudades inteligentes.

2.4.2 *Sistemas predictivo y análisis de Big Data basado en redes neuronales*

La siguiente investigación presenta un sistema de predicción y análisis de Big Data basado en redes neuronales convolucionales. La combinación de servicios Big Data se combina con métodos de detección de elementos coincidentes, detección de elementos frecuentes y regla de asociación extracción de características de datos de fusión de alta dimensión. Se adopta un método de agrupamiento para realizar la clasificación y minería de datos en la nube. Los resultados experimentales muestran que la precisión de la minería de datos por este método es 12.43% y 21.76% superior a la de los métodos tradicionales, y el número de pasos de iteración es más corto, lo que indica que la puntualidad de la minería es mayor. Está probado que este tipo de arquitectura de la red puede mejorar considerablemente la velocidad de entrenamiento precisión de la red neuronal [46].

En el año 2019 se realizó un avance importante creando dos nuevos tipos de arquitectura de redes neuronales híbridas para clasificación del Big Data. La primera llamada Morfológica-Lineal que tiene la capacidad obtener las características mediante el uso de una capa de salida de perceptrones. El segundo tipo red neuronal llamada morfológica neuronal, está compuesta por varias capas de perceptrón como objetivo de extracción y es precedido por una capa de salida de neuronas morfológicas para generar una clasificación de tipo no lineal. Una de las principales contribuciones de este trabajo, fue mostrar que la capa morfológica ofrece una mayor capacidad para extraer características que la capa de perceptrón y que está respaldada tanto teórica como

experimentalmente. Se comprobó que la capa morfológica presenta una mayor capacidad por unidad de cómputo para seccionar el espacio de entrada 2D que la capa perceptrón. Es decir, contar con más hiper-cajas da como respuesta el obtener más regiones de respuesta que agregar hiperplanos. Desde un punto de vista empírico, se probaron los dos nuevos modelos en 25 conjuntos de datos estándar de baja dimensionalidad y un conjunto de datos de gran tamaño. El resultado es que la red morfológica-Lineal requiere un número menor de parámetros de aprendizaje que las otras arquitecturas probadas y obtiene mejores precisiones [47].

Araque et al. [48] realizaron una investigación de tipo descriptivo, donde expone diferentes escenarios asociados al Big Data y los divide en tres sectores: logística, economía y salud. La intervención de las redes neuronales, Big Data y la industria 4.0 muestran que la integración de hardware y software en los procesos industriales, muestran lo indispensable e importante que son para lograr la mejora continua y calidad en el servicio de los diferentes sectores evaluados. Otro de los sectores que ha sido objeto de análisis de mejoramiento utilizando la técnica de redes neuronales y, que puede acortar el tiempo de modelación de planes estratégicos y obtener resultados predictivos para la mejora de exportación de productos, son las ventas por comercio electrónico [49].

2.5 Redes neuronales en los procesos de manufactura

2.5.1 Control y manejo de la información en el proceso por arranque de viruta

En la ingeniería industrial relacionados con la industria 4.0 se encuentran temas como procesos de manufactura, redes industriales, sistemas automatizados, mejora continua, cadenas de suministro y logística, etc. En el tema de la manufactura aplicada tenemos procesos, en los cuales se cuentan con equipos convencionales o que por sus condiciones están ligados al arranque de viruta de materiales. Equipos como torno, fresadora, rectificadora son algunos de los equipos utilizados en la ingeniería de manufactura y que están destinados exclusivamente a los operarios de las máquinas herramientas.

Ospina et al. [50] desarrollaron una investigación en el que menciona que el operario está incluido en la solución de problemas y el manejo de la información en la fabricación de piezas, que se encuentren relacionadas al proceso por arranque de viruta. Sin embargo, existen problemas al enfrentarse a diferentes tareas donde la información llega de forma masiva; es imprecisa y distorsionada. Para un trabajo de tipo arranque de viruta se determinó que la red neuronal más adecuada fue la de tipo Percetrón Multicapa. Posteriormente se realizó una planeación de componentes de entradas y salidas; entrenando la red neuronal con la información de cada una de las piezas que están marcadas con un código específico y que en total fueron diez piezas estándar de acuerdo con el entrenamiento de la red neuronal.

La industria 4.0 y las redes neuronales en la manufactura permiten, a través del entrenamiento de una red neuronal, organizar la información obtenida de los sistemas de producción de los centros de maquinados y talleres de máquina herramienta para arranque de viruta. Las redes neuronales traen cambios sustanciales a las organizaciones para la mejor toma de decisiones y tener una producción competitiva.

2.5.2 Inspección de componentes en el proceso de fabricación de arneses de seguridad

Otro de los trabajos de investigación en la resolución de problemas asociados a los procesos de fabricación de arneses es la inspección de componentes, ya que en su mayoría la inspección es realizada por los mismos operarios y los resultados son muy variables; en algunas veces

inadecuado. Con la implementación de la técnica de erosión de imagen contra imagen maestra de tipo conector y el reconocimiento de imágenes utilizando redes neuronales artificiales se pueden extraer las características de la imagen y la posición de los conectores de los arneses. La inspección de conectores es generada por la captura de imágenes, erosión de áreas no deseadas, monocromatizado de la imagen, extracción de puntos clave y red neuronal. Para la inspección de cables se genera la captura de imágenes, reducción de pixeles de la imagen, entrenamiento de la red neuronal y salida de la información. Esta técnica se validó con el área de inspección en una fábrica de manufactura local y se obtuvo resultados del sistema de visión con un 100% para la identificación de conectores y exactitud de un 83% de identificación de los cables del arnés [51].

