

CADENA DE SUMINISTRO DEL FUTURO: IMPACTO Y APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LA MEJORA DE LA CONFIABILIDAD HUMANA

Por

BAZIUK, Pedro Alejandro
pedro.baziuk@fce.uncu.edu.ar
FCE UNCUIYO
BENITES RODRIGUEZ, Aixa María
aixabenites.05@gmail.com
FCE UNCUIYO
MARTIN CAVALLI, Hilario
hilariomcavallic@gmail.com
FING UNCUIYO
GABRIELLI, Oliverio
oliveriogabrielli@yahoo.com.ar
FING UNCUIYO

1. INTRODUCCIÓN

La gestión de la cadena de suministro es una disciplina empresarial fundamental que implica coordinar de manera efectiva el flujo de bienes, información y finanzas desde los proveedores hasta los consumidores finales. En un mundo cada vez más complejo y competitivo, las organizaciones buscan constantemente formas de mejorar la eficiencia, reducir los costos y aumentar la confiabilidad en sus operaciones logísticas.

En este contexto, la inteligencia artificial (IA) ha surgido como una herramienta transformadora que está revolucionando la forma en que se abordan los desafíos de la cadena de suministro. La gestión sostenible de la cadena de suministro se ha convertido en un aspecto crucial en este contexto, ya que las empresas enfrentan crecientes presiones para minimizar su impacto ambiental, social y económico.

En específico, la gestión de riesgos en la cadena de suministros es una práctica crucial para asegurar la continuidad y rentabilidad de las operaciones. Este enfoque, conocido como Supply Chain Risk Management (SCRM), se distingue por su orientación hacia la identificación y reducción del riesgo en toda la cadena de suministro, involucrando la coordinación y colaboración entre sus diversos actores (Khojasteh-Ghamari & Irohara, 2018). Aunque los estudios sobre riesgos en la cadena de suministro datan de décadas atrás, es en los últimos años que esta disciplina ha cobrado independencia y relevancia, con la aparición de libros y estudios específicos (Tang, 2006).

El principal riesgo para una cadena de suministro es la interrupción del flujo de materiales (Waters, 2011). De este precepto es fácil inferir que el enfoque que adquiere la gestión de riesgos en la cadena logística acompaña la estructura y funciones a lo largo del flujo de materiales. La mayoría de los autores en la disciplina coinciden en el intento de identificar los riesgos asociados a las funciones principales de este flujo de materiales: gestión del transporte, gestión de almacenes, manejo de materiales, gestión de órdenes, gestión de compras, servicios al consumidor, gestión de la información; o de sus principales actividades: diseño de la cadena de suministros, compras y abastecimiento, transporte de abastecimiento, recepción de pedidos, almacenamiento, control de existencias, manejo de materiales, recolección de pedidos, transporte de distribución, reciclado y disposición de residuos, comunicación, etc. Esta identificación de riesgos permite generar recomendaciones que justamente apuntan a la disponibilidad y mantenibilidad de este flujo de materiales. Esta preocupación subraya la necesidad de que la gestión de riesgos se adapte a la estructura y funciones de la cadena logística, abordando los riesgos asociados con sus actividades principales, desde la gestión del transporte hasta el reciclado y disposición de residuos (Khojasteh-Ghamari & Irohara, 2018).

La rápida evolución de la tecnología y la creciente adopción de la inteligencia artificial (IA) han revolucionado profundamente la forma en que las empresas operan en diversos sectores, especialmente en la gestión de cadenas de suministro y la toma de decisiones estratégicas. La aplicación de la IA en la creación de valor es evidente en áreas cruciales como la previsión de la demanda, la optimización de la producción, la promoción y fijación de precios, y la entrega eficiente (Dash, McMurtrey, Rebman & Kar, 2019). Por ejemplo, al aprovechar algoritmos de aprendizaje automático y datos históricos, las organizaciones pueden obtener proyecciones de demanda casi precisas y ajustar sus operaciones de abastecimiento y producción de manera óptima. La interconexión de sistemas inteligentes, como robots colaborativos y vehículos autónomos, ha agilizado la gestión de inventarios y la entrega al tiempo que reduce los costos de mano de obra. Además, la

personalización de la experiencia del cliente a través de análisis avanzados y tecnologías como la realidad aumentada ha redefinido la relación entre las empresas y sus consumidores. Estos avances tecnológicos no solo han mejorado la eficiencia operativa, sino que también han permitido a las empresas obtener ventajas competitivas mediante la toma de decisiones más informadas y la adaptación ágil a las fluctuaciones del mercado. En este contexto de transformación digital, surge la pregunta de cómo la integración de la inteligencia artificial en la cadena de suministro impacta la confiabilidad humana y la toma de decisiones en un entorno cada vez más complejo y colaborativo.

La integración de la inteligencia artificial en la cadena de suministro plantea interrogantes sobre cómo afecta la confiabilidad humana y la toma de decisiones en un entorno cada vez más complejo y colaborativo (Dash et al., 2019). La hipótesis general es que las cadenas de suministros, como sistemas sociotecnológicos, son susceptible de ser optimizadas (aumento de disponibilidad, confiabilidad y eficiencia) gracias a la aplicación de técnicas de confiabilidad humana. Específicamente, en este plan de trabajo se formula la pregunta de investigación: ¿Cómo ha impactado la integración de la inteligencia artificial en la cadena de suministro en términos de confiabilidad humana y toma de decisiones? Cuya afirmación tentativa: Es posible que la implementación de la inteligencia artificial en la cadena de suministro mejore la confiabilidad humana al automatizar tareas repetitivas y reducir errores.

La investigación en el campo de la gestión de la cadena de suministro ha sido enriquecida significativamente por la aplicación de la inteligencia artificial (IA). Los estudios han agrupado estas metodologías en diferentes "clusters" (Pournader, Ghaderi, Hassanzadegan & Fahimnia, 2021), que abarcan desde la simulación y la dinámica de sistemas hasta el análisis de big data y las redes neuronales. Estos enfoques han sido aplicados para mejorar la toma de decisiones, el análisis de datos y la gestión de riesgos en la cadena de suministro. Además, se destacan áreas emergentes de investigación, como la implementación de métodos de aprendizaje automático para la identificación y evaluación de riesgos, así como la ampliación de su aplicación en el diseño estratégico de redes de suministro.

El sistema socio-técnico emerge como un marco conceptual fundamental para comprender la gestión de riesgos en la cadena de suministro. Este enfoque reconoce la interdependencia entre los elementos humanos, técnicos y organizacionales de la cadena, y destaca la importancia de abordar la complejidad y la adaptabilidad del sistema (Tonç et al., 2009). Los modelos de confiabilidad humana basados en la teoría de sistemas ofrecen una visión sistémica de los accidentes en los sistemas socio-técnicos modernos, capturando la causalidad y complejidad subyacente (Tonç et al., 2009).

El análisis sistémico basado en conceptos como resonancia y emergencia está estrechamente relacionado con la transmisión y amplificación de interrupciones en las cadenas de suministro (Swierczek, 2018). La transmisión de los efectos negativos del riesgo puede afectar a múltiples participantes en la cadena, y su intensidad puede ser absorbida o amplificada durante el proceso (Juttner et al., 2003).

La capacidad de la cadena de suministro para responder y recuperarse de eventos de riesgo está influenciada por diversos factores, como la flexibilidad, velocidad, visibilidad, colaboración, capacidad y adaptabilidad (Radhakrishnan et al., 2018). Estos conceptos permiten modelar la cadena de suministro como un sistema socio-técnico, cuya seguridad es una propiedad emergente (Radhakrishnan et al., 2018).

La gestión de riesgos en la cadena de suministro requiere un enfoque integrado que considere tanto los aspectos técnicos como humanos del sistema. La aplicación de la inteligencia artificial y los enfoques sistémicos ofrecen oportunidades para mejorar la confiabilidad humana y la toma de decisiones en un entorno cada vez más complejo y colaborativo. Sin embargo, es crucial reconocer la interdependencia y la complejidad inherentes a las cadenas de suministro modernas, así como la necesidad de abordar la transmisión y amplificación de interrupciones para garantizar su seguridad y continuidad operativa.

Si bien la gestión sostenible de la cadena de suministro presenta desafíos y oportunidades significativas en el contexto empresarial actual, el enfoque central de este artículo se centra en cómo la inteligencia artificial puede contribuir a la disminución de los errores humanos y, por tanto, al aumento de la confiabilidad humana en la gestión de la cadena de suministro. Sin embargo, es importante reconocer que la sostenibilidad también es un aspecto crucial en este contexto, ya que la eficiencia operativa y la responsabilidad social están intrínsecamente relacionadas con la confiabilidad y la calidad en la gestión de la cadena de suministro.

El presente artículo se organiza en cuatro secciones principales que exploran diferentes aspectos de cómo la inteligencia artificial está fortaleciendo la gestión de la cadena de suministro. En la primera sección, se aborda el papel de la IA en la predicción y optimización de la demanda, destacando cómo esta tecnología mejora la precisión de los pronósticos y permite una planificación más efectiva de las operaciones. La segunda sección examina las aplicaciones de la inteligencia artificial en la selección de proveedores, resaltando cómo estas herramientas están impulsando la eficiencia operativa y reduciendo errores en la toma de decisiones. En la tercera sección, se analiza cómo la IA está mejorando la producción y reduciendo errores en los procesos de fabricación, destacando su impacto en la calidad y eficiencia de la producción. Finalmente, la cuarta sección resume las conclusiones principales y destaca el papel transformador de la inteligencia artificial en la gestión de

la cadena de suministro, ofreciendo una visión integral de cómo esta tecnología está fortaleciendo la fiabilidad humana en cada etapa de la cadena de suministro.

2. METODOLOGIA

El enfoque metodológico adoptado en esta investigación se basó en un enfoque exploratorio, fundamentado en el constructivismo como base epistemológica, lo que permitió una aproximación flexible y contextualizada a la interacción entre la confiabilidad humana, la logística y la inteligencia artificial en la cadena de suministro. Este enfoque buscó construir una comprensión integral y enriquecedora del tema, considerando la diversidad de perspectivas y la complejidad de las interacciones involucradas.

En primer lugar, se llevó a cabo una revisión bibliográfica exhaustiva, utilizando bases de datos académicas para recopilar artículos relevantes que abordaran los temas de confiabilidad humana, logística e inteligencia artificial en la cadena de suministro. Esta actividad permitió identificar y seleccionar las fuentes más pertinentes para el estudio.

Posteriormente, se realizó un análisis de contenido de los artículos seleccionados, con el fin de identificar patrones, tendencias y temas recurrentes relacionados con el impacto de la inteligencia artificial en la confiabilidad humana y la toma de decisiones en la cadena de suministro. Este análisis proporcionó una visión general de la literatura existente y orientó la investigación en una dirección más informada.

Además, se llevó a cabo un estudio de casos, analizando ejemplos concretos de organizaciones que habían implementado soluciones de inteligencia artificial en la cadena de suministro. Este análisis permitió evaluar cómo la integración de la inteligencia artificial había influido en la confiabilidad humana y los resultados operativos en diferentes contextos y escenarios.

En paralelo, se exploraron las implicaciones éticas y sociales de la integración de la inteligencia artificial en la cadena de suministro, mediante la revisión de literatura especializada y la reflexión crítica sobre temas como la privacidad de datos, la dependencia tecnológica y el impacto en el empleo humano.

Basado en la revisión de la literatura y los hallazgos de las actividades anteriores, se propusieron posibles áreas de investigación futura y desarrollo en el campo de la confiabilidad humana, logística e inteligencia artificial, con el objetivo de generar perspectivas futuras y contribuir al conocimiento existente.

Por último, se fomentó la participación activa de estudiantes de la Facultad de Ciencias Económicas en el proyecto, con el fin de formar recursos humanos y promover el intercambio de ideas entre diferentes actores interesados en el tema. Esta integración intercátedras permitió enriquecer el enfoque metodológico con diversas perspectivas y experiencias.

3. MARCOS CONCEPTUALES

En el presente apartado se analizan los paradigmas de la confiabilidad humana y de la gestión de riesgos en la cadena de suministros con el propósito de explorar y analizar sus diferencias y similitudes que permitan la integración de ambos.

a. El paradigma de la confiabilidad humana

El término "Human Reliability Assessment" (HRA), evaluación o análisis de la confiabilidad humana, fue introducido por primera vez en 1962 por Munger (Munger, Smith, & Payne, 1962). Y se puede definir como la probabilidad que una tarea o trabajo sea completado satisfactoriamente por un individuo en un estado específico de la operación del sistema en un tiempo requerido mínimo (si es que hay requisitos de tiempo) (Meister, 1989).

En el sentido negativo del término, aparece el llamado "error humano", que se define como la falla en la ejecución de una tarea dada (o la ejecución de una tarea prohibida), que puede causar daños a los equipos o interrumpir la secuencia de operaciones (Hagen, 1976).

Prácticamente todos los métodos y enfoques HRA comparten el supuesto de que es significativo usar el concepto de "error humano", por lo tanto también es significativo el desarrollo de formas para estimar probabilidades de "error humano". Como consecuencia de esto, numerosos estudios se han realizado para producir conjuntos de datos o bases de datos que pueden ser utilizados como base para la determinación de probabilidades de error humano. Este punto de vista prevalece a pesar de serias dudas expresadas por destacados científicos y profesionales de HRA y disciplinas afines. Una crítica general de HRA (Dougherty, 1990), por ejemplo, señala que muchos enfoques HRA se basan en supuestos altamente cuestionables sobre el comportamiento humano.

El nacimiento de los métodos de HRA data del año 1960, pero la mayoría de las técnicas para la evaluación del factor humano, en términos de propensión a fallar, se han desarrollado desde mediados de los años 80. Las técnicas o enfoques de HRA se pueden dividir básicamente en dos categorías: primera y segunda generación. Actualmente, surgen las técnicas dinámicas de HRA o métodos de la tercera generación, entendido como una evolución de las generaciones anteriores (Di Pasquale, Iannone, Miranda, & Riemma, 2013).

Los métodos de primera generación de HRA o métodos cuantitativos HRA, se basaron en las estadísticas, el más importante es THERP, basado en el análisis del árbol de fallas. Una gran cantidad de métodos y modelos de confiabilidad en la teoría clásica asume que todas las probabilidades son precisas (Kim & Bishu, 2006), es decir, que cada probabilidad implicada es perfectamente determinable. La probabilidad de error humano puede ser asignada sobre la base de las características de la tarea del operador y luego modificada por factores que determinan el rendimiento (su sigla en inglés PSFs: "Performance Shaping Factors"). En la primera generación de HRA, las características de una tarea, representados por HEPS, se consideran como principales factores; el contexto, que está representado por PSF, se considera un factor de menor importancia en la estimación de la probabilidad de fallo humano (Kim & Bishu, 2006). Esta generación se concentra hacia la cuantificación, en términos de éxito / fracaso de la acción, con menos atención a la profundidad de las causas y razones de la conducta humana, tomados de las ciencias del comportamiento.

Entre las técnicas de primera generación encontramos: el juicio de probabilidad absoluta (sus siglas en inglés son APJ: "Absolute Probability Judgment"), la evaluación de los errores humanos y la técnica de reducción (sus siglas en inglés HEART: "Human Error Assessment and Reduction Technique"), la información de los datos de error humano justificado (sus siglas en inglés JHEDI: "Justified Human Error Data Information"), el análisis de la confiabilidad humana probabilístico (sus siglas en inglés PHRA: "Probabilistic Human Reliability Analysis"), sistema de árbol de la acción del operador (sus siglas en inglés OATS: "Operator Action Tree System"), y método del índice de probabilidad de éxito (sus siglas en inglés SLIM: "Success Likelihood Index Method"). Entre estos, el método más popular y eficaz es THERP, caracterizado, como otros enfoques de primera generación, por un tratamiento matemático preciso de la probabilidad y las tasas de error. La base de THERP es el modelado del árbol de eventos, donde cada rama representa una combinación de las actividades humanas, las influencias sobre las actividades y los resultados de estas actividades.

Las principales características de los métodos de primera generación se pueden resumir de la siguiente manera (Kim I. S., 2001): representación binaria de las acciones humanas (éxito / fracaso); atención en la fenomenología de la acción del hombre; baja atención en las acciones cognitivas humanas (falta de un modelo cognitivo); énfasis en la cuantificación de la probabilidad de realización incorrecta de las acciones humanas; dicotomía entre los errores de omisión y comisión; tratamiento indirecto de contexto.

THERP y los enfoques desarrollados en paralelo - como HCR (Human Cognition Reliability) desarrollado por Hannaman, Spurgin y Lukic en 1985 - describen los aspectos cognitivos del desempeño del operador con el modelado cognitivo del comportamiento humano, conocido como modelo de habilidad-regla-conocimiento (sus siglas en inglés SRK: "skill-rule-knowledge") por Rasmussen (1983). Este modelo, que se basa en la clasificación de la conducta humana, se divide en conducta basada en habilidades prácticas, en normas, y en conocimiento, dependiendo del nivel cognitivo utilizado. La atención y el pensamiento consciente que un individuo le da a las actividades disminuyen desde el tercer al primer nivel. Este modelo de comportamiento se ajusta muy bien con la teoría del error humano de Reason (1990), según la cual hay varios tipos de errores, en función del resultado de acciones llevadas a cabo con la intención de realizarlas o no.

Reason distingue entre: deslices, destinados a la ejecución de errores que se producen en el nivel de habilidad; lapsus, es decir, los errores en la ejecución derivados de la falla de la memoria, y las equivocaciones, los errores cometidos durante la puesta en práctica de la acción. En THERP, en cambio, las malas acciones se dividen en errores de omisión y errores de comisión, que representan, respectivamente, la falta de realización de las operaciones necesarias para conseguir el resultado y la ejecución de una operación que no se refiera a la tarea en cuestión, lo que impide la obtención del resultado (Hollnagel, 1998).

Los métodos HRA primera generación ignoran los procesos cognitivos que subyacen a la conducta humana, de hecho, poseen un modelo cognitivo sin realismo humano y psicológicamente inadecuado.

A menudo son criticados por no haber considerado el impacto de factores como el medio ambiente, los factores organizacionales y otros PSF pertinentes, errores de comisión, y por no utilizar métodos apropiados para juzgar a los expertos (Hollnagel, 1998) (Sträter, Dang, Kaufer, & Daniels, 2004) (Mosleh & Chang, 2004). Hallnagel señaló que "todas las insuficiencias de las metodologías anteriores de HRA, a menudo conducen a los analistas a realizar evaluación de HEP deliberadamente altos y con mayores límites de incertidumbre, para compensar, al menos en parte, estos problemas " (Hollnagel, 1998, pág. 10). Esto claramente no es una solución deseable.

A principios de 1990, la necesidad de mejorar los métodos de HRA genera una serie de importantes actividades de investigación y desarrollo en todo el mundo. Estos esfuerzos dieron lugar a grandes avances en los métodos de primera generación y el nacimiento de nuevas técnicas, identificadas como segunda generación. Estos métodos HRA fueron, en un primer momento, imprecisos y poco claros. Mientras que los métodos HRA de primera generación son principalmente enfoques conductuales, los métodos HRA de segunda generación aspiran a ser de tipo conceptual (Mosleh & Chang, 2007).

La separación entre las generaciones es evidente en el abandono del enfoque cuantitativo del análisis probabilístico de riesgo (sus siglas en inglés PRA "Probabilistic Risk Analysis") o análisis probabilístico de seguridad (sus siglas en inglés PSA "Probabilistic Safety Analysis") en favor de una mayor atención a la evaluación cualitativa de los errores humanos. La atención se centró en los aspectos cognitivos de los seres humanos, las causas de los errores en lugar de su frecuencia, el estudio de la interacción de los factores que aumentan la probabilidad de error, y la interdependencia de los PSF.

Los métodos HRA segunda generación (como CREAM "Cognitive Reliability and Error Analysis Method" o ATHEANA "A Technique for Human Event Analysis") se basan en modelos de conducta humana. Esta generación de métodos hace énfasis en la caracterización cualitativa del error humano, describiendo las raíces cognitivas y las funciones cognitivas humanas involucradas.

Es evidente que cualquier intento de comprensión de la conducta humana debe incluir el papel de la cognición humana, definida como el acto o proceso de conocimiento que incluye la conciencia y el juicio del operador humano. Desde la perspectiva del analista de HRA, la solución inmediata de tomar en consideración la cognición humana en los métodos de HRA fue la introducción de una nueva categoría de error: "error cognitivo", que se define tanto como la falta de una actividad que es predominantemente de naturaleza cognitiva y como la causa inferida de la actividad que falla. Por ejemplo, en CREAM, desarrollado por Erik Hollnagel en 1993, mantiene la división entre las causas y las consecuencias lógicas de un error humano. Las causas de la mala conducta (genotipos) son las razones que determinan la ocurrencia de ciertos comportamientos y los efectos (fenotipos) están representadas por las formas incorrectas del proceso cognitivo y acciones inapropiadas.

Los modelos cognitivos han sido desarrollados para representar el proceso lógico-racional del ser humano e incluir la dependencia con los factores personales (como el estrés, la incompetencia, etc.) y por la situación en la que se desempeña (sistema de conducción normal, condiciones anormales, o incluso situaciones de emergencia), y los modelos de interfaz hombre-máquina, que reflejan el sistema de control del proceso de producción (Marsden & Hollnagel, 1996). En esta perspectiva, el hombre debe ser visto en un sistema integrado, hombres-tecnología-empresa (sus siglas en inglés MTO: "Man-Technology-Organization"), es decir, un equipo de operadores (hombres) que colaboran para lograr el mismo objetivo, que interviene en el proceso mecánico (tecnología) dentro de un sistema de organización y gestión de la empresa (organización) y, en conjunto, representan los recursos disponibles.

El modelo de operador CREAM es más importante y menos simplista que el de los enfoques de primera generación. El modelo cognitivo utilizado es el modelo de control contextual (sus siglas en inglés COCOM: “Contextual Control Model”), basado en la suposición de que el comportamiento humano se rige por dos principios básicos: la naturaleza cíclica de la cognición humana y la dependencia de los procesos cognitivos de contexto y el entorno de trabajo. El modelo se refiere al paradigma IPS que considera por separado las funciones cognitivas (percepción, la interpretación, la planificación y la acción) y sus mecanismos de conexión y los procesos cognitivos que rigen la evolución (Hollnagel, 1998) (Kim & Bishu, 2006). En tanto que, el análisis de plantas estandarizadas, método de análisis de la confiabilidad de riesgo humano (sus siglas en inglés SPAR-H: “Standardised Plant Analysis Risk–Human reliability analysis method”) (Boring & Blackman, 2007) se basa en un modelo de procesamiento de la información explícita de la conducta humana, derivada de las ciencias del comportamiento.

Otra diferencia entre las generaciones se refiere a la elección y el uso de PSF. Ninguno de los primeros enfoques HRA trata de explicar cómo los PSFs ejercen su efecto en el rendimiento y, además, PSF - tales como los métodos de gestión y actitudes, factores organizativos, las diferencias culturales y de comportamiento irracional - no se tratan adecuadamente en estos métodos. Los PSF en la primera generación se derivaron principalmente centrándose en el impacto ambiental de los operadores, mientras que los PSF en la segunda generación fueron obtenidos al centrarse en los efectos cognitivos de los operadores (Lee, Kim, Ha, & Seong, 2011). Los PSF de ambas generaciones se revisaron y se recogen en una sola taxonomía de rendimiento de los factores que influyen para HRA (Kim & Jung, 2003).

Entre los métodos de la segunda generación se pueden mencionar: una técnica para el análisis de errores humanos (sus siglas en inglés ATHEANA: “A Technique for Human Event Analysis”), Simulación cognitiva Ambiental (sus siglas en inglés CES: “Cognitive Environmental Simulation”), la Evaluación Conexionismo de Confiabilidad Humana (sus siglas en inglés CAHR: “Connectionism Assessment of Human Reliability”) y Método de Evaluación de la Realización de Misiones Operacionales para la Seguridad (de sus siglas en francés MERMOS: “Méthode d'Evaluación de la Réalisation des Missions Opérateur pour la Sûreté”).




Figura 1. Paradigma de la confiabilidad humana (Fuente: elaboración propia)

b. El paradigma de la gestión de riesgos en la cadena de suministros

La gestión de riesgos en la cadena de suministros (del inglés: Supply Chain Risk Management SCRM) se puede definir como la gestión del riesgo de la cadena de suministro a través de la coordinación o la colaboración entre los socios de la cadena de suministro a fin de garantizar la rentabilidad y la continuidad, diferenciándose de la gestión de riesgo tradicional por orientarse a identificar y reducir el riesgo, no solo a nivel de la empresa, sino que se centra en cadenas de suministro completas (Khojasteh-Ghamari & Irohara, 2018). Es una disciplina emergente, si bien los primeros estudios de riesgo en una cadena de suministro datan de 1964, no es hasta hace sólo algunos años que se independiza como disciplina y comienzan a aparecer libros y estudios específicos de la temática (Tang, 2006).

El paradigma de análisis de la gestión de riesgos en la cadena de suministros tiene aspectos tridimensionales (Brindley, 2017). Una primera dimensión es la unidad de análisis: la unidad más pequeña son las actividades logísticas individuales, compañías logísticas, configuraciones diádicas (empresas líderes y seguidoras), cadena de suministro y, la unidad de análisis más amplia, una red completa de suministros. Una segunda dimensión es el proceso de gestión de riesgos hasta llegar a la administración de negocios: identificación de riesgos, análisis y evaluación de riesgos, administración de riesgos, administración estratégica de negocios. Por último, una tercera dimensión es el tipo de riesgo e incertidumbre: accidentes operacionales, catástrofes operacionales, incertidumbres estratégicas.

El principal riesgo para una cadena de suministro es la interrupción del flujo de materiales (Waters, 2011). De este precepto es fácil inferir que el enfoque que adquiere la gestión de riesgos en la cadena logística acompaña la estructura y funciones a lo largo del flujo de materiales. La mayoría de los autores en la disciplina coinciden en el intento de identificar los riesgos asociados a las funciones principales de este flujo de materiales: gestión del transporte, gestión de almacenes, manejo de materiales, gestión de órdenes, gestión de compras, servicios al consumidor, gestión de la información; o de sus principales actividades: diseño de la cadena de suministros, compras y abastecimiento, transporte de abastecimiento, recepción de pedidos, almacenamiento, control de existencias, manejo de materiales, recolección de pedidos, transporte de distribución, reciclado y disposición de residuos, comunicación, etc. Esta identificación de riesgos permite generar recomendaciones que justamente apuntan a la disponibilidad y mantenibilidad de este flujo de materiales.

Las decisiones estratégicas y tácticas de una empresa afectan la medida en que su cadena de suministro puede mitigar las consecuencias de los eventos adversos. Más allá de la reducción de los costos, la administración efectiva de la cadena de suministro también debe involucrar el diseño de una red de suministro robusta. La búsqueda de ventajas competitivas lleva a las empresas a extender sus cadenas de suministro y a estrategias de eficiencia que no suelen estar acompañadas de un análisis de riesgo. Tendencias como la globalización, la fabricación ajustada, el abastecimiento único y la deslocalización aumentan las complejidades e interdependencias en las cadenas de suministro.

Pero una tendencia más preocupante es que los gerentes de logística cambien las operaciones para brindar un mejor servicio y eficiencia, sin considerar las consecuencias sobre el riesgo. Como resultado, las cadenas de suministro son cada vez más eficientes, pero a costa de aumentar la vulnerabilidad. Incluso cuando el riesgo individual para cada miembro de una cadena es pequeño, el efecto acumulativo sobre los cientos o miles de miembros en una cadena grande se vuelve muy significativo.

Esto se puede evidenciar en la encuesta realizada por Aberdeen Group que encontró que el 82% de los gerentes informaron interrupciones en las cadenas de suministro en los dos años anteriores (Minahan, 2005). Las principales causas fueron: productos de mala calidad o dañados 50%, entregas extraviadas o tardías 49%, aumentos inesperados en los costos de suministro 47%, tiempos de entrega más largos 33%, restricciones en la capacidad de suministro 32%.

El problema de los nuevos métodos de logística que aumentan el riesgo de la cadena de suministro es que esto no ocurre porque los gerentes deciden positivamente trabajar con niveles más altos de riesgo, sino porque simplemente no están considerando los riesgos y los están incluyendo en sus cálculos. Por ejemplo, la gestión de inventarios, los gerentes dicen que inventarios pequeños en realidad reducen el riesgo, ya que hay menos posibilidades de existencias no vendidas, obsolescencia, daños, deterioro y todos los demás riesgos de las existencias acumuladas. Esto es indudablemente cierto, por lo que existe una aparente paradoja, con métodos diseñados para reducir algunos riesgos que realmente aumentan a otros. Jüttner (2005) encontró que los factores que probablemente aumentarían la vulnerabilidad de la cadena de suministro son la globalización (reportada por el 52% de los gerentes), reducción de los niveles de stock (51%), menor cantidad de proveedores (38%) y tercerización (30%).