2.5.3 Análisis de porosidad de piezas en el proceso de fusión selectiva laser

Cisneros et al. [52] construyeron dos modelos de redes neuronales, perceptrón multicapa (MLP) y ADALINE, que tiene la capacidad de adaptarse muy bien a la hora de modelar el proceso de fusión selectiva laser (SLM). El objetivo de implementar la técnica de redes neuronales fue optimizar cada uno de los parámetros de producción y fabricación de este proceso de fusión y validar los resultados obtenidos. Se emplearon bases de datos que fueron obtenidos por una máquina SLM y se utilizó como material de evaluación y análisis el acero inoxidable AISI 316L en estado polvo con una pureza del 99% y un tamaño de partícula de $36.6\mu\text{m}$ [53]. Los parámetros tomados fueron potencia de láser, estrategia de escaneo, velocidad del escaneo, área de sombreado y porcentaje de densidad. Los resultados obtenidos, mostraron que las redes neuronales tienen la capacidad de predecir los parámetros idóneos para una fabricación óptima de piezas AISI 316L. Los modelos de redes neuronales utilizados mostraron en algunos casos un mejor rendimiento que los modelos tradicionales. De acuerdo con las pruebas realizadas por el modelo multicapa, se predijo que la mayor densidad fue de 99.3% obtenida mediante combinaciones de parámetros y que corresponde a 185W de potencia en el láser, velocidad de escaneo 80 mm/s, espacio sombra de 0.04 mm y a estrategia de escaneo fue de 5 mm.

2.5.4 Rrugosidad en el proceso de maquinado de aleación de Ti-6Al-4V

Hemos visto como la industria 4.0 en conjunto con las redes neuronales están siendo aplicadas poco a poco y mejorando cada día la forma en que evaluamos procesos industriales y de manufactura. La rugosidad superficial, juega un papel muy importante a la hora de hablar de calidad en la fabricación y obtención de productos manufacturados. El siguiente trabajo desarrollado por [54], presenta una metodología que puede ayudar a predecir la rugosidad del Ti-6Al-4V (aleación titanio grado 5) obtenida del proceso de maquinado de torno convencional, utilizando intervalos de confianza conocidos y las redes neuronales (RNA) como técnica de comparación de resultados. Las variables consideradas fueron la velocidad de corte, avance y profundidad de corte. En este proceso, se utilizó un buril con inserto de carburo cubierto por TiAlN (nitruro de titanio aluminio). Los resultados obtenidos determinaron que los errores son normales con desviación estándar conocida, es decir, esta metodología de análisis mediante el uso de redes neuronales pudo ayudar a predecir la rugosidad necesaria en el diseño de las partes y agregando un sistema inteligente se pueden determinar condiciones adecuadas para poder trabajar aleaciones que son muy difíciles de maquinar.

2.5.5 Reconocimiento de patrones en los procesos industriales de la industria metalúrgica

En esta investigación se evaluaron 43 empresas distribuidas en dos ciudades relacionadas a la industria metalúrgica, con el objetivo de optimizar sus procesos productivos mediante la intervención de las redes neuronales. La obtención de la información se realizó mediante un cuestionario que presenta 66 preguntas y está estructurado en siete secciones: información de la

empresa, gerencia y administración, operaciones, ingeniería de procesos, perfil de la empresa, nivel de adopción de las tecnologías y el nivel de implementación de las tecnologías. La red neuronal de comienzo fue de 100 iteraciones con incrementos de 50 iteraciones hasta llegar a un total de 500. Se obtuvieron 3 segmentos donde la primera son las empresas que incorporan tecnología, el segundo segmento incorpora muy poca o no presentan un resultado significativo y la tercera se relaciona con procesos industriales de uso manual y sin ningún indicio de automatización. Los resultados muestran que una red neuronal entrenada apoya a conocer el nivel de implementación de las tecnologías, sin embargo, los autores recomiendan que para este análisis se deben unir la técnica de redes neuronales y mapas auto-organizativos (SOM), ya que permiten un mejor análisis y exploración con una distribución de tipo espacial neuronal como mapeo [55].

2.5.6 Mejoramiento de la demanda de energía eléctrica de las centrales eléctricas

En esta investigación se propuso un modelo para predecir la demanda de energía eléctrica, utilizando las técnicas de redes neuronales y regresión lineal múltiple para el mejoramiento de sus operaciones, planeación estratégica y mantenimientos de la central eléctrica. Este trabajo fue una investigación de campo con un total de 70,128 registros durante 10 años, y se trataron 726 datos atípicos y perdidos. La estructura de la red fue realizada mediante la técnica de búsqueda dinámica y forzada. Los resultados obtenidos indicaron que el modelo presentó un error absoluto del 2.6% y el basado por regresión lineal 4.56%. La red neuronal exteriorizó un mejor rendimiento que el de regresión lineal. También se concluyó que es importante realizar la búsqueda de datos atípicos con el fin de suavizar la serie temporal y obtener resultados positivos [56].

2.5.7 La industria de la manufactura y los robots inteligentes

Los sistemas de producción y procesos industriales donde intervienen los robots inteligentes se aplican ampliamente en la industria manufacturera, principalmente para determinar la categoría y la posición de las piezas. Esta investigación expone un sistema de visión inteligente basado en una red neuronal RGB-D para el análisis y reconocimiento de imágenes y objetos. También este sistema tiene la capacidad de estimar la pose del objeto escaneado en 6D. Las predicciones de los objetos se realizan mediante pixeles 2d y 3d por medio de estimación de posiciones basadas en colores y geometrías donde cada uno de los experimentos son realizados por datos de tipo YCB-Video y LineMOD, que tiene la capacidad de determinar la capacidad y rendimiento del método propuesto.

Los resultados obtenidos mostraron un comportamiento efectivo para las operaciones comunes como selección, recolección y movimiento de objetos, demostrando el alto impacto que tiene esta metodología y que puede aplicarse en todo tipo de operaciones y aplicaciones de fabricación en tiempo real [57]. La cuarta Revolución Industrial y robots han ido ganando cada vez más espacio en la industria y superando las expectativas. El uso de robots en la industria está relacionado con el aumento de la producción y la calidad de los productos electrónicos [58].