4. TAXONOMÍA DE ERRORES HUMANOS Y RIESGOS DE INTERRUPCIÓN DEL FLUJO DE MATERIALES

En esta sección se analizarán los tipos de riesgos y fallas que ambas disciplinas, HRA y SCRM, han desarrollado. Como se podrá observar, el énfasis de la gestión de riesgos en la cadena de suministros está en la identificación de los tipos de riesgos y su análisis, es decir, el desarrollo de una taxonomía de riesgos. De igual manera los análisis de confiabilidad humana ponen énfasis en una taxonomía de errores humanos. Estos focos

epistemológicos pueden ser asociados al clásico reduccionismo científico, en el intento de describir las partes constitutivas de un todo para luego comprender su funcionamiento.

a. Taxonomías de errores humanos en los análisis de confiabilidad humana

En muchas áreas de conocimiento usan clasificaciones o taxonomías como una forma de organizar el conocimiento. En el área del error humano esta clasificación tiene valor teórico y práctico. Las taxonomías que enfatizan en conductas observables tienen valor más práctico. Pueden ser usadas en retrospectiva para determinar puntos de debilidad en el diseño, o en prospectiva para predecir posibles errores. En la industria de la salud, dada la gran diversidad de procedimientos y circunstancias, es difícil establecer una taxonomía.

Las taxonomías que enfatizan en los aspectos cognitivos tienen valor predictivo. Sin embargo predecir el error humano es una tarea difícil. En el proceso de establecer asignaciones entre el contexto y la fiabilidad humana, existen numerosas capas de conjeturas producidas por las situaciones complejas y multidimensionales que se presentan en los trabajos actuales y la incertidumbre asociada a los objetivos, intenciones y estados emocionales y atencionales humanos.

Kirwan habla de técnicas taxonómicas (Kirwan, 1998) y especifica que pueden ser genéricas (como THERP) o específicas y relacionadas con una industria específica (como SRS-HRA), o específicas y relacionadas con un tipo de error (como INTENT). Estas técnicas son esencialmente basadas en la experiencia, por tanto, tendrán cierta validez contextual.

Rasmussen (Rasmussen, 1983) en su modelo SRK (por sus siglas en inglés Skill, Rules, Knowledge) clasifica la actuación humana de acuerdo al grado de conciencia o control cognitivo que se presta al realizarla, si es un bajo nivel de conciencia (acciones automatizadas) el comportamiento estará basado en habilidades, si el nivel de conciencia es medio el comportamiento estará basado en reglas y si tiene un alto nivel de conciencia estará basado en conocimientos.

El método CREAM (Cognitive Reliability and Error Analysis Method) creado por Hollnagel (Hollnagel, 1998) se aparta del concepto de error humano y por lo tanto de una taxonomía, luego la probabilidad de que algo se realice incorrectamente (Hollnagel lo llama “anhelado error humano”) está determinado más bien por las condiciones que por las probabilidades de error inherentemente humanas. La probabilidad que el desempeño como un todo falle o sea no satisfactorio está descrito en términos del “grado de control” que un operario (o un equipo) tiene sobre una situación.

En la figura 2 se resumen las taxonomías de Reason (color verde), Rasmussen (color rosado), Payne y Altman (color naranja), Wickens (color celeste) y CREAM (color azul). Como se puede observar existen zonas grises donde ninguna de las taxonomías clasifica errores. Este hecho fue demostrado empíricamente por Wiegmann y Shappell (Wiegmann & Shappell, 1997). El resultado de ese estudio fue que el 19,37% de los factores causales no se pueden categorizar de acuerdo al modelo de información de Wickens; el 11,57% de acuerdo al modelo de Rasmussen y el 15,73% en el caso del modelo de Reason.




Figura 2. Resumen de las taxonomías de error humano y clasificaciones de la conducta humana. Basado en (Baziuk, Rivera, & Nuñez McLeod, 2014).

Otro resultado interesante del trabajo de Wiegmann y Shappell es la distribución de errores de acuerdo a las taxonomías, que se muestran en la figura 3.




Figura 3. Distribución de errores de acuerdo a las taxonomías de Wickens (W), Rasmussen (R) y Reason (RE). Datos extraídos de (Wiegmann & Shappell, 1997).

b. Taxonomía de riesgos y fallas en la gestión de riesgos en la cadena de suministros

Hendricks y Singhal (2003) encontraron que el 34% de las interrupciones en la cadena de suministro se originó a partir de operaciones internas, lo que significa que la empresa misma fue responsable de las interrupciones; los proveedores fueron los principales responsables del 15% de las interrupciones, los clientes el 13%, la naturaleza y el gobierno el 4% cada uno y varias combinaciones de ellos el 6%. Descubrieron que la escasez de piezas era la razón principal de las interrupciones en la cadena de suministro (en el 22% de los incidentes), seguidas por cambios repentinos en la demanda (9%), cambios en los pedidos por parte de los clientes (9%) y diversos problemas de producción (9%), problemas de desarrollo (4%) y calidad (3%).

Una breve encuesta (Scarborough, 2007) sugiere que los gerentes suelen estar más preocupados por los siguientes tipos de interrupciones: pérdida de los sistemas de tecnología de la información (76%); pérdida de los sistemas de telecomunicación (67%); daño de fuego a las instalaciones (52%); daño a la imagen corporativa (47%); pérdida de personal calificado (42%); salud y seguridad de los empleados (41%); interrupción de la

cadena de suministro (39%); acceso a las instalaciones (32%); un incidente ambiental (31%); clima severo (27%); seguridad del producto (16%); daño terrorista (14%).

El riesgo en sí mismo dentro del contexto de la cadena de suministro puede clasificarse en varias dimensiones (Zsidisin & Ritchie, 2009):

- 1) Interrupciones en el suministro de bienes o servicios, incluida mala calidad, que causan tiempo de inactividad y consecuente falla en satisfacer los requisitos del cliente a tiempo.
- 2) La volatilidad en términos de precio puede generar dificultades para transmitir los cambios de precios al cliente y potencialmente tener consecuencias en la pérdida de beneficios
- 3) Los productos o servicios de baja calidad, ya sea upstream o downstream, pueden tener un impacto en el nivel de satisfacción del cliente con consecuencias para ingresos futuros y posiblemente reclamos más inmediatos por compensación financiera.
- 4) La reputación de la empresa, a menudo generada por cuestiones que no están directamente relacionadas con la cadena de suministro en sí misma, puede presentar riesgos. Los comentarios inadvertidos de los altos ejecutivos o la falta de aprobación de ciertos protocolos pueden dañar la reputación de la organización.

De acuerdo a Donald Waters (Waters, 2011), los riesgos en una cadena de suministros se pueden clasificar en riesgos internos a las organizaciones, externos a las organizaciones o externos a la cadena de suministro (ver tabla 1).

Tipos de riesgos en las cadenas de suministros	Subtipos	Principales Causas
Los riesgos internos surgen de las operaciones dentro de una organización	- riesgos inherentes en las operaciones (como accidentes, la fiabilidad de los equipos, la pérdida de un sistema de tecnología de la información, errores humanos y problemas de calidad); - riesgos que surgen más directamente de las decisiones de los gerentes (como la elección del tamaño de los lotes, los niveles de existencias de seguridad, los problemas financieros y los plazos de entrega).	Se producen por las vulnerabilidades internas de la organización, fallas en la administración, fallas en la toma de decisiones, fallas en los equipos.
Los riesgos de la cadena de suministro son externos a las organizaciones, pero dentro de la cadena de suministro	- riesgos de los proveedores: confiabilidad, disponibilidad de materiales, plazos de entrega, problemas de entrega, acción industrial, etc. - riesgos de los clientes: demanda variable, pagos, problemas con el procesamiento de pedidos, requisitos personalizados, etc.	Se producen a partir de las interacciones entre los miembros de la cadena de suministro. Las principales causas de estos riesgos son una cooperación inadecuada entre los miembros y la falta de visibilidad.
Los riesgos externos son externos a la cadena de suministro	Accidentes, clima extremo, legislación, grupos de presión, delincuencia, desastres naturales, guerras, etc.	Surgen de las interacciones con su entorno. Son de alta incertidumbre y sus causas son difíciles de determinar.

Tabla 1. Tipos y subtipos de riesgos en la cadena de suministros (adaptado de (Waters, 2011)

Por otro lado, Schlegel y Trent (Schlegel & Trent, 2016) clasifican los riesgos en estratégicos, riesgos normales o peligros normales (aquellos para los cuales se contrata un seguro), riesgo financiero y riesgo operacional. Y los tipifican en cuatro pilares básicos:

- 1) Riesgo de suministro: este riesgo abarca áreas tales como la continuidad del proveedor, el abastecimiento estratégico, la viabilidad y capacidad del proveedor, el precio de las materias primas, las evaluaciones de los proveedores, la logística de entrada, el fraude, la corrupción y la falsificación.

Los riesgos inherentes aquí son las interrupciones causadas por la incapacidad de los proveedores para entregar a tiempo, fallas de calidad, fallas financieras, fallas de cumplimiento, complejidad del canal y fallas de comunicación.

- 2) Riesgo de proceso: incluye sistemas de telecomunicaciones, fusiones y adquisiciones, estrategia de marketing, estructura organizacional, marcos y métricas, estrategia y ejecución de la cadena de suministro, fabricación y calidad, evaluación del riesgo organizacional, mapas de calor y salas de guerra. Aquí los riesgos inherentes incluyen interrupciones causadas por problemas de calidad, escasez de inventario, entregas tardías, falta de capacidad, fallas en los equipos, cortes de las telecomunicaciones, mala ejecución general y desalineación de la estrategia y las métricas.
- 3) Riesgo de demanda: abarca áreas como nuevos clientes, tendencias del mercado, interés / gasto del consumidor, gestión / previsión de la demanda, planificación de requisitos de distribución, integridad del producto, servicio al cliente y planificación de escenarios. Los riesgos inherentes aquí son las interrupciones causadas por problemas en la distribución, las acciones de los competidores, la reputación del producto, la gestión de marca, las redes sociales / tendencias, la logística y el sentimiento del cliente.
- 4) Riesgo ambiental: abarca áreas tales como regulaciones gubernamentales, impuestos, volatilidad económica, cambio de divisas, desastres naturales y cumplimiento. Los riesgos inherentes son los desastres naturales, los riesgos geopolíticos y energéticos, la seguridad portuaria, la seguridad de las instalaciones y la logística, las fluctuaciones del cambio de divisas, la economía global, la guerra, las pandemias y la desobediencia civil.

Los autores de SCRM han realizado grandes esfuerzos en identificar y caracterizar los factores que predisponen al incremento de los riesgos, entre los que se destacan (Waters, 2011) (Schlegel & Trent, 2016):

- 1) Incremento de la globalización de mercados: sobre todo a través de tercerizaciones, que se extienden en las cadenas de suministro de extremo a extremo.
- 2) Aumento de los niveles de incertidumbre económica y la volatilidad del mercado, que crean una variabilidad adicional en la demanda y la oferta y hacen que sea más difícil lograr la planificación del suministro de la demanda.
- 3) Incompatibilidad operacional: Cada organización ejecuta sus operaciones de la manera que mejor se adapte a sus propios fines.
- 4) Decisiones complejas: Las cadenas de suministro son largas y complejas, y no es realista esperar que cada gerente de la cadena tome las decisiones correctas. Por lo tanto, es probable que ocurra algo inesperado en alguna parte, tal vez por un gerente que comete un error, y las consecuencias se propagan a través de la cadena.
- 5) Expansión de riesgo: Forrester (1961) describió el "efecto látigo", donde el riesgo se amplifica a medida que se mueve a través de una cadena de suministro.
- 6) Inercia: En completo contraste con la agilidad está el concepto de inercia en una cadena de suministro, que es la renuencia a realizar cambios o adaptarse a cualquier tipo de condiciones nuevas.

Otros riesgos pueden estar asociados con esto, y el Servicio de Seguridad del Reino Unido (2006) - comúnmente denominado MI5 - enumera las posibles consecuencias de un incidente terrorista importante como: pérdida de personal por muerte o lesiones; daño a los edificios; pérdida de sistemas de TI, registros, comunicaciones y otras instalaciones; la falta de disponibilidad del personal debido al transporte interrumpido o su falta de voluntad para viajar; efectos psicológicos adversos en el personal, incluido el estrés y la desmoralización; interrupción a las organizaciones y negocios relacionados que son necesarios para las operaciones; daño a la reputación; nuevas demandas de negocios puestas en la organización.

5. INTELIGENCIA ARTIFICIAL Y CONFIABILIDAD HUMANA EN LA CADENA DE SUMINISTRO: APLICACIONES Y AVANCES TECNOLÓGICOS

La inteligencia artificial (IA) es un campo de la informática que abarca el desarrollo de sistemas capaces de realizar tareas que normalmente requieren inteligencia humana (Bughin et al., 2018). Se estima que las tecnologías de IA contribuirán económicamente con alrededor de 13 billones de dólares para 2030, potencialmente aumentando el PIB global en aproximadamente un 1.2 por ciento anualmente (Bughin et al., 2018). A pesar de su potencial para alterar la forma en que operan las organizaciones, un estimado del 37% de

las organizaciones aún están buscando definir sus estrategias de IA, mientras que el 35% está luchando por encontrar la aplicación adecuada (Andrews, 2018).

El término "inteligencia artificial" fue acuñado por primera vez por John McCarthy en 1955 para explorar la capacidad de las máquinas para usar el lenguaje y resolver problemas que normalmente están reservados para los humanos (McCarthy et al., 1955). Aunque no existe una definición estándar y acordada de IA, se consideran dos dimensiones principales: el rendimiento del sistema en comparación con el pensamiento humano o la racionalidad ideal, y si el sistema coincide con el rendimiento humano en actuar racionalmente (Russell Stuart y Norvig, 2009). Adoptamos la definición ampliamente aceptada proporcionada por Marvin Minsky, fundador del Laboratorio de Inteligencia Artificial del MIT (Minsky, 1968): "la ciencia de hacer que las máquinas hagan cosas que requerirían inteligencia si las hicieran los hombres".