2.5.8 Aumento de la calidad en el proceso de inspección de dibujos de ingeniería

Xie et al. [59] menciona que cada año se recibe una gran cantidad de dibujos de ingeniería y manufactura escaneados y que las empresas han experimentado una creciente necesidad de aumentar su eficiencia de procesamiento al reemplazar el proceso de inspección manual actual con un sistema automático. En esta investigación se propone un método de fabricación de tipo computacional con el fin de determinar el método apropiado de acuerdo con el dibujo de ingeniería analizado, como maquinado en torno, fresado, rectificado y doblado. Se desarrolló un algoritmo basado en redes neuronales de tipo gráfico, el cual mediante el trazado de líneas se puede transformar en geometrías hasta los dibujos más complejos con una mínima perdida de la

información obtenida por el algoritmo. Esta red neuronal presenta conexiones gráficas actualizadas que tiene la capacidad de clasificar los dibujos con un porcentaje de efectividad de 90.78%.

2.5.9 Mejora del proceso de colada continua en la fabricación de losas de acero en una planta siderúrgica

La siguiente investigación es la implementación de una metodología basada en redes neuronales capaz de mejorar el proceso de mejora continua en la fabricación de losas de acero. Ansari et al. [60] menciona que la ruptura es uno de los principales accidentes que a menudo surgen en los talleres de colada continua de planchones de acero y que provocan una gran pérdida de capital, reduciendo la productividad y creando notorios riesgos para la seguridad. El sistema existente no es capaz de predecir la ruptura con precisión, ya que considera solo un parámetro de proceso, es decir, la temperatura del termopar. Este trabajo consideró múltiples parámetros del proceso (velocidad de fundición, nivel del molde, temperatura del termopar y conicidad/molde) y desarrolló un sistema de predicción de ruptura (BOPS) para la colada continua de losas de acero. El BOPS se modela utilizando una red neuronal artificial con un algoritmo de retropropagación, que además se ha validado mediante el uso del formato Keras y las plataformas de aprendizaje automático basadas en TensorFlow. Este trabajo utilizó el optimizador de Adam y la función de pérdida de entropía cruzada binaria para predecir la ruptura del líquido en la colada y evitar la intervención del operador.

3. Metodología

3.1 Método de búsqueda y análisis bibliográfica

En este trabajo se utilizó el método de búsqueda de fuentes bibliográficas, que tiene como particularidad evaluar la importancia de la pregunta de investigación y la selección del tipo diseño a estudiar. De igual manera funciona como entrenamiento para poder aprender limitantes y errores de investigaciones previas [61]. También se utilizó el software MAXQDA en su versión 2020 para una parte del análisis cualitativo de la información, mediante la herramienta de nube de palabras que tiene como objetivo estructurar un conjunto de palabras a partir de texto y organizar de manera jerárquica las de mayor frecuencia.

La búsqueda se basa en información de artículos, repositorios y páginas web especializadas en el tema de investigación en idioma español e inglés para presentar los conceptos de RNA, industria 4.0, cadena de suministro, robótica, manufactura aditiva, procesos de fabricación, modelación en 3D, Internet de las cosas, comercio, Big Data, etc. La revisión de la literatura se consideró de publicaciones desde el año 2002 hasta el primer semestre del año 2022, además que el 60% de las investigaciones no fueran mayores a 5 años de publicación.

3.2 Selección y criterio para la selección de las investigaciones

La búsqueda de las diferentes investigaciones fue mediante el uso de palabras clave relacionadas con el tema de investigación y se obtuvo un total de 220 registros de las bases de datos Redib, Taylor & Francis, Springer, Researchgate, Scielo, Dialnet, Ebsco, ScienceDirect, Redalyc y Google académico. Cada uno de los artículos encontrados se compartió a especialistas en el tema para determinar la calidad y las discrepancias, se revisaron en consenso entre los autores para ser aceptado o en su defecto eliminado. Se seleccionaron 47 publicaciones de las cuales 3 son pertenecientes a repositorios o páginas web especializadas, y solo el 66% del total de las publicaciones presentan una antigüedad de 5 años.

4. Resultados

Los resultados elegidos fueron detalladamente analizados y evaluados, utilizando como parámetros de selección: aplicación de la industria 4.0 o redes neuronales en la ingeniería industrial y como parámetros de exclusión: investigación que no se encuentre relacionada con áreas de la ingeniería industrial. No se consideraron las publicaciones en idioma diferente al español e inglés que contaran con más de 20 años de antigüedad.

De acuerdo con la información presentada, se observa un uso considerable de las RNA en el campo de la ingeniería industrial. En tabla 1, se muestra un análisis de resultados sobre el campo de aplicación y el tipo de estructura utilizado de las redes neuronales en algunas investigaciones ya que en algunos casos si bien se mencionan su aplicación no muestran de forma detallada el entrenamiento de estas.

Tabla 1. Modelos de redes neuronales utilizados en la literatura científica

Área de aplicación	Modelo de red neuronal	Arquitectura	Objetivo de la red	Función de activación	Resultado	Autor
Procesos industriales.	Perceptrón multicapa-	38-10-10-1	Predecir fallos en el funcionamiento	No detalla	MSE=0.001	(14)
Tratamiento de aguas residuales	Backpropagation		de plantas	Predecir parámetros		
	Perceptrón multicapa-	8-1-1	óptimos para reducción de scrap	Sigmoide	Opt=0.25	(17)
Manufactura automotriz	Backpropagation		Monitorear comportamiento de temperaturas	Levenberg-Marquardt	R= 0.995	(24)
Energía: turbinas de viento	Perceptrón multicapa-	2-2-1	de conductir			
Industria 4.0	Perceptrón multicapa-	2-10-1	automáticamente vehículos de plataforma	Sigmoide	No detalla	(25)
Vehículos de plataforma	Backpropagation		Procesar señales cerebrales	Sigmoide	Pr=0.77	(27)
Prótesis de mano robótica	RNN-GRU	1-1-1-1-1	Reconocer gestos de una	Sigmoide	R=0.90	(28)
Prótesis biónica	Backpropagation		prótesis biónica			
	Perceptrón					
Metrología óptica y visión robótica	multicapa-	m-10-1	Reconstruir objetos 3D	Gauss	MSE=0.00246	(30)
Planificación y	Backpropagation			No detalla	EpRNA< Ep	(37)
	Perceptrón	1-20-20-1	Pronosticar			