La reciente expansión del interés en la IA se atribuye a varios factores, incluidas las mejoras significativas en la potencia computacional, la disponibilidad de grandes conjuntos de datos para el entrenamiento de algoritmos y el desarrollo de nuevos algoritmos de aprendizaje (Duan et al., 2019; Leary, 2013; Al-Jarrah et al., 2015). Además, las inversiones significativas realizadas por las principales empresas como Google, IBM, Microsoft y Amazon también han impulsado los desarrollos recientes en el campo (Lohr, 2016).

Para aplicar técnicas de IA a un dominio específico, un paso preliminar es comprender las principales ramas de la IA. En este sentido, se ha propuesto una taxonomía de IA que clasifica los métodos de IA en un grado razonable (Salkind, 2010). Esta taxonomía, validada por expertos en IA y profesionales de la cadena de suministro, proporciona una perspectiva detallada en términos de ramas principales y aplicaciones de los métodos de IA.

La primera rama de la IA se refiere a enfoques relacionados con la percepción e interacción, como el procesamiento del lenguaje natural (NLP), el reconocimiento de voz y la visión por computadora (Ramos et al., 2008). Por ejemplo, el NLP se ha utilizado recientemente para establecer interfaces hombre-máquina mejoradas (Zanon et al., 2020), mientras que el reconocimiento de voz ha avanzado significativamente, con aplicaciones ampliamente utilizadas como Google Home y Amazon Alexa (de Barcelos Silva et al., 2020).

La segunda rama de la IA incluye aplicaciones y métodos destinados a aprender de los datos, como el aprendizaje automático (machine learning), que se clasifica en métodos supervisados, no supervisados y de refuerzo (Priore et al., 2019). Por ejemplo, el aprendizaje automático se ha utilizado extensivamente para la predicción de series temporales (Carbonneau et al., 2008).

La tercera rama de la IA comprende aplicaciones y métodos relacionados con la toma de decisiones, incluidos sistemas expertos, planificación, simulación y optimización (Duan et al., 2019). Estos métodos se han aplicado ampliamente en la optimización de operaciones y problemas de planificación y programación en la cadena de suministro (Diabat y Deskoors, 2016).

La innovación en la cadena de suministro es fundamental para mantener la competitividad y la eficiencia en un mercado en constante cambio, y la inteligencia artificial (IA) está desempeñando un papel crucial en este proceso. Esta área se encuadra dentro de la cuarta rama de la taxonomía propuesta, que se centra en métodos y aplicaciones de IA destinados a impulsar la innovación en la cadena de suministro (Duan et al., 2019; Pan et al., 2020; Soleimani et al., 2018).

Uno de los aspectos clave de la innovación impulsada por la IA en la cadena de suministro es la optimización de procesos y operaciones. La IA se utiliza para identificar áreas de mejora, automatizar tareas repetitivas y aumentar la eficiencia en toda la cadena de suministro, desde la gestión de inventarios hasta la planificación de la producción (Rao et al., 2020). Algoritmos de optimización avanzados, como la optimización basada en algoritmos genéticos y la optimización basada en enjambres de partículas, se aplican para encontrar soluciones óptimas a problemas complejos de la cadena de suministro (Allam y Dhunny, 2019; Fischetti y Fraccaro, 2019).

Además de la optimización de procesos, la IA también impulsa la innovación en la cadena de suministro a través de la mejora de la visibilidad y la predicción. Mediante el análisis de datos en tiempo real y la aplicación de algoritmos de aprendizaje automático, las organizaciones pueden anticipar la demanda del mercado, identificar tendencias emergentes y tomar decisiones proactivas para evitar problemas potenciales (Lee et al.,

2020). Esto se traduce en una mayor capacidad de respuesta ante cambios en la demanda del mercado y una reducción del riesgo de exceso o escasez de inventario.

Otro aspecto importante de la innovación impulsada por la IA en la cadena de suministro es la mejora de la colaboración y la coordinación entre los actores de la cadena. Plataformas de colaboración basadas en IA facilitan la comunicación y el intercambio de información entre proveedores, fabricantes, distribuidores y minoristas, lo que permite una planificación más coordinada y una respuesta más rápida a los cambios en la demanda o en las condiciones del mercado (Wang et al., 2018).

La IA está impulsando una revolución en la gestión de la cadena de suministro al ofrecer nuevas formas de percepción e interacción, aprendizaje de datos y toma de decisiones. Al comprender estas ramas principales de la IA y sus aplicaciones en la cadena de suministro, las organizaciones pueden aprovechar su potencial para mejorar la eficiencia, la precisión y la confiabilidad en la gestión de la cadena de suministro. La aplicación de la IA está transformando radicalmente la forma en que se gestionan y operan las cadenas de suministro, impulsando la innovación en múltiples niveles, permitiendo automatizar tareas y tomar decisiones sin la intervención humana, lo que reduce la posibilidad de errores humanos en la gestión de la cadena de suministro (Riahi et al., 2021). Desde la optimización de procesos hasta la mejora de la visibilidad y la colaboración, la IA ofrece a las organizaciones herramientas poderosas para mantenerse ágiles, eficientes y competitivas en un entorno empresarial en constante evolución.

La gestión eficiente de la cadena de suministro es fundamental para el éxito de cualquier empresa en un entorno empresarial cada vez más competitivo y dinámico. En este contexto, la integración de la inteligencia artificial (IA) está revolucionando la forma en que se abordan los desafíos y se aprovechan las oportunidades en cada etapa de la cadena de suministro. En los 7 apartados siguientes se analiza desde la predicción y optimización de la demanda hasta la mejora de la experiencia de entrega, pasando por la selección de proveedores y la optimización de promociones y precios, la IA está fortaleciendo la fiabilidad humana y mejorando la eficiencia operativa en todas las áreas clave.

En el apartado de "Predicción y Optimización de la Demanda", se exploran métodos avanzados de análisis de datos para anticipar las necesidades del mercado y optimizar los niveles de inventario. La IA permite a las empresas tomar decisiones más informadas y estratégicas para satisfacer la demanda de manera eficiente, minimizando los errores humanos y maximizando la rentabilidad.

En "Aplicaciones de inteligencia artificial en la selección de proveedores", se examina cómo la IA está siendo utilizada para agilizar el proceso de selección de proveedores y mejorar la calidad de los productos y servicios. Al automatizar tareas clave y evaluar datos en tiempo real, las empresas pueden reducir errores y optimizar la eficiencia operativa en su red de suministro.

"Mejora de la Producción y Reducción de Errores" se centra en la integración de la IA en los procesos de fabricación para aumentar la precisión y seguridad. Desde la identificación de errores hasta la optimización de activos, la IA está mejorando la fiabilidad humana y la calidad del producto final en la cadena de suministro.

En el ámbito de "Optimización de Promociones y Precios", la IA se utiliza para analizar datos y personalizar estrategias de marketing y ventas. Al predecir comportamientos del consumidor y ajustar precios dinámicamente, las empresas pueden aumentar la efectividad de sus promociones y mejorar la satisfacción del cliente.

"Mejora de la Experiencia de Entrega" explora cómo la IA está transformando la logística y la distribución, permitiendo entregas más personalizadas y eficientes. Desde el seguimiento en tiempo real hasta la entrega mediante drones, la IA está optimizando la experiencia del cliente y aumentando la fiabilidad en la cadena de suministro.

En "Maximizando el Potencial de Aprendizaje de Datos", se analiza cómo la IA está potenciando la capacidad de las organizaciones para analizar y utilizar grandes volúmenes de datos. Desde el aprendizaje automático hasta el análisis de sentimientos, la IA está permitiendo a las empresas tomar decisiones más informadas y estratégicas en la gestión de la cadena de suministro.

En conjunto, estos apartados destacan cómo la integración de la IA está impulsando la eficiencia, la precisión y la fiabilidad humana en cada aspecto de la gestión de la cadena de suministro, allanando el camino hacia un futuro más competitivo y exitoso. La tabla 2 resume algunos casos empresariales mencionados en estos apartados, junto con las técnicas de IA utilizadas y los principales resultados alcanzados.

Caso	Técnica de IA empleada	Principal Resultado
Amazon	Aprendizaje Automático	Optimización de inventario en tiempo real
UPS	Drones	Entrega más rápida y eficiente
Associated Press	Wordsmith, Articulo, Quill	Generación automatizada de contenido personalizado
Forbes	Wordsmith, Articulo, Quill	Generación automatizada de contenido personalizado
Airbus	Tecnologías de IA	Priorización de objetivos de ventas y optimización de precios
Tetra Pak	Tecnologías de IA	Optimización del precio de servicios y mejora de rentabilidad
Wise Athena	Programa de Gestión de Rendimiento	Determinación de mejores precios y decisiones estratégicas

Tabla 2. Casos empresariales de integración de IA en la gestión de la cadena de suministro.

a) Predicción y Optimización de la Demanda: Fortaleciendo la Fiabilidad Humana en la Gestión de la Cadena de Suministro

La integración de la inteligencia artificial (IA) en los procesos de predicción y optimización de la demanda no solo ha transformado los métodos tradicionales de proyección de ventas, sino que también ha reforzado significativamente la confiabilidad humana en la toma de decisiones logísticas. Al automatizar tareas repetitivas y propensas a errores, como la recopilación y análisis de datos, la IA libera a los profesionales de la cadena de suministro de la carga cognitiva asociada, permitiéndoles centrarse en actividades de mayor valor agregado, como la innovación y la resolución de problemas complejos. Esta colaboración entre humanos y sistemas de IA está sentando las bases para una cadena de suministro más confiable y resiliente en el futuro.

Al utilizar algoritmos avanzados y capacidades de procesamiento masivo de datos, la IA ha mejorado significativamente la precisión de los pronósticos de demanda, permitiendo a las organizaciones anticiparse de manera más eficiente a las necesidades del cliente (Bughin et al., 2017; Yao, 2017).

Estudios recientes han demostrado que la integración de modelos de pronóstico basados en series temporales, métodos de regresión de vectores de soporte y técnicas de aprendizaje profundo puede aumentar la precisión de la predicción de la demanda (He, Zha, Li, 2013) (Kilimci et al, 2019). Además, se ha destacado que el análisis de sentimientos en las redes sociales puede proporcionar indicadores tempranos de la demanda real del consumidor, lo que permite una predicción más precisa de la demanda futura en comparación con otros métodos tradicionales (Swain,2019). La combinación de métodos de análisis de sentimientos con modelos predictivos existentes puede mejorar aún más la precisión de los modelos de predicción de la demanda (Liu, Huang, An, Yu, 2007).

Este avance tecnológico no solo ha transformado los procesos de proyección de ventas, sino que también ha reforzado la confiabilidad humana en la toma de decisiones logísticas. La capacidad de los sistemas de IA para analizar grandes conjuntos de datos reduce la carga cognitiva asociada con la toma de decisiones en entornos complejos, proporcionando a los profesionales de la cadena de suministro una base sólida para la planificación y ejecución de las operaciones (Bughin et al., 2017).

Un ejemplo destacado es el caso de Otto, una empresa de comercio electrónico alemana que ha logrado reducir drásticamente (hasta el 90%) su inventario utilizando aplicaciones de IA para pronosticar la demanda con precisión. Los pronósticos de IA son tan confiables que Otto construye su inventario anticipando los pedidos, sin necesidad de intervención humana (Burgess, 2018). Al eliminar la necesidad de intervención

humana en tareas repetitivas y propensas a errores, la IA libera el potencial humano para actividades de mayor valor agregado, como la innovación y la resolución de problemas complejos (Burgess, 2018).

La capacidad de los sistemas de IA para procesar y analizar automáticamente grandes conjuntos de datos ha mejorado significativamente la precisión de los pronósticos de demanda, lo que permite a las empresas optimizar sus operaciones de abastecimiento y reducir costos relacionados con el transporte, el almacenamiento y la administración de la cadena de suministro (Yao, 2017). Esta precisión en los pronósticos también permite a las organizaciones tomar decisiones más informadas y rápidas, lo que aumenta la confianza en la planificación y ejecución de la cadena de suministro.

En el ámbito del aprendizaje de datos, se han identificado varios enfoques que contribuyen al fortalecimiento de la predicción de la demanda disminuyendo los errores humanos. Uno de los más clásicos es el análisis de series temporales, donde se ha desarrollado un enfoque estadístico para el suavizado exponencial y la mejora de la precisión de los pronósticos (Gardner, 2006). Este enfoque ha permitido una mejor comprensión de las tendencias y patrones en los datos de demanda, lo que ha llevado a una toma de decisiones más informada en la planificación de la cadena de suministro (Fildes et al., 2009). Más recientemente, la simulación y la dinámica de sistemas, que proporciona herramientas para analizar y mejorar el rendimiento de la cadena de suministro en diferentes escenarios (Van Der Zee y Van Der Vorst, 2005; Holweg et al., 2005).

Otro enfoque importante es el uso de algoritmos genéticos y modelado basado en agentes, que ofrecen métodos innovadores para abordar la complejidad y la incertidumbre en la toma de decisiones logísticas (Malmberg, 1996; Swaminathan et al., 1998). Estas técnicas permiten desarrollar modelos predictivos más sofisticados y adaptativos, que pueden mejorar la eficiencia y la agilidad de la cadena de suministro.

En la actualidad, el de análisis de big data, que abarca una amplia gama de aplicaciones en diferentes campos, incluida la gestión de la cadena de suministro. Dentro de este enfoque, se ha investigado el uso de big data y análisis de datos para la selección de proveedores, la gestión de riesgos en la cadena de suministro y la planificación y control de la producción (Cavalcante et al., 2019; Ivanov et al., 2019; Dolgui et al., 2019). Estas investigaciones demuestran el potencial de las tecnologías de big data para mejorar la eficiencia y la agilidad en la cadena de suministro, complementando los enfoques tradicionales de predicción y optimización de la demanda.

En particular en referencia al big data, existe un creciente interés en el uso de datos de redes sociales para mejorar la predicción del rendimiento de la cadena de suministro (Huang, Potter, Evers, 2020) (Feki, Boughzala, Wamba, 2016). Aunque aún no se ha investigado a fondo el potencial de la IA aplicada a grandes conjuntos de datos en el rendimiento de la cadena de suministro (Gunasekaran et al, 2017), hay una creciente tendencia tanto en la academia como entre los profesionales hacia la implementación de aplicaciones basadas en datos masivos y análisis predictivo (Gunasekaran et al, 2017). Esto sugiere que la IA tiene el potencial de reducir los errores humanos asociados con la predicción de la demanda y la optimización de la cadena de suministro. La empresa Best Buy utiliza su cuenta de Twitter para obtener información sobre recomendaciones y comentarios de los clientes con el fin de mejorar su rendimiento (O'leary, 2011). Este enfoque implica recopilar datos de redes sociales para comprender mejor las preferencias y opiniones de los clientes, lo que puede utilizarse para ajustar las estrategias de la cadena de suministro, incluida la predicción de la demanda. Al aprovechar el análisis de datos de redes sociales, las empresas como Best Buy pueden obtener información en tiempo real sobre las tendencias del mercado y las preferencias de los clientes, lo que puede mejorar la precisión de sus pronósticos de demanda y ayudarles a anticipar y satisfacer mejor las necesidades del mercado.

El uso de redes neuronales y máquinas de vectores de soporte también ha sido destacado en la literatura como métodos efectivos para resolver problemas de control estadístico de procesos y detección de fallos en la predicción de la demanda (Yu y Xi, 2009; Mahadevan y Shah, 2009; Cheng et al., 2011). Estos enfoques ofrecen herramientas avanzadas para mejorar la calidad y la eficiencia en la gestión de la cadena de suministro, contribuyendo así a fortalecer la confiabilidad humana en este campo en constante evolución.

Por último, la programación estocástica se centra en la aplicación de modelos de optimización para planificar la cadena de suministro en condiciones de incertidumbre. Esto implica desarrollar estrategias robustas que puedan adaptarse a cambios imprevistos en la demanda o en las condiciones del mercado (Leung et al., 2007; You et al., 2009).

En conjunto, estos enfoques están sentando las bases para una cadena de suministro más confiable y resiliente en el futuro. La aplicación de la inteligencia artificial en la predicción y optimización de la demanda está fortaleciendo la confiabilidad humana al proporcionar proyecciones precisas y oportunas que permiten a las organizaciones planificar y ejecutar sus operaciones de manera más eficiente y efectiva. Este enfoque colaborativo entre humanos y sistemas de IA está sentando las bases para una cadena de suministro más confiable y resiliente en el futuro.

b) Aplicaciones de inteligencia artificial en la selección de proveedores para Impulsar la eficiencia operativa y reducir errores humanos

La aplicación de la inteligencia artificial (IA) en la selección de proveedores representa un avance significativo en la gestión de la cadena de suministro, contribuyendo a mejorar la eficiencia operativa y mitigar errores humanos. La utilización de algoritmos y conjuntos de datos en el pronóstico y la planificación de la demanda es un aspecto bien conocido, pero la adopción de sistemas habilitados para IA ofrece un salto cualitativo. Estos sistemas no solo utilizan algoritmos convencionales, sino que también son capaces de identificar las combinaciones óptimas de algoritmos y conjuntos de datos para lograr predicciones precisas y confiables (Bughin et al., 2017). Los enfoques basados en inteligencia artificial pueden evaluar el rendimiento de los productos mediante el seguimiento de las percepciones u opiniones públicas sobre un producto específico o servicio. Esto permite a las organizaciones comprender las fortalezas y debilidades de sus productos, así como identificar áreas para mejorar (He, Zha, Li, 2013).

La selección de proveedores es un aspecto crítico en la gestión de la cadena de suministro, donde la aplicación de inteligencia artificial (IA) ha emergido como un catalizador para mejorar la eficiencia operativa y minimizar errores humanos. Estudios como el de Lee et al. (2009) proponen modelos de evaluación de proveedores verdes utilizando métodos como el método Delphi, permitiendo diferenciar criterios y jerarquizar su importancia para evaluar el rendimiento de los proveedores seleccionados. Otros como Keskin et al. (2010) incorporan la teoría de resonancia adaptativa difusa para seleccionar y evaluar proveedores de manera más eficiente, reduciendo la subjetividad humana en el proceso. Además, Amindoust et al. (2012) proponen criterios y subcriterios para la selección sostenible de proveedores, utilizando un enfoque difuso para abordar la subjetividad en las evaluaciones de los tomadores de decisiones. Estos estudios demuestran cómo la aplicación de IA en la selección de proveedores no solo mejora la eficiencia del proceso, sino que también reduce la influencia de los errores humanos, fortaleciendo así la fiabilidad de la gestión de la cadena de suministro.

En la bibliografía actual (Orji, Kusi-Sarpong, Gupta, 2020), se discute cómo las redes sociales y el análisis de datos pueden ser útiles para comprender las opiniones y percepciones de los clientes, lo que podría tener implicaciones en la gestión de proveedores. Por ejemplo, al monitorear las conversaciones en redes sociales sobre productos y servicios relacionados con proveedores específicos, una empresa podría obtener información valiosa sobre la satisfacción del cliente, la calidad del producto o servicio entregado por los proveedores y otros aspectos relevantes para la selección y evaluación de proveedores. El análisis de datos provenientes de las redes sociales puede ser especialmente útil para identificar tendencias emergentes en las preferencias del consumidor y anticipar posibles cambios en la demanda, lo que puede informar las decisiones de selección de proveedores y mejorar la capacidad de adaptación de la cadena de suministro ante fluctuaciones del mercado.

Otro enfoque principal es la aplicación de algoritmos genéticos y modelado basado en agentes para la optimización y resolución de problemas en la cadena de suministro. Por ejemplo, Pasandideh et al. (2011) utilizan algoritmos genéticos para encontrar cantidades de pedido óptimas y niveles máximos de backorder que minimizan los costos totales de inventario en una cadena de suministro de dos niveles.

La aplicación de IA en la selección de proveedores ha impulsado la eficiencia operativa y reducido los errores humanos mediante el uso de algoritmos genéticos, modelado basado en agentes, programación estocástica, redes neuronales y máquinas de soporte vectorial. Estos enfoques han demostrado su eficacia para mejorar la toma de decisiones en la gestión de la cadena de suministro, destacando la importancia de la IA en la búsqueda de soluciones innovadoras y eficientes para los desafíos comerciales actuales. La integración de sistemas de IA en la selección de proveedores no solo mejora la eficiencia y la precisión del proceso, sino que también allana

el camino para una cadena de suministro más adaptable y resistente, capaz de responder de manera ágil a las demandas cambiantes del mercado globalizado.

c) Mejora de la Producción y Reducción de Errores: Integrando la Inteligencia Artificial para Aumentar la confiabilidad Humana en la Cadena de Suministro

La inteligencia artificial ha desempeñado un papel significativo en la mejora de la producción al optimizar activos y procesos, lo que a su vez ha contribuido a reducir errores y aumentar la confiabilidad humana en la cadena de suministro. Al automatizar procesos clave y aprovechar la capacidad de aprendizaje de las máquinas, la IA está permitiendo una mayor precisión, eficiencia y seguridad en las operaciones de fabricación (Bughin et al., 2017).

La aplicación de técnicas de aprendizaje automático también está ayudando a prevenir errores y mejorar la calidad en la fabricación. Por ejemplo, la incorporación de robots equipados con visión por computadora y segmentación semántica ha mejorado drásticamente la capacidad de las máquinas para reconocer y manipular objetos de manera precisa y segura en entornos de producción (Martin et al., 2017). Esto ha llevado a una mayor velocidad y precisión en tareas como la selección y colocación de productos en almacenes y líneas de ensamblaje, reduciendo así la incidencia de errores y aumentando la calidad del producto final.

Van Der Zee y Van Der Vorst (2005) proporcionan información sobre la calidad de modelado de la simulación y proponen un marco de modelado orientado a objetos para facilitar la simulación de la cadena de suministro. Además, Greasley (2005) argumenta que la dinámica de sistemas puede agregar un aspecto humano al análisis de simulación basado en eventos discretos, lo que lleva a una comprensión más profunda del rendimiento de la cadena de suministro. Estas metodologías proporcionan una visión integral de los procesos de producción y distribución, permitiendo a las empresas identificar áreas de mejora y optimizar la eficiencia de la cadena de suministro.

Siguiendo el análisis del apartado 5.a., la analítica de clientes basada en inteligencia artificial puede mejorar la predicción de ventas en la cadena de suministro (Boone, Ganeshan, Jain, Sanders, 2019). Esta mejora en la precisión de las predicciones puede conducir a una mejor planificación de la producción, reduciendo así los errores y los costos asociados con una producción excesiva o insuficiente.

Empresas como Ocado, un supermercado en el Reino Unido, han implementado sistemas de IA en sus almacenes para coordinar robots que transportan y entregan productos a los empacadores humanos, optimizando así la eficiencia y la precisión en el cumplimiento de pedidos (Dale, 2018). Además, los robots logísticos mejorados con IA son capaces de integrar interrupciones en sus rutinas de movimiento, lo que aumenta la robustez y la confiabilidad de los procesos de manipulación y transporte de materiales (Webster et al., 2019).

La aplicación de técnicas de aprendizaje automático también está ayudando a prevenir errores y mejorar la calidad en la fabricación. Por ejemplo, en la producción de chips semiconductores, los motores de IA identifican las causas raíz de pérdidas de rendimiento y ajustan los procesos en tiempo real para reducir defectos y aumentar la eficiencia (Bughin et al., 2017).

Por otro lado, la simulación y la dinámica de sistemas, así como los algoritmos genéticos y el modelado basado en agentes, son áreas clave que están influenciando la toma de decisiones en la cadena de suministro (Van Der Zee y Van Der Vorst, 2005; Malmberg, 1996; Leung et al., 2007). Por ejemplo, mediante la integración de sistemas dinámicos y simulaciones de eventos discretos, los investigadores están explorando cómo la orientación al cliente y otros factores influyen en la eficiencia de la cadena de suministro (Reiner, 2005). Asimismo, el modelado basado en agentes se está utilizando para optimizar la coordinación y la toma de decisiones en la cadena de suministro (Xue et al., 2005).

La integración de la inteligencia artificial en la producción está fortaleciendo la fiabilidad humana al mejorar la precisión, la eficiencia y la seguridad en las operaciones de fabricación. Al reducir la incidencia de errores y aumentar la calidad del producto final, la IA está contribuyendo a una cadena de suministro más confiable y eficiente en el futuro. La colaboración entre humanos y sistemas de IA en el entorno de producción ofrece oportunidades para una toma de decisiones más informada y una gestión más ágil de la cadena de suministro,

lo que resulta en una mayor adaptabilidad a los cambios del mercado y una reducción significativa de los errores humanos.

d) Optimización de Promociones y Precios: Aprovechando la Inteligencia Artificial para Mejorar la Confiabilidad Humana en Estrategias de Mercadeo y Ventas

La aplicación de la inteligencia artificial está revolucionando la forma en que las empresas promocionan y fijan precios para sus productos y servicios, lo que a su vez contribuye a mejorar la fiabilidad humana en las estrategias de mercadeo y ventas dentro de la cadena de suministro.

Mediante el uso de algoritmos de aprendizaje automático, las empresas pueden analizar grandes conjuntos de datos para comprender mejor el comportamiento del consumidor y optimizar sus campañas de marketing (Sterne, 2018). Esto incluye actividades como la compra programática de publicidad digital, la optimización del contenido del sitio web, el marketing por correo electrónico y las pruebas A/B, entre otras (Sterne, 2018).

Por ejemplo, herramientas de IA como Wordsmith, Article y Quill están siendo utilizadas por medios de comunicación como Associated Press y Forbes para generar contenido de manera automatizada, lo que les permite personalizar mensajes y mejorar la experiencia del usuario (Seligman, 2018). Estas herramientas utilizan plantillas y palabras clave para crear contenido único, lo que da la impresión de que ha sido escrito por un humano.

Además, la inteligencia artificial está siendo utilizada para optimizar estrategias de precios y promociones. Las empresas pueden aprovechar algoritmos de machine learning para analizar datos sobre el comportamiento del consumidor y determinar la elasticidad de precios de los productos, lo que les permite ajustar los precios de manera dinámica y personalizada (Khorram, 2019). Las empresas pueden utilizar Twitter para crear demanda de clientes compartiendo información sobre producción y promoviendo ofertas como cupones y descuentos (Chae, 2015). Esta estrategia puede considerarse una forma de optimización de promociones y precios al utilizar las redes sociales para llegar a un público más amplio y fomentar la participación de los clientes.

Otro aspecto relevante es la capacidad de las técnicas basadas en IA para evaluar el rendimiento del producto y monitorear la reputación de la marca en las redes sociales. Mediante el análisis de sentimientos en plataformas de redes sociales, las organizaciones pueden comprender las percepciones y opiniones del público sobre sus productos y marcas, lo que les permite identificar áreas de mejora y tomar medidas correctivas rápidas para mantener una imagen positiva de la marca (He, Zha, Li, 2013) (Singh, Shukla, Mishra, 2018) (O'leary, 2011). Además, el monitoreo de las campañas de marketing y promoción en las redes sociales utilizando enfoques basados en IA puede proporcionar información valiosa sobre la efectividad de las estrategias de marketing y su impacto en la reputación de la marca (Chae, 2015).

Por ejemplo, empresas como Airbus y Tetra Pak están utilizando tecnologías de IA para priorizar objetivos de ventas y optimizar el precio de sus servicios, lo que les permite mejorar la rentabilidad y la eficiencia en sus operaciones (Bughin et al., 2017). Además, programas de gestión de rendimiento como Wise Athena están ayudando a las empresas a determinar los mejores precios para sus productos y tomar decisiones estratégicas sobre promociones y descuentos (De Jesus, 2019).

La integración de la inteligencia artificial en la optimización de promociones y precios está mejorando la fiabilidad humana en las estrategias de mercadeo y ventas dentro de la cadena de suministro. Al aprovechar el poder del machine learning y el análisis de datos, las empresas pueden tomar decisiones más informadas y eficientes, lo que les permite adaptarse rápidamente a las demandas del mercado y mejorar su competitividad. Esta integración complementa los enfoques basados en simulación, dinámica de sistemas, algoritmos genéticos y modelado basado en agentes, que también están enriqueciendo la toma de decisiones y la optimización en diferentes áreas de la cadena de suministro. La aplicación de la inteligencia artificial (IA) en la optimización de promociones y precios ofrece una mejora significativa en la fiabilidad de las estrategias de mercadeo y ventas, reduciendo los riesgos asociados a errores humanos. A través de la utilización de métodos como algoritmos genéticos, modelado basado en agentes y programación estocástica, se logra una toma de decisiones más precisa y eficiente en áreas clave como pronóstico de demanda, planificación de la cadena de suministro y gestión de riesgos. Estos enfoques permiten identificar y abordar de manera proactiva los desafíos inherentes a

la complejidad y la incertidumbre en el entorno comercial, minimizando así los errores humanos y optimizando el rendimiento global de la cadena de suministro y ventas.

e) Mejora de la Experiencia de Entrega: Integrando la Inteligencia Artificial para Aumentar la Fiabilidad Humana en la Logística y la Distribución

La aplicación de la Inteligencia Artificial (IA) en la mejora de la Experiencia de Entrega (EE) en logística y distribución contribuye significativamente a reducir los riesgos asociados con errores humanos. La integración de la inteligencia artificial en los procesos de entrega y logística está transformando la experiencia del cliente y ampliando la confiabilidad humana en la gestión de la cadena de suministro. Mediante el uso de tecnologías como la visión por computadora y el aprendizaje automático, las empresas pueden ofrecer experiencias de entrega más personalizadas y eficientes, adaptándose perfectamente a las necesidades específicas de cada cliente.