demandas de artículos	multicapa- Backpropagation	demandas para toma de decisiones				
Evaluación de riesgos en cadenas de suministro- Finanzas	Perceptrón multicapa- Backpropagation	4-5-3	probabilidades de ocurrencia de riesgo	Lineal	Rc=0.947	(38)
Evaluación de riesgos en cadenas de suministro- Finanzas	Perceptrón multicapa- Backpropagation	30-x-x	probabilidades de ocurrencia de riesgo	Sigmoide	E<0.001	(39)
Evaluación de riesgos en cadenas de suministro	Perceptrón multicapa- Backpropagation	38-10-1	probabilidades de ocurrencia de riesgo	GA-BP	Pr=0.2842	(40)
Evaluación de riesgos en cadenas de suministro-TI	Perceptrón multicapa- Backpropagation	12-7-1	probabilidades de ocurrencia de riesgo	Sigmoide	E<0.07	(41)
Optimización en cadenas de suministros	Perceptrón multicapa- Backpropagation	3-3-2-1	Optimizar cadena de suministros	NFA	No detalla	(42)
Manufactura	Backpropagation		Predecir consumo de			
Cadenas de suministro-E-commerce	Perceptrón multicapa- Backpropagation	3-3-1	energía en máquinas	Sigmoide	No detalla	(44)
Manufactura-Industria de Mecanizado	Perceptrón multicapa- Backpropagation	3-3-3	fresadoras			
Manufactura. Inspección de calidad	Perceptrón multicapa- Backpropagation	6-4-5	Predecir ventas en e-commerce	Sigmoide	Rc=0.96571	(50)
Manufactura- Industria de Mecanizado	Perceptrón multicapa- Backpropagation	1-10-1	Asistir la automatización de taller	Sigmoide	No detalla	(51)
Manufactura. Inspección de calidad	Perceptrón multicapa- Backpropagation	3-8-5-3-1	Reconocer patrones	Sigmoide	Rc=0.94	(52)
Manufactura	Perceptrón		Optimizar	No detalla	Error=<0.0001%	(53)

	multicapa-		parámetros de			
	Backpropagation		fabricación			
			Optimizar			
		4-1	parámetros de	No detalla	Erro=<0.01	(53)
Manufactura	ADALINE		fabricación			
	Perceptrón		Predecir			
Control	multicapa-	8-27-1	demandas de	Sigmoide y	MSE=0.0263	(57)
automático	Backpropagation		energía eléctrica	Lineal		

Opt= Optimización **Ep**= Error Promedio esperado **MSE**= Error medio cuadrático **R**= Coeficiente de correlación
Pr= Probabilidad de riesgo **EpRNA**= Error promedio de la red neuronal **Pr**= Precisión **Re**= Resultado Precisión
E= Error relativo

4.1 Análisis de la información

Para este punto se utilizó el software MAXQDA en su versión 2020 para una parte del análisis cualitativo de los datos, mediante la herramienta de *nube de palabras* que tiene como función estructurar en forma del diseño visual, un conjunto de palabras a partir de texto y organizar términos jerárquicamente que se presentan con mayor frecuencia. En la figura 3, se puede observar las palabras claves más frecuentes utilizadas en búsqueda de información de literatura científica aplicada en este trabajo.



Figura 3. Palabras clave utilizadas en la nube de datos
 Fuente: MAXQDA, 2020

En la Figura 4, se muestra la frecuencia por secciones del documento, se puede observar que el segmento más alto es la palabra de redes neuronales seguido por procesos industriales y circulación comercial. Esto significa que las redes neuronales y los procesos industriales están asociadas en la literatura científica representando un trabajo en conjunto.



Fig.4 Palabras clave por segmento del documento

Fuente: MAXQDA, 2020

Las publicaciones relacionadas al tema de redes neuronales artificiales en la ingeniería industrial han tenido participaciones por año, en la que se ubicaron 48 productos con el tema de estudio, como se muestra en la Tabla 2.

Tabla 2. Número de trabajos publicados por año relacionados a redes neuronales

Año de publicación	Número de trabajos publicados
2002	1
2003	1
2006	1
2007	1
2009	1
2012	1
2014	1
2015	4
2017	3
2018	2
2019	6
2020	3
2021	15
2022	9
Total	48

Como se puede apreciar en la Tabla 1, el modelo de red neuronal que más se aplica en las investigaciones consultadas es bajo el método *Backpropagation*, el cual permite que una red neuronal multicapa aprenda a través de la asociación que existe entre las entradas y las acciones correspondientes para conseguir la salida esperada, esto a través de la organización en las capas intermedias (figura 5), donde x_i corresponde a las entradas de la red, y_j corresponde a las salidas de la capa oculta y, z_k corresponde a las salidas de la capa final; t_k corresponde a las salidas esperadas. Por otro lado, w_{ij} son los pesos de la capa oculta y θ_j sus umbrales; w'_{jk} los pesos de la capa de salida y θ'_k sus umbrales. Logrando un reforzamiento de aprendizaje, tal y como se muestra en la figura 6.