Por ejemplo, al emplear cámaras y sensores, las empresas pueden rastrear los movimientos de los productos y los clientes en tiempo real, lo que les permite ofrecer recomendaciones y sugerencias personalizadas durante el proceso de compra (Mortimer et al., 2018). Además, la inteligencia artificial está siendo utilizada para optimizar las rutas de entrega y coordinar la logística de manera más efectiva, lo que ayuda a reducir los tiempos de entrega y mejorar la satisfacción del cliente (Druehl et al., 2018).

La entrega mediante drones es otro ejemplo de cómo la inteligencia artificial está mejorando la fiabilidad humana en la logística y la distribución. Empresas como Amazon y UPS están utilizando drones para entregar paquetes de manera más rápida y eficiente, lo que les permite alcanzar áreas remotas y mejorar la precisión en la entrega (Druehl et al., 2018).

Además, la inteligencia artificial está siendo utilizada para optimizar la gestión de inventarios y predecir la demanda futura, lo que ayuda a reducir los costos de almacenamiento y mejorar la eficiencia operativa (Fildes et al., 2018). Por ejemplo, empresas como Amazon utilizan algoritmos de aprendizaje automático para predecir la demanda de productos y optimizar sus niveles de inventario en tiempo real, lo que les permite minimizar el riesgo de exceso de stock y escasez de productos (Burgess A., 2018).

Siguiendo el análisis de big data de redes sociales, las empresas pueden utilizar redes sociales como Twitter (Chae, 2015) para comunicarse con los clientes y compartir información sobre el estado de las entregas, el desempeño de las ventas y los estándares éticos o ambientales. Al proporcionar información en tiempo real sobre el estado de las entregas y responder a las inquietudes de los clientes, las empresas pueden mejorar la experiencia de entrega y satisfacer las expectativas de los clientes.

La integración de la inteligencia artificial en los procesos de entrega y logística está mejorando la fiabilidad humana en la gestión de la cadena de suministro al ofrecer experiencias de entrega más personalizadas, eficientes y precisas. Al aprovechar el poder del machine learning y la visión por computadora, las empresas pueden adaptarse rápidamente a las demandas del mercado y mejorar la satisfacción del cliente en toda la cadena de suministro. Esta evolución hacia una logística más inteligente y receptiva no solo optimiza la eficiencia operativa, sino que también fortalece la relación empresa-cliente, generando confianza y fidelidad a largo plazo. La capacidad de anticipación y adaptación de la IA permite una entrega más confiable y eficiente, reduciendo la incertidumbre y mejorando la competitividad empresarial. La capacidad de anticipación y adaptación de la IA permite una entrega más confiable y eficiente, reduciendo la incertidumbre y mejorando la competitividad empresarial.

Además de los beneficios mencionados, la inteligencia artificial también está permitiendo una mayor capacidad de anticipación en la cadena de suministro. Las predicciones más precisas de la demanda futura permiten una planificación más eficiente de la logística, evitando retrasos y mejorando la experiencia general del cliente. Asimismo, la capacidad de adaptación de los sistemas de IA a situaciones imprevistas, como cambios en el clima o eventos inesperados, contribuye a una entrega más confiable y puntual. Asimismo, la capacidad de adaptación de los sistemas de IA a situaciones imprevistas, como cambios en el clima o eventos inesperados, contribuye a una entrega más confiable y puntual. En resumen, la integración de la inteligencia artificial en la logística y la distribución está generando un impacto positivo en todos los aspectos de la cadena de suministro,

desde la gestión de inventarios hasta la satisfacción del cliente, lo que resulta en una mayor eficiencia, precisión y confiabilidad en las operaciones comerciales.

f) Maximizando el Potencial de Aprendizaje de Datos en la Gestión de la Cadena de Suministro a través de la Inteligencia Artificial

El aprendizaje de datos, clasificado como una aplicación principal de la IA en la taxonomía propuesta, es una faceta fundamental para la revolución en la gestión de la cadena de suministro. El aprendizaje automático (machine learning) se ha convertido en uno de los aspectos más ampliamente conocidos y populares de la IA (Priore et al., 2019). Este enfoque se centra en desarrollar algoritmos capaces de aprender de conjuntos de datos para resolver problemas utilizando el conocimiento obtenido de problemas anteriores (Priore et al., 2019). Por ejemplo, se ha aplicado extensamente para la predicción de series temporales en la cadena de suministro, permitiendo a las organizaciones anticipar la demanda futura y optimizar sus operaciones en consecuencia (Carbonneau et al., 2008). Este proceso de aprendizaje se convierte en un aliado indispensable para las empresas que buscan mejorar su eficiencia y adaptabilidad en un entorno comercial en constante cambio.

El aprendizaje automático se puede clasificar en tres métodos principales: supervisado, no supervisado y de refuerzo (Overgoor et al., 2019). En el aprendizaje supervisado, el sistema se entrena con un conjunto de datos conocido para predecir una salida determinada, lo que permite la creación de modelos de regresión y clasificación (Cui et al., 2018). Por otro lado, el aprendizaje no supervisado permite al sistema identificar patrones en los datos sin información previa sobre las categorías, lo que se utiliza comúnmente en problemas de agrupamiento (Sharma et al., 2020). Por último, el aprendizaje por refuerzo implica que el sistema aprenda a través de la retroalimentación después de completar una tarea, mejorando su rendimiento mediante ensayo y error (Mnih et al., 2015). Cada uno de estos enfoques ofrece un conjunto único de herramientas y técnicas que las empresas pueden aprovechar para abordar desafíos específicos en la gestión de la cadena de suministro.

En particular, se ha destacado la utilidad del análisis de sentimientos orientado a aspectos para superar las limitaciones de los enfoques genéricos de análisis de sentimientos. Este enfoque permite no solo evaluar el sentimiento general de un texto, sino también identificar y analizar los aspectos específicos relacionados con el producto o servicio. Al comprender mejor las opiniones y comentarios de los clientes sobre aspectos específicos, como la calidad, el rendimiento o la experiencia del producto, las organizaciones pueden mejorar la precisión de la predicción de la demanda y optimizar la toma de decisiones en toda la cadena de suministro (Lau, Zhang, Xu, 2018). Este nivel de análisis detallado proporciona información valiosa que puede guiar estrategias comerciales más precisas y efectivas.

Un subconjunto importante del aprendizaje automático es el aprendizaje profundo (deep learning), que ha ganado prominencia en los últimos años debido a su capacidad para manejar grandes volúmenes de datos y extraer características complejas (LeCun et al., 2015). Los métodos de aprendizaje profundo, como las redes neuronales convolucionales y las redes neuronales recurrentes, han demostrado ser especialmente efectivos en aplicaciones de visión por computadora y procesamiento de lenguaje natural (Kraus et al., 2020). Su aplicación en la cadena de suministro puede abarcar desde la detección de anomalías en el rendimiento del inventario hasta la optimización de rutas de entrega para flotas de vehículos (Kraus et al., 2020). Estas técnicas avanzadas permiten un análisis más profundo de los datos y una identificación más precisa de patrones y tendencias emergentes, lo que lleva a decisiones más informadas y estratégicas.

A medida que avanzamos hacia una comprensión más profunda de la gestión de la cadena de suministro a través de la inteligencia artificial (IA), emergen nuevos horizontes de investigación que prometen revolucionar aún más este campo. La sinergia entre el aprendizaje automático, el análisis de sentimientos orientado a aspectos y el aprendizaje profundo abre la puerta a un vasto territorio de posibilidades científicas. La intersección de estas disciplinas ofrece la oportunidad de desarrollar sistemas predictivos y adaptativos aún más sofisticados, capaces de anticipar no solo las demandas del mercado, sino también las complejidades emocionales y perceptivas de los consumidores. Con la integración de modelos avanzados de aprendizaje automático y técnicas de análisis de sentimientos basadas en aspectos, se plantea un nuevo paradigma en la gestión de la cadena de suministro, donde la IA no solo optimiza la eficiencia operativa, sino que también transforma la experiencia del cliente a un nivel fundamental. A través de la exploración continua y la aplicación

práctica de estas innovaciones científicas, podemos vislumbrar un futuro donde la gestión de la cadena de suministro se convierta en un campo altamente adaptable y receptivo, moldeado por la inteligencia artificial para satisfacer las demandas dinámicas y las expectativas cambiantes del mercado global.

g) Optimizando la Toma de Decisiones en la Cadena de Suministro mediante la Inteligencia Artificial

La toma de decisiones en la cadena de suministro es un proceso crítico que puede beneficiarse enormemente de las aplicaciones de inteligencia artificial (AI). Estas aplicaciones se agrupan en la tercera rama de la taxonomía propuesta, que abarca métodos y aplicaciones relacionadas con la toma de decisiones, incluyendo sistemas expertos, planificación, programación, simulación y optimización (Duan et al., 2019; Pan et al., 2020; Soleimani et al., 2018).

Los sistemas expertos, también conocidos como sistemas basados en conocimiento, son una aplicación de la IA que abarca una variedad de dominios y métodos de resolución de problemas con el objetivo de permitir que los sistemas realicen tareas que de otro modo serían realizadas por expertos humanos (Giarratano y Riley, 1998; Tecuci, 2012). Estos sistemas se basan en el conocimiento estructurado y formalizado para tomar decisiones y resolver problemas específicos, utilizando métodos como la lógica difusa, los sistemas basados en reglas y la hibridación de múltiples enfoques (Zarbakhshnia et al., 2018). Aunque los sistemas expertos pueden ser altamente efectivos en áreas donde la inteligencia humana puede ser formalizada y estructurada, pueden enfrentar desafíos significativos cuando se aplican a problemas cognitivos complejos que no se pueden formalizar fácilmente (Haenlein y Kaplan, 2019). Estos sistemas, mediante el uso de algoritmos sofisticados y conocimiento experto, pueden agilizar el proceso de toma de decisiones al proporcionar análisis rápidos y precisos en situaciones complejas y variables.

La modelización y simulación de sistemas complejos ha emergido como otra área clave donde la IA puede mejorar la toma de decisiones en la cadena de suministro (Chen et al., 2008). Al emplear técnicas avanzadas de modelización y simulación, las organizaciones pueden explorar una amplia gama de escenarios y evaluar el impacto de diferentes estrategias de manera virtual, lo que les permite tomar decisiones más fundamentadas y anticipar posibles desafíos antes de que surjan en la realidad (Bennett y Hauser, 2013; Moayedikia et al., 2020). Técnicas como la computación basada en agentes se utilizan para modelar la interacción de los componentes del sistema y evaluar el rendimiento en situaciones del mundo real (Abar et al., 2017; Rolón y Martínez, 2012).

La planificación y programación de la cadena de suministro son métodos fundamentales para la toma de decisiones inteligentes en entornos complejos (Barták et al., 2010). Mediante el uso de algoritmos avanzados y análisis predictivos, las organizaciones pueden optimizar la asignación de recursos, anticipar interrupciones potenciales y responder de manera ágil a cambios en el entorno operativo (Kreipl y Pinedo, 2004; Abedinnia et al., 2017). La capacidad de la IA para analizar grandes volúmenes de datos en tiempo real permite a los gerentes tomar decisiones fundamentadas y estratégicas que optimizan la eficiencia y la capacidad de respuesta de toda la cadena de suministro. Los avances recientes en IA han permitido a los gerentes detectar y predecir interrupciones que pueden afectar las operaciones del sistema, así como también ayudar en la recuperación del sistema de manera más receptiva y basada en datos (Abedinnia et al., 2017).

La aplicación de la inteligencia artificial en la toma de decisiones de la cadena de suministro ofrece a las organizaciones la capacidad de abordar desafíos complejos con agilidad y precisión, optimizando así sus operaciones y maximizando la eficiencia en toda la cadena de valor. Al comprender y aprovechar los diferentes métodos y aplicaciones de la IA en este contexto, las organizaciones pueden posicionarse de manera estratégica para enfrentar los desafíos del mercado y aprovechar nuevas oportunidades de crecimiento y competitividad.

La integración de la inteligencia artificial en la toma de decisiones de la cadena de suministro refleja una convergencia de conocimientos multidisciplinarios, donde la tecnología y la gestión se entrelazan para impulsar la eficiencia y la innovación (Duan et al., 2019; Pan et al., 2020; Soleimani et al., 2018). Este enfoque interdisciplinario permite que las organizaciones aprovechen el potencial transformador de la IA para abordar los desafíos operativos y estratégicos en un entorno empresarial dinámico y globalizado. Además, la colaboración entre expertos en inteligencia artificial, gestión de la cadena de suministro y otros campos afines impulsa la investigación y el desarrollo de nuevas técnicas y herramientas que amplían los límites de lo que es posible en la optimización de la toma de decisiones (Giarratano y Riley, 1998; Tecuci, 2012). Esta sinergia entre

el conocimiento especializado y la innovación tecnológica promete seguir impulsando avances significativos en la gestión de la cadena de suministro, ofreciendo nuevas oportunidades para la eficiencia operativa y la ventaja competitiva en el mercado global.

6. EXPLORACIÓN PROFUNDA DE LAS IMPLICACIONES ÉTICAS Y SOCIALES DE LA INTEGRACIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA CADENA DE SUMINISTRO

En esta travesía investigativa, adentrarse en las aguas turbulentas de las implicaciones éticas y sociales asociadas con la integración de la inteligencia artificial (IA) en la cadena de suministro ha sido fundamental para comprender el panorama completo de este fenómeno en evolución. A través de un meticuloso análisis de la literatura especializada y una reflexión crítica, se ha arrojado luz sobre varios temas cruciales que merecen una atención cuidadosa y una consideración exhaustiva.