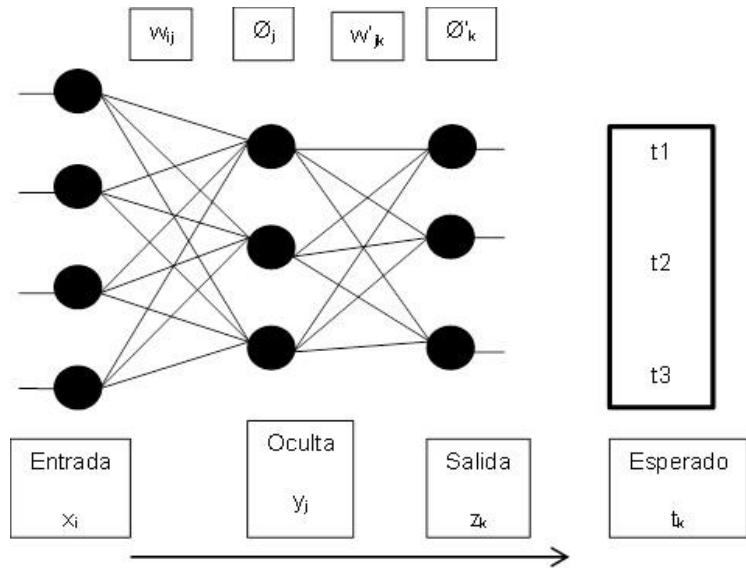


Fig.5 Arquitectura con tres capas [62]

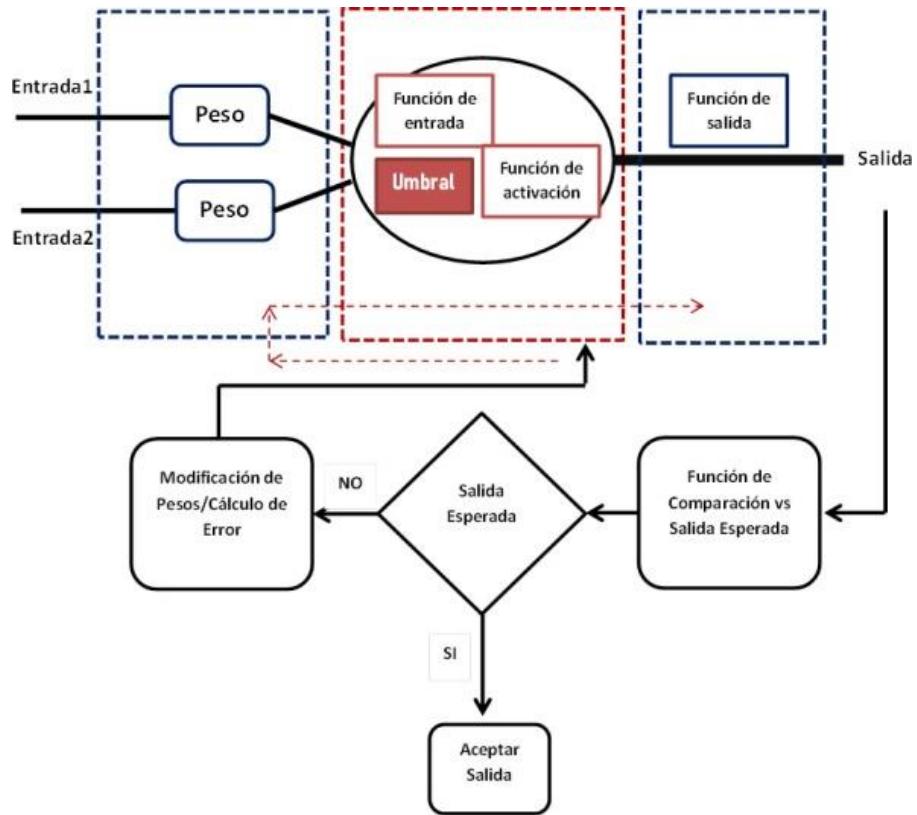


Fig.6 Reforzamiento de aprendizaje en *Backpropagation* [62]

5. Conclusiones

En esta investigación se pudo observar que las redes neuronales, junto con la industria 4.0 en áreas de aplicación de prótesis robóticas y reconocimiento de gestos presentaron una R de 90% de efectividad, utilizando una función de activación de tipo sigmoide. La inspección de calidad de procesos industriales y reconocimiento de patrones obtuvo un Rc de 94% de efectividad utilizando activación de tipo sigmoide. También se encontraron aplicaciones en áreas automotrices,

automatización de procesos y mecanizado de piezas, donde los resultados concluyen que el buen entrenamiento de los perceptrones multicapa dan como resultado una eficacia en los resultados. En cuanto a la cadena de suministro, en e-commerce y su análisis de activación de tipo sigmoide, presentó un $R_c = .96\%$ de efectividad para predecir las ventas y comercio en línea.

Las redes neuronales es una técnica novedosa, para predecir la fiabilidad de las operaciones y actividades de las personas. La aplicación de la técnica de RNA supera en efectividad y rapidez a los métodos tradicionales, por su capacidad de adaptación y resistencia al fallo. Las redes neuronales han ido evolucionando con la entrada de la industria 4.0 y su impacto ha tenido un alcance impresionante desde aplicaciones 3D, procesos de maquinado en torno, procesos de siderurgia, optimización de la cadena de suministro.

Las redes neuronales como parte de los elementos que integran la industria 4.0, llegó para evolucionar junto con las redes neuronales, traer un cambio sustancial a cualquier organización que esté buscando la optimización de sus procesos industriales, con la seguridad de que las tecnologías llegaron para mejorar la vida de las empresas y los trabajadores, así como ser parte de esta nueva red de tecnologías con resultados en tiempo real.

Referencias

1. Mahlmann, L., Bertolin, L., Hoppe, D., Frozza, R., Iespen, S., *Scopus Scientific mapping production in industry 4.0* (2011-2018): a bibliometric analysis. International Journal of Production Research, 2019. 58: p. 1605-1627. DOI: <https://doi.org/10.1080/00207543.2019.1671625>
2. Belvedere, V., Grando, A., Bielli, P., *A quantitative investigation of the role of information and communication Technologies in the implementation of producto-service system*. International Journal of Production Research, 2012. 51 (2): p. 410-426. DOI: <https://doi.org/10.1080/00207543.2011.648278>
3. Maynard, A., *Naving the fourth industrial revolution*. Nature Nanotech, 2015. 10: p.1005-1006. DOI: <https://doi.org/10.1038/nnano.2015.286>
4. Kagerman, H., Wolfgang, W., Helbig, J., *Recommendations for implementing the strategic initiative INDUSTRIE 4.0*. Forschungsunion/Acatech, 2013. 51 (2): p. 1-84.
5. Belvedere, V., Grando, A., Bielli, P., *A quantitative investigation of the role of information and communication Technologies in the implementation of producto-service system*. International Journal of Production Research, 2012. 51 (2): p. 410-426. DOI: <https://doi.org/10.1080/00207543.2011.648278>
6. Atzori, L., Lera, A., Morabito, G., *The Internet of Things: A survey*. Computer Networks, 2010. 54 (15): p. 2787-2805. DOI: <https://doi.org/10.1016/j.comnet.2010.05.010>
7. Kumar, S., McCalley, J., *Design Techniques and Applications of Cyberphysical Systems: A Survey*. IEEE, 2015. 9 (2): p. 350-365. DOI: <https://doi.org/10.1109/JSYST.2014.2322503>
8. Sáenz, N., Álvaro, M., *Redes neuronales: concepto, aplicaciones y utilidad en medicina*. Neurocirugía, 2002. 30 (2): p. 119-120. DOI: [10.1016/S0212-6567\(02\)78981-6](https://doi.org/10.1016/S0212-6567(02)78981-6)
9. International Business Machines (IBM) [Internet]. El modelo de redes neuronales; [citado 31 marzo 2023]. Disponible en: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
10. Basogain, X., *Redes neuronales artificiales y sus aplicaciones*. 2018. p 1-79. Disponible en: https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/ibro-del-curso.pdf
11. Rivas, W., Mazon, B., *Capítulo 1: Generalidades de las redes neuronales artificiales*. Utmachala, 2017. P. 32-29. Disponible en:

- <http://repositorio.utmachala.edu.ec/bitstream/48000/14223/1/Cap.1-Generalidades%20de%20las%20redes%20neuronales%20artificiales.pdf>
12. Cruz, L., Acevedo, M., *Reconocimiento de Voz usando Redes Neuronales Artificiales*. Backpropagation y Coeficientes LPC, Ed: CICos, 2008. p. 1-11.
 13. Barbosa, L., Kleisinger, G., Valdez, A., Monzón, J., *Utilización del modelo de KOHOMEN y del perceptron multicapa para detectar arritmias cardiacas*. Sociedad Cubana de Bioingeniería, 2001. p. 1-9. Disponible en: https://scholar.google.com/scholar?oi=bibs&hl=es&ctes=16771180673481807151&as_sdt=5
 14. Espina, J., García, J., Larragaña, J., *Herramientas de redes neuronales para ingeniería de procesos industriales*. Técnica Industrial, 2010. p. 291:40-48.
 15. Martín, E., *Redes neuronales en la industria 4.0*. Disponible en: <https://www.grupocibernos.com/blog/redes-neuronales-en-la-industria-40>
 16. Ramírez, N., Laguna, M., Rubín, N., *Un acercamiento a la industria 4.0 a través de redes neuronales para la reducción de scrap en una empresa automotriz*. Pistas educativas, 2019. **41**(133): p.1-18.
 17. Pisa, I., Vilanova, R., Santín, I., Vicario, J., Morell, A., *Aplicación de una red neuronal artificial para dar soporte a la operación de plantas en la industria de las aguas residuales*; Disponible en: <https://www.uab.cat/web/detalle-noticia/aplicacion-de-una-red-neuronal-artificial-para-dar-soporte-a-la-operacion-de-plantas-en-la-industria-de-las-aguas-residuales-1345680342040.html?noticiaid=1345806500768>
 18. Elhoone, H., Zhang, T., Anwar, M., Desai, S., *Cyber-based design for additive manufacturing using artificial neural networks for Industry 4.0*. International Journal of Production Research, 2019. **30** (2):1-22. DOI: <https://doi.org/10.1080/00207543.2019.1671627>
 19. Bansond, G., Khandekar, S., Khurana, S., *Analysis of Convolution Neural Network Architecture and Their Applications in Industry 4.0*. 1st ed. Charlestow US, 2021. p. 24
 20. Amini, A., Kanfound, J., Hean, T., *An Artificial Intelligence Neural Network Predictive Model for Anomaly Detection and Monitoring of Wind Turbines Using SCADA Data*. Applied Artificial Intelligence, 2002. **36** (1): p.1-15. DOI: <https://doi.org/10.1080/08839514.2022.2034718>
 21. Ree, S., Löfstrand, M., Andrews, J., *Modelling stochastic behaviour in simulation digital twins through neural nets*. Journal of Simulation, 2021. p. 1-15. DOI: <https://doi.org/10.1080/17477778.2021.1874844>
 22. Dingli, A., Haddod, F., Klüver, C., *Artificial Intelligence in Industry 4.0 – A collection of innovative research case-studies that are reworking the way we look at industry 4.0 thanks to artificial intelligence*. Springer, 2021. **928** (2): p.1-248. DOI: <https://doi.org/10.1007/978-3-030-61045-6>
 23. Arbellal, Y., Trinchet, C., Mora, C., *Monitoreo de condición en las turbinas de viento del parque eólico Gibara II aplicando métodos de la industria 4.0*. RILCO, 2021. p.1-9. DOI: <https://doi.org/10.51896/rilco>
 24. Simon, J., Trojanová, M., Hošovský, A., Sárosi, J., *Neural network driven automated guided vehicle platform development for industry 4.0 environment*. Technical Gazette, 2021. **28**(6): p.1936-1942. DOI: <https://doi.org/10.17559/TV-20200727095821>
 25. Serna, A., Prieto, F., *Towards a 3D modeling of brains tumors by using endoneurosonography and neural networks*. Revista Ingenierías Universidad de Medellín, 2017. **16** (30): p.129-148. DOI: <https://doi.org/10.17559/TV-20200727095821>
 26. González, M., Brugiat, A., Cornejo, D., Pinzón, C., *Prototipo de mano robótica controlada mediante el procesamiento de señales cerebrales utilizando redes neuronales recurrentes*. Revista de iniciación científica, 2021. (4): p.1-6. DOI: <https://doi.org/10.33412/rev-ric.v6.0.3154>
 27. Artal, J., Pérez, F., Pascual, A., Domínguez, J., *Control de una mano robótica basado en redes neuronales y técnicas de reconocimiento de gestos mediante múltiples sensores EMG*.