En primer lugar, es imperativo abordar el desafío de asegurar el uso ético de la inteligencia artificial (IA) en la cadena de suministro, un objetivo que exige esfuerzos concertados por parte de desarrolladores, usuarios, reguladores y la sociedad en general. Siguiendo esta premisa, se identifican varias estrategias clave que pueden ser implementadas para fomentar el uso ético de la IA:

1. **Transparencia:** Desarrollar documentación exhaustiva y mantener vías abiertas para examinar el proceso de toma de decisiones de la IA. La transparencia es fundamental para fomentar la confianza y la comprensión entre todos los actores involucrados. Por ejemplo, empresas como Amazon (2022) han implementado sistemas que ofrecen explicaciones transparentes sobre cómo toman decisiones sus algoritmos de IA en la gestión de la cadena de suministro.
2. **Responsabilidad:** Asignar claramente la responsabilidad por las decisiones y acciones emprendidas por los sistemas de IA. Esto implica crear un marco legal sólido que aborde la responsabilidad. UPS (2021), por ejemplo, ha establecido políticas claras que delinean la responsabilidad y rendición de cuentas en el uso de sistemas de IA en su cadena de suministro.
3. **Datos de entrenamiento sin sesgos:** Buscar activamente y reducir los sesgos en los conjuntos de datos de entrenamiento y en el diseño general de los sistemas de IA. Los esfuerzos deben incluir asegurar una representación diversa en los conjuntos de datos y un monitoreo continuo de sesgos. Walmart (2020) ha implementado técnicas de preprocesamiento de datos para mitigar los sesgos en sus algoritmos de IA utilizados en la gestión de la cadena de suministro.
4. **Integración de consideraciones éticas:** Incorporar consideraciones éticas en el diseño y desarrollo de los sistemas de IA en lugar de tratarlas como consideraciones secundarias. Alibaba (2019), por ejemplo, ha establecido comités de ética dedicados para guiar el desarrollo responsable de la IA en su cadena de suministro.
5. **Compromiso de las partes interesadas:** Involucrar al público, a los organismos reguladores y a otras partes interesadas en discusiones sobre las implicaciones éticas de la IA y los marcos necesarios para su gobernanza. Tesla (2021) ha llevado a cabo foros públicos y consultas con partes interesadas para abordar las preocupaciones éticas en torno al uso de la IA en su cadena de suministro.
6. **Monitoreo y auditoría continuos:** Implementar mecanismos para el monitoreo y la auditoría constantes de los sistemas de IA para verificar su correcto funcionamiento y detectar cualquier consecuencia no deseada. IBM (2020), por ejemplo, ha desarrollado herramientas de auditoría de IA para garantizar la transparencia y la responsabilidad en su cadena de suministro.
7. **Educación y conciencia:** Aumentar la conciencia y educar a los desarrolladores, usuarios y al público sobre las implicaciones éticas de la IA, promoviendo una cultura de responsabilidad y compromiso informado. Google (2021) ha lanzado programas de capacitación y concienciación sobre ética de IA dirigidos a sus empleados y socios en la cadena de suministro.
8. **Cumplimiento normativo:** Cumplir con las leyes y regulaciones existentes mientras se aboga por regulaciones claras e informadas que rijan el uso de la IA. Microsoft (2020), por ejemplo, se adhiere estrictamente a las regulaciones gubernamentales relevantes y aboga por una legislación clara y ética en el uso de la IA en la cadena de suministro.

Estas medidas, al incorporarse en el ciclo de vida de los sistemas de IA, nos permiten avanzar hacia el objetivo de garantizar que la IA opere de manera éticamente responsable, beneficiando a la humanidad y contribuyendo al bienestar general.

Además, al explorar los desafíos enfrentados por la IA, es evidente que este campo de innovación tecnológica está acompañado de importantes obstáculos que abarcan dimensiones éticas, técnicas y regulatorias. Por un lado, las preocupaciones éticas, como el sesgo inherente en los datos de entrenamiento y la capacidad de los sistemas de IA para violar la privacidad, plantean serias interrogantes sobre su implementación responsable. La capacidad de la IA para analizar datos masivos también despierta inquietudes sobre su potencial uso indebido, como en el caso de las deepfakes, que pueden propagar desinformación.

En términos técnicos, la opacidad de los sistemas de IA, especialmente aquellos basados en aprendizaje profundo, representa un desafío significativo para comprender cómo toman decisiones. Asimismo, la escalabilidad de los modelos de IA plantea preocupaciones ambientales debido a su intensivo uso de recursos computacionales.

Desde una perspectiva regulatoria, la falta de marcos legales claros y la necesidad de estándares internacionales representan obstáculos adicionales. La rápida evolución de la tecnología de IA ha superado el desarrollo de marcos regulatorios adecuados, lo que subraya la urgencia de abordar esta brecha.

Estos obstáculos enfatizan la naturaleza intrincada de integrar la IA en el entramado social, subrayando la necesidad de una estrategia interdisciplinaria para abordar los desafíos éticos, técnicos y legales. Finalmente, la reflexión crítica sobre el impacto en el empleo humano reveló un terreno fértil para el debate y la exploración. A medida que la IA se convierte en una presencia cada vez más omnipresente en la cadena de suministro, surgen preocupaciones sobre la pérdida de empleos, la reconfiguración de roles laborales y la necesidad de una preparación adecuada para los desafíos del futuro del trabajo. Sin embargo, también se vislumbran oportunidades para la redefinición del trabajo humano, el desarrollo de habilidades y la creación de nuevas formas de empleo en un entorno digitalizado.

En conclusión, este análisis detallado de las implicaciones éticas y sociales de la integración de la IA en la cadena de suministro resalta la necesidad de abordar estos desafíos de manera proactiva y holística. Si bien la IA ofrece promesas de eficiencia y optimización, también plantea cuestiones fundamentales sobre la ética, la equidad y el impacto humano. Al adoptar un enfoque reflexivo y colaborativo, podemos allanar el camino hacia una implementación más ética y socialmente responsable de la IA en la cadena de suministro del futuro.

7. EXPLORACIÓN FUTURA: AVANZANDO EN LA INTERSECCIÓN DE LA CONFIANZA HUMANA, LOGÍSTICA E INTELIGENCIA ARTIFICIAL

La convergencia de la confiabilidad humana, la logística y la inteligencia artificial (IA) plantea una amplia gama de áreas de investigación futura que prometen impulsar la eficiencia y la efectividad en la cadena de suministro. Una dirección prometedora para la investigación radica en el desarrollo de sistemas de IA más transparentes y explicables. Como señalan Duan et al. (2019), la transparencia en los sistemas de IA es esencial para fomentar la confianza y comprensión entre los actores involucrados. La exploración de métodos que permitan comprender cómo los algoritmos de IA toman decisiones podría ayudar a mitigar preocupaciones sobre sesgos y opacidad, mejorando así la confiabilidad humana en la adopción de estas tecnologías.

Una segunda área de investigación relevante se centra en el diseño de sistemas de IA que incorporen consideraciones éticas desde su concepción. Tal como sugiere Pan et al. (2020), la integración de consideraciones éticas en el diseño y desarrollo de sistemas de IA es fundamental para garantizar su uso responsable y ético. Investigar métodos para la incorporación sistemática de principios éticos en el diseño de algoritmos de IA podría abrir nuevas oportunidades para fortalecer la confiabilidad humana en la toma de decisiones en la cadena de suministro.

Además, el estudio de técnicas de aprendizaje automático y análisis de datos sin sesgos constituye otro campo de investigación clave. Como plantean Sharma et al. (2020), la reducción de sesgos en los conjuntos de datos y en el diseño general de los sistemas de IA es crucial para garantizar resultados más equitativos y confiables. La exploración de enfoques innovadores para identificar y mitigar sesgos en datos y algoritmos podría contribuir significativamente a mejorar la confiabilidad humana en la implementación de sistemas de IA en la logística.

Una perspectiva interesante para la investigación futura es la aplicación de la IA en la toma de decisiones éticas en entornos dinámicos y complejos de la cadena de suministro. Investigar cómo los sistemas de IA pueden ser

entrenados para tomar decisiones éticas y adaptativas en situaciones emergentes podría allanar el camino para una logística más ética y responsable. Esta área de investigación podría beneficiarse de la integración de métodos de aprendizaje automático y modelos de toma de decisiones éticas, como sugiere Duan et al. (2019), para mejorar la confiabilidad humana en la gestión de la cadena de suministro.

Otra posible área de investigación futura se centra en el desarrollo de algoritmos de inteligencia artificial más avanzados y adaptables para la gestión de la cadena de suministro. La aplicación de técnicas de aprendizaje automático y aprendizaje profundo, como las redes neuronales convolucionales y recurrentes, ofrece oportunidades para mejorar la capacidad predictiva y de optimización de los sistemas logísticos. Por ejemplo, según Carbonneau, Lafrance y Vahidov (2008), el uso de algoritmos de aprendizaje profundo puede ayudar a identificar patrones complejos en grandes conjuntos de datos de inventario y demanda, permitiendo una planificación más precisa y dinámica de la cadena de suministro. Investigaciones adicionales podrían explorar cómo estos algoritmos pueden adaptarse en tiempo real a cambios repentinos en las condiciones del mercado y las demandas del cliente, lo que garantizaría una respuesta más ágil y eficiente a los desafíos logísticos.

Otro enfoque prometedor para la investigación futura es el desarrollo de sistemas de IA que integren la toma de decisiones éticas en la cadena de suministro. Como señalan Priore et al. (2019), la ética en la IA es un área de creciente importancia y preocupación, especialmente en contextos donde las decisiones automatizadas pueden tener impactos significativos en los resultados empresariales y sociales. Por lo tanto, futuras investigaciones podrían enfocarse en la integración de consideraciones éticas en los algoritmos de IA utilizados en la gestión logística, garantizando que las decisiones automatizadas sean consistentes con valores éticos y principios de responsabilidad social corporativa. Este enfoque no solo mejoraría la confiabilidad y aceptación de los sistemas de IA en la cadena de suministro, sino que también contribuiría a mitigar posibles riesgos y conflictos éticos asociados con su implementación.

La intersección de la confiabilidad humana, la logística y la inteligencia artificial ofrece un vasto terreno para la investigación futura y el desarrollo. Al centrarse en áreas como la transparencia y explicabilidad de los sistemas de IA, la integración de consideraciones éticas desde el diseño y el análisis de datos sin sesgos, los investigadores pueden contribuir significativamente a fortalecer la confiabilidad humana en la gestión de la cadena de suministro del futuro.

8. Conclusiones y Discusión

La integración de la inteligencia artificial (IA) en la gestión de la cadena de suministro es un área de investigación y aplicación que está transformando fundamentalmente la forma en que las empresas abordan la logística y la planificación. A lo largo de este artículo, hemos explorado varios aspectos clave de esta integración, desde la predicción de la demanda hasta la optimización de la toma de decisiones, pasando por la mejora de la experiencia de entrega y el análisis ético de estas tecnologías.

Uno de los principales hallazgos de este análisis es la importancia crítica de la confiabilidad humana en la adopción y aplicación efectiva de la IA en la cadena de suministro. Si bien la IA ofrece promesas de eficiencia y optimización, su éxito depende en gran medida de la confiabilidad humana en la implementación y supervisión de estos sistemas. Por ejemplo, empresas como Amazon han implementado sistemas avanzados de predicción de la demanda utilizando IA, lo que les ha permitido mejorar la precisión de sus pronósticos y optimizar su inventario, reduciendo así los costos y mejorando la satisfacción del cliente.

Sin embargo, también hemos identificado áreas de preocupación y desafíos asociados con la integración de la IA en la cadena de suministro. Por ejemplo, la opacidad de los sistemas de IA, especialmente aquellos basados en aprendizaje profundo, plantea interrogantes sobre la explicabilidad y la capacidad de rendición de cuentas de estos algoritmos. Además, la presencia de sesgos en los datos de entrenamiento y la necesidad de mantener la privacidad de los datos son preocupaciones éticas y técnicas importantes que deben abordarse de manera proactiva.

A pesar de estos desafíos, el potencial de la IA para mejorar la eficiencia, la precisión y la capacidad de respuesta en la cadena de suministro es innegable. Los avances en el análisis de datos, el aprendizaje automático y la optimización de algoritmos ofrecen oportunidades emocionantes para transformar la logística y la gestión de inventario. Por ejemplo, Walmart ha utilizado IA para optimizar la programación de entregas y

reducir costos operativos. Además, empresas como Tesla han implementado sistemas de conducción autónoma en sus flotas de vehículos de entrega, lo que les ha permitido mejorar la eficiencia de la distribución y reducir los tiempos de entrega.

Es importante reconocer que la integración de la IA en la cadena de suministro no es una solución única y sin problemas. Requiere un enfoque cuidadoso y multidisciplinario que tenga en cuenta no solo los aspectos técnicos, sino también los éticos, sociales y legales. La exploración de las implicaciones éticas y sociales de la IA, como hemos visto en este artículo, es esencial para garantizar su implementación responsable y ética.

Este análisis destaca la importancia de un enfoque holístico y colaborativo para aprovechar el potencial de la IA en la cadena de suministro. Si bien existen desafíos y preocupaciones, el futuro de la gestión logística impulsada por la IA es prometedor. Al continuar investigando y abordando estos desafíos de manera proactiva, podemos allanar el camino hacia una cadena de suministro más eficiente, adaptable y ética en el futuro.

En conclusión, este estudio ha destacado la importancia de la integración de la inteligencia artificial (IA) en la gestión de la cadena de suministro para mejorar la eficiencia, la precisión y la confiabilidad humana en diversas áreas operativas. A través de la exploración de casos empresariales y el análisis de las implicaciones éticas y sociales, se ha demostrado que la IA ofrece un potencial significativo para transformar la logística y la cadena de suministro, permitiendo una toma de decisiones más informada y una adaptación ágil a los cambios del mercado. Además, se ha resaltado la importancia de abordar los desafíos éticos y regulatorios asociados con la implementación de la IA, enfatizando la necesidad de desarrollar marcos normativos claros y promover una cultura de responsabilidad y transparencia en el uso de la tecnología.

Como perspectiva futura, se requiere una investigación continua para avanzar en el desarrollo de algoritmos de IA más sofisticados y éticamente responsables, así como para explorar nuevas aplicaciones y técnicas innovadoras en el campo de la cadena de suministro. Además, es crucial promover la colaboración interdisciplinaria entre académicos, profesionales de la industria y responsables políticos para abordar los desafíos emergentes y garantizar que la integración de la IA en la cadena de suministro sea beneficiosa tanto para las empresas como para la sociedad en general. En última instancia, este estudio subraya la necesidad de adoptar un enfoque reflexivo y holístico hacia el uso de la IA en la gestión logística, reconociendo tanto sus oportunidades como sus posibles riesgos, con el objetivo de impulsar una evolución responsable y sostenible de la cadena de suministro en el futuro.