- Proceedings TAEE 2020, 2020. p.1-8. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=8062508>
28. Yang, Q., Xu, F., Leng, J., *Abnormal actions detection of robotic arm via 3D convolution neural network and suport vector data description*. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2022. **42**(6): p.5931-5937. DOI: <https://doi.org/10.3233/JIFS-212468>
29. Muñoz, J., Asundi, A., Rodríguez ,R., *Aplicación de redes neuronales de aproximación a una línea de luz para reconstrucción 3D de objetos*. Revista Mexicana de Física, 2003. **50**(5): p.453-461. Disponible en: <http://www.scielo.org.mx/pdf/rmf/v50n5/v50n5a5.pdf>
30. Arif, M., Loana, A., Ristoscu, C., Mihailescu, I., *Artificial Neural Network Algorithms for 3D Printing*. Materials, 2021. **14**(163): p.1-27. DOI: <https://doi.org/10.3390/ma14010163>
31. Maturana, D., Scherer, S., *VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition*. IEEE Xplore, 2015. p. 922-928. DOI: <https://doi.org/10.1109/IROS.2015.7353481>
32. Javadi, S., Dahl, M., Pettersson, M., *Vehicle Detection in Aerial Images Based on 3D Depth Maps and Deep Neural Networks*. IEEE 2021, 2021. 9: p. 8381-839. DOI: <https://doi.org/10.1109/ACCESS.2021.3049741>
33. Mena, N., Lario, F., Vicens, E., *Planificación de la demanda en la Gestión de cadena de suministro con redes neuronales y lógica difusa*. X Congreso de Ingeniería de Organización, 2006. p.1-10. Disponible en: https://www.researchgate.net/publication/277733174_Planificacion_de_la_Demanda_en_la_Gestion_de_Cadena_de_Suministro_con_Redes_Neuronales_y_Logica_Difusa
34. Kochak, A., Sharma, S., *Demand forecasting using neural network for supply chain management*. International Journal of Mechanical Engineering and Robotics Research, 2015. **4**(1): p.96-104. Disponible en: <http://www.ijmerr.com/show-126-176-1.html>
35. Flores, C., *Uso de redes neuronales profundas en la cadena de abastecimiento de una empresa chilena del rubro forestal*. Universidad de Concepción, 2017. Disponible en: <http://152.74.17.92/jspui/handle/11594/7100>
36. Lao, Y., Méndez, A., Pérez, M., Marrero, F., *Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales*. Holguín Ciencias, 2017. p.43-59. Disponible en: <https://www.redalyc.org/journal/1815/181549596004/html/>
37. Li, L., Wen, Y., Hou, Y., Jun, Z., *A Convolutional Neural Network-Based Model for Supply Chain Financial Risk Early Warning*. Hindawi, 2022. p.1-16. DOI: <https://doi.org/10.1155/2022/7825597>
38. Sang, B., *Application of genetic algorithm and BP neural network in supply chain finance under information sharing*. Journal of Computational and Applied Mathematics, 2021. p.1-11. DOI: <https://doi.org/10.1016/j.cam.2020.113170>
39. Jianying, F., Bianyu, Y., Xin, L., Dong, T., Weisong, M., *Evaluation on risks of sustainable supply chain base on optimized BP neural networks in fresh grape industry*. Computers and Electronics in Agriculture, 2021. **183**: p.1-11. DOI: <https://doi.org/10.1016/j.compag.2021.105988>
40. Liu, C., *Risk Prediction of Digital Transformation of Manufacturing Supply chain based on Principal Component Analysis and Backpropagation Artificial Neural Network*. Alexandria Engineering Journal, 2022. **61**: p.775-784. DOI: <https://doi.org/10.1016/j.aej.2021.06.010>
41. Li, T., *Algorithm optimization of large-scale supply chain designs base don FPGA and neural network*. Microprocessors and Microsystems, 2021. **81**: p.1-6. DOI: <https://doi.org/10.1016/j.micpro.2020.103790>
42. Cotino, L., *Riesgos e impactos del Big Data, la inteligencia artificial y la robótica y enfoques, modelos y principios de la respuesta del Derecho*. Revista General de Derecho Administrativo, 2019. p.1-38.

43. Lechevalier, D., Hudak, S., Tina, R., Foufou, S., *A Neural Network Meta-Model and its Application for Manufacturing*. 2015 IEEE International Conference on Big Data, 2015. p.1-8. DOI: <https://doi.org/10.1109/BigData.2015.7363903>
44. Zheng, P., Wang, H., Sang, Z., Zhong, R., Liu, Y., Chao, L., et al. *Smart manufacturing systems for Industria 4.0: Conceptual framework, scenarios, and future perspective*. Springer, 2018. p. 137-150. DOI: <https://doi.org/10.1007/s11465-018-0499-5>
45. Al-Badi, A., Islam, A., *A Sustainable Development Neural Network Model for Big Data in Smart Cities*. Springer, 2022. p.408-413. DOI: <https://doi.org/10.1016/j.procs.2022.04.057>
46. Du, X., Cao, X., Zhang, R., *Big Data Analysis and Prediction System Based on Improved Convolutional Neural Network*. Hindawi, 2022. p.1-12. DOI: <https://doi.org/10.1155/2022/4564247>
47. Hernández, G., Zamora, E., Sossa, H., Téllez, G., Furlán, F., *Hybrid neural networks for Big Data classification*. Nuerocomputing, 2019. p.1-36. DOI: <https://doi.org/10.1016/j.neucom.2019.08.095>
48. Araque, A., Gómez, M., Vélez, P., Suárez, A., *Big Data y las implicaciones en la cuarta revolución industrial- Retos, oportunidades y tendencias futuras*. Revista Venezolana de Gerencia. 2021. **26**(93): p.1-12.
49. Zhang, Y., *Application of improved BP neural network based one-commerce supply chain network data in the forecast of aquatic product export volume*. Cognitive Systems Research, 2018. **57**: p.228-235. DOI: <https://doi.org/10.1016/j.cogsys.2018.10.025>
50. Ospina, R., Parra, H., Aguirre, H., *Diseño de una red neuronal artificial para asistir la automatización en un taller de mecanizado*. Scientia et Technica, 2007. **1**(37): p.181-186. DOI: <https://doi.org/10.22517/23447214.4047>
51. Medina, L., González, S., Mayorquín, J., López, G., *Diseño de interfaces de inspección de calidad utilizando redes neuronales y visión artificial para la industria manufacturera*. Research in Computing Science, 2019. **148**(8): p.121-131. DOI: <https://doi.org/10.13053/rccs-148-8-9>
52. Cisneros, J., Amezquita, L., Reyes, L., Zambrano, P., Garza, C., Lopez, O., *Parametric prediction of porosity in parts manufactured by the SLM process using neural networks*. Ingeniería mecánica tecnología y desarrollo, 2021. **7**(2): 33-40.
53. Laohaprapanon, A., Jeamwatthanachai, P., Wongcumchang, M., Chantarapanich, N., Chantaweroad, S., Sitthiseripratip, K., et al. *Optimal Scanning Condition of Selective Laser Melting Processing with Stainless Steel 316L Powder*. Advanced Materials Research, 2012. **341**: p.816-820. DOI: <https://doi.org/10.4028/www.scientific.net/AMR.341-342.816>
54. Escamilla, I., Torres, L., Zambrano, P., Pérez, P., González, B., *Predicción de rugosidad en maquinado de aleación Ti-6Al-4V usando redes neuronales*. Ingenierías, 2009. **12** (42): 1-7.
55. Fornari, J., González, G., Herrera, L., *Reconocimiento de Patrones de Procesos Industriales mediante el uso de redes neuronales artificiales*, Zenodo. 2015. **1** (2): p.1-10. DOI: <https://doi.org/10.5281/zenodo.59445>
56. Sinaluisa, I., Morocho, A., Marquez, C., *Predicción de la demanda de energía eléctrica mediante redes neuronales artificiales*, risti. 2019. **25**: p.505-519.
57. Liang, G., Chen, F., Liang, Y., Feng, Y., Wang, C., Wu, X., *A Manufacturing-Oriented Intelligent Vision System Based on Deep Neural Network for Object Recognition and 6D Pose Estimation*. Frontiers in Neurobotics, 2021. p.1-15. DOI: <https://doi.org/10.3389/fnbot.2020.616775>
58. Karabegović, I., Turmanidze, R., Dašić, P., *Robotics and Automation as a Foundation of the Fourth Industrial Revolution-Industry 4.0*. Advanced Manufacturing Process, 2020. p.128-136. DOI: https://doi.org/10.1007/978-3-030-40724-7_13

59. Xie, L., Lu, Y., Furuhata, T., Yamakawa, S., Zhang, W., Regmi, A., et al. *Graph neural network-enabled manufacturing method classification from engineering drawings*. Computers in Industry. 2022. **142**: p.1-10. DOI: <https://doi.org/10.1016/j.compind.2022.103697>
60. Ansari, M., Chattopadhyaya, S., Ghose, J., Sharma, S., Kozak, D., Li, C., et al. *Productivity Enhancement by Prediction of Liquid Steel Breakout during Continuous Casting Process in Manufacturing of Steel Slabs in Steel Plant Using Artificial Neural Network with Backpropagation Algorithms*. Materials, 2022. **15** (670): p.1-10. DOI: <https://doi.org/10.3390/ma15020670>
61. Arguedas, O., *El ángulo del investigador-La búsqueda bibliográfica*. Acta méd. Costarric, 2009. **51**:155-157.
62. Santana, G., *Análisis de los algoritmos Backpropagation para el diseño de neuronas artificiales con capacidad de aprendizaje*, 2022. p. 80-88.
63. González, S., Gómez, I., Pastrana, J., Hernández, A., *Algoritmos de clasificación y redes neuronales en la observación automatizada de registros*. Cuadernos de psicología del deporte. 2014. **15** (1): p.31-40. DOI: <https://dx.doi.org/10.4321/S1578-84232015000100003>
64. Valderrama, F., Chávez, D., Muñoz, S., Tuesa, V., Mejía, H., *Importancia de las redes neuronales artificiales en la ingeniería civil: Una revisión sistemática de la literatura*. Revista ITECKNE, 2021. **18** (1): p.71-83. DOI: <https://doi.org/10.15332/iteckne.v18i1.2542>

Conflicto de Intereses

Se declara que no existe conflicto de intereses de ninguna índole en el presente artículo

Contribución de los autores

Marco Díaz Martínez. ORCID: <https://orcid.org/0000-0003-1054-7088>

Concepción de la investigación y redacción del documento.

Reina Román Salinas. ORCID: <https://orcid.org/0000-0001-9287-4298>

Supervisión de los resultados, edición del documento y validación de resultados.

Gil Santana Esparza. ORCID: <https://orcid.org/0000-0002-1124-4006>

Aplicación de la metodología propuesta, manejo de datos y obtención de resultados.

Mario Morales Rodríguez. ORCID: <https://orcid.org/0000-0002-1342-297X>

Validación de resultados y validación de referencias.