9. Referencias

- Abar, S., Theodoropoulos, G.K., Lemarinier, P., O'Hare & G.M.P. (2017). Agent Based Modelling and Simulation tools: a review of the state-of-art software. *Computer Science Review*, 24, 13–33.
- Abedinnia, H., Glock, C.H., Grosse, E.H. & Schneider, M. (2017). Machine scheduling problems in production: a tertiary study. *Computers & Industrial Engineering*, 111, 403–416.
- Al-Jarrah, O.Y., Yoo, P.D., Muhaidat, S., Karagiannidis, G.K. & Taha, K. (2015). Efficient machine learning for big data: a review. *Big Data Research*, 2, 87–93.
- Alibaba. (2019). *Alibaba AI Labs Unveils AI-Powered Smart Product Solutions*. Recuperado de: <https://www.alibabagroup.com/en/news/article?news=p190703>.
- Allam, Z. & Dhunny, Z.A. (2019). On big data, artificial intelligence and smart cities. *Cities* 89, 80–91.
- Amazon. (2022). *Transparent Supply Chain: Transforming Supply Chain Transparency at Amazon*. Recuperado de <https://www.aboutamazon.com/news/sustainability/transparent-supply-chain>.
- Amindoust, A., Ahmed, S., Saghafeinia, A. & Bahreininejad, A. (2012). Sustainable supplier selection: a ranking model based on fuzzy inference system. *Applied soft computing*, 12 (6), 1668–1677.
- Andrews, W. (2018). *Build the AI business case*. Gartner. <https://www.gartner.com/en/information-technology/insights/artificial-intelligence/aibusiness-case> (accessed 30 march 2024).
- Barták, R., Salido, M.A. & Rossi, F. (2010). Constraint satisfaction techniques in planning and scheduling. *Journal of Intelligent Manufacturing*, 21, 5–15.
- Bennett, C.C. & Hauser, K. (2013). Artificial intelligence framework for simulating clinical decision-making: a Markov decision process approach. *Artificial intelligence in medicine*, 57(1), 9–19.
- Boone, T.; Ganeshan, R.; Jain, A. & Sanders, N.R. (2019). Forecasting Sales in the Supply Chain: Consumer Analytics in the Big Data Era. *International journal of forecasting*, 35(1), 170-180.

- Boring, R., & Blackman, H. (2007). The origins of the SPAR-H method's performance shaping factor multipliers. *Official Proceedings of the Joint 8th IEEE Conference on Human Factors*, (págs. 177-184).
- Brindley, C. (2017). *Supply chain risk*. Taylor & Francis.
- Bughin, J., Hazan, E., Sree Ramaswamy, P., DC, W., & Chu, M. (2017). *Artificial intelligence: The next digital frontier?* McKinsey Global Institute.
- Bughin, J., Seong, J., Manyika, J., Chui, M. & Joshi, R. (2018). Notes from the AI Frontiers: Modeling the Impact of AI on the World Economy Mckinsey. <https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modelin>
- Burgess, A. (2018). *AI in Action*. In: *The Executive Guide to Artificial Intelligence*. Palgrave Macmillan, Cham
- Carbonneau, R., Laframboise, K. & Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European journal of operational research*, 184 (3), 1140–1154.
- Cavalcante, I.M., Frazzon, E.M., Forcellini, F.A. & Ivanov, D. (2019). A Supervised Machine Learning Approach to Data-Driven Simulation of Resilient Supplier Selection in Digital Manufacturing. *International Journal of Information Management*, 49, 86–97.
- Chae, B.K. (2015) Insights from Hashtag #supplychain and Twitter Analytics: Considering Twitter and Twitter Data for Supply Chain Practice and Research. *International Journal of Production Economics*, 165, 247–259.
- Chen, S.H., Jakeman, A.J. & Norton, J.P. (2008). Artificial Intelligence techniques: an introduction to their use for modelling environmental systems. *Mathematics and computers in simulation*, 78 (2-3), 379–400.
- Cheng, C.-S. & Cheng, H.-P. (2011). Using neural networks to detect the bivariate process variance shifts pattern. *Computers & Industrial Engineering*. 60, 269–278.
- Cui, R., Gallino, S., Moreno, A. & Zhang, D.J. (2018). The operational value of social media information. *Production and operations management*, 27(10), 1749–1769.
- Dash, R., McMurtrey, M., Rebman, C., & Kar, U. K. (2019). Application of artificial intelligence in automation of supply chain management. *Journal of Strategic Innovation and Sustainability*, 14(3).
- de Barcelos Silva, A., Gomes, M.M., da Costa, C.A., da Rosa Righi, R., Barbosa, J.L.V., Pessin, G., De Doncker, G. & Federizzi, G. (2020). Intelligent personal assistants: a systematic literature review. *Expert Systems with Applications*, 147, 113193.
- De Jesus, A. (2019). AI for Pricing – Comparing 5 Current Applications. Retrieved from <https://emerj.com/ai-sector-overviews/ai-for-pricing-comparing-5-current-applications/2019>
- Di Pasquale, V., Iannone, R., Miranda, S., & Riemma, S. (2013). An Overview of Human Reliability Analysis Techniques in Manufacturing Operations. En *Operations Management* (Chapter 9). ISBN 978-953-51-1013-2.
- Diabat, A. & Deskoore, R. (2016). A hybrid genetic algorithm based heuristic for an integrated supply chain problem. *Journal of Manufacturing Systems*, 38, 172–180.
- Dolgui, A., Ivanov, D., Sethi, S.P. & Sokolov, B. (2019). Scheduling in Production, Supply Chain and Industry 4.0 Systems by Optimal Control: Fundamentals, State-Of-The-Art and Applications. *International journal of production research*, 57(2), 411–432.
- Dougherty, E. M. (1990). Human reliability analysis - Where shouldst thou turn? *Reliability Engineering and System Safety*, 29(3), 283-299.
- Druehl, C., Carrillo, J., & Hsuan, J. (2018). *Innovation and Supply Chain Management Technological Innovations: Impacts on Supply Chains*. Springer.
- Duan, Y., Edwards, J.S. & Dwivedi, Y.K. (2019). Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International journal of information management*, 48, 63–71.
- Feki, M.; Boughzala, I.; Wamba, S.F. (2016). Big Data Analytics-Enabled Supply Chain Transformation: A Literature Review. In *Proceedings of the 49th Hawaii International Conference on System Sciences*, Koloa, HI, USA, 5–8 January 2016.
- Fildes, R., Goodwin, P., Lawrence, M. & Nikolopoulos, K. (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International journal of forecasting*, 25(1), 3–23.
- Fischetti, M. & Fraccaro, M. (2019). Machine learning meets mathematical optimization to predict the optimal production of offshore wind parks. *Computers & Operations Research*, 106, 289–297
- Forrester, J. (1961). *Industrial Dynamics*. Boston: MIT Press.
- Gardner, E.S. (2006). Exponential smoothing: the state of the art—Part II. *International journal of forecasting*, 22(4), 637-666.
- Giarratano, J.C. & Riley, G. (1998). *Expert Systems*. PWS Publishing Co.

- Google. (2021). *Google's Responsible AI Practices*. Recuperado de: <https://www.blog.google/technology/ai/responsible-ai-practices/>.
- Greasley, A. (2005). Using system dynamics in a discrete-event simulation study of a manufacturing plant. *International Journal of Operations & Production Management*, 25(6), 534–548.
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Wamba, S.F., Childe, S.J., Hazen, B. & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, 70, 308–317.
- Haenlein, M. & Kaplan, A. (2019). A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. *California management review*, 61(4), 5–14.
- Hagen, E. (1976). Human Reliability Analysis. *Nuclear Safety*, 315-326.
- He, W.; Zha, S. & Li, L. (2013). Social Media Competitive Analysis and Text Mining: A Case Study in the Pizza Industry. *International journal of information management*, 33, 464–472.
- Hendricks, K. B., & Singhal, V. R. (2003). The effect of supply chain glitches on shareholder wealth. *Journal of operations Management*, 21(5), 501-522.
- Hollnagel, E. (1998). *Cognitive reliability and error analysis method (CREAM)*. Oxford: Elsevier.
- Holweg, M., Disney, S.M., Hines, P. & Naim, M.M. (2005). Towards responsive vehicle supply: a simulation-based investigation into automotive scheduling systems. *Journal of operations Management*, 23(5), 507–530.
- Huang, S.; Potter, A. & Eysers, D. (2020). Social Media in Operations and Supply Chain Management: State-of-the-Art and Research Directions. *International Journal of Production Research*, 58(6), 1893–1925.
- IBM. (2020). *IBM and Partners Launch New Blockchain Network for Supply Chain Management*. Recuperado de: <https://newsroom.ibm.com/2020-02-05-IBM-and-Partners-Launch-New-Blockchain-Network-for-Supply-Chain-Management>.
- Ivanov, D. & Sokolov, B. (2013). Control and System-Theoretic Identification of the Supply Chain Dynamics Domain for Planning, Analysis and Adaptation of Performance under Uncertainty. *International journal of production research*, 224, 313–323.
- Jüttner, U. (2005). Supply chain risk management: Understanding the business requirements from a practitioner perspective. *The international journal of logistics management*, 16(1), 120-141.
- Keskin, G.A., I'lhán, S. & O' zkan, C. (2010). The Fuzzy ART algorithm: a categorization method for supplier evaluation and selection. *Expert Systems with Applications*, 37, 1235–1240.
- Khojasteh-Ghamari, Z., & Irohara, T. (2018). Supply Chain Risk Management: A Comprehensive Review. En *Supply Chain Risk Management* (págs. 3-22). Singapore: Springer.
- Khorram, M., Faria, P., Abrishambaf, O., & Vale, Z. (2019). Demand Response Implementation in an Optimization Based SCADA Model Under Real-Time Pricing Schemes. In: *International Symposium on Distributed Computing and Artificial Intelligence*, 801, 21-29. Cham: Springer International Publishing.
- Kilimci, Z.H.; Akyuz, A.O.; Uysal, M.; Akyokus, S.; Uysal, M.O.; Atak Bulbul, B. & Ekmis, M.A. (2019). An Improved Demand Fore- casting Model Using Deep Learning Approach and Proposed Decision Integration Strategy for Supply Chain. *Complexity*, 2019, 9067367.
- Kim, B., & Bishu, R. (2006). Uncertainty of human error and fuzzy approach to human reliability analysis. *International Journal of Uncertainty, fuzziness and Knowledge-Based Systems*, 14, 111-129.
- Kim, I. S. (2001). Human reliability analysis in the man-machine interface design review. *Annals of Nuclear Energy*, 1069-1081.
- Kim, J. W., & Jung, W. (2003). A taxonomy of performance influencing factors for human reliability analysis of emergency tasks. *Journal of Loss Prevention in the Process Industries*, 479-495.
- Kraus, M., Feuerriegel, S. & Oztekin, A. (2020). Deep learning in business analytics and operations research: models, applications and managerial implications. *European journal of operational research*, 281, 628–641.
- Kreipl, S. & Pinedo, M. (2004). Planning and scheduling in supply chains: an overview of issues in practice. *Production and operations management*, 13, 77–92.
- Lau, R.Y.K.; Zhang, W. & Xu, W. (2018). Parallel Aspect-Oriented Sentiment Analysis for Sales Forecasting with Big Data. *Production and operations management*, 27, 1775–1794.
- Leary, D.E.O. (2013). Artificial intelligence and big data. *IEEE intelligent systems*, 28(2), 96–99.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, 436–444.
- Lee, A.H., Kang, H.-Y., Hsu, C.-F. & Hung, H.-C. (2009). A green supplier selection model for high-tech industry. *Expert Systems with Applications*, 36, 7917–7927.
- Lee, S. W., Kim, A. R., Ha, J. S., & Seong, P. H. (2011). Development of a qualitative evaluation framework for performance shaping factors (PSFs) in advanced MCR HRA. *Annals of Nuclear Energy*, 1751-1759.

- Leung, S.C., Tsang, S.O., Ng, W.-L. & Wu, Y. (2007). A robust optimization model for multi-site production planning problem in an uncertain environment. *European journal of operational research*, 181, 224–238.
- Liu, Y.; Huang, X.; An, A. & Yu, X. (2007). ARSA: A Sentiment-Aware Model for Predicting Sales Performance Using Blogs. In *Proceedings of the 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval—SIGIR '07*, Amsterdam, The Netherlands, 23–27 July 2007; ACM Press: New York, NY, USA, 2007, pp. 607–614.
- Lohr, S. (2016). *IBM Is Counting on its Bet on Watson, and Paying Big Money for it*. New York Times. <https://www.nytimes.com/2016/10/17/technology/ibm-is-counting-on-its-bet-on-watson-and-paying-big-money-for-it.html>.
- Mahadevan, S. & Shah, S.L. (2009). Fault detection and diagnosis in process data using one-class support vector machines. *Journal of process control*, 19(10), 1627–1639.
- Malmberg, C.J. (1996). A genetic algorithm for service level based vehicle scheduling. *European journal of operational research*, 93, 121–134.
- Marsden, P., & Hollnagel, E. (1996). Human interaction with technology: The accidental user. *Acta Psychologica*, 345–358.
- Martin, C., & Leurent, H. (2017). Technology and Innovation for the Future of Production: Accelerating Value Creation. In *World Economic Forum* (pp. 1–38).
- McCarthy, J., Minsky, M., Rochester, N. & Shannon, C. (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI magazine*, 27(4), 12–12.
- Meister, D. (1989). The nature of human error. *Global Telecommunications Conference and Exhibition Communications Technology for the 1990s and Beyond GLOBECOM '89* (pp. 783–786). IEEE.
- Microsoft. (2020). *Microsoft's Commitment to Responsible AI*. Recuperado de: <https://www.microsoft.com/en-us/ai/responsible-ai>
- Minahan, T. (2005). *The Supply Risk Benchmark Report*. Boston: Aberdeen Group.
- Minsky, M. (1968). *Semantic Information Processing*. The MIT Press.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A.A., Veness, J., Bellemare, M.G., Graves, A., Riedmiller, M., Fidjeland, A.K. & Ostrovski, G. (2015). Human-level control through deep reinforcement learning. *Nature* 518, 529–533.
- Mortimer, G., & Milford, M. (2018) When AI meets your shopping experience it knows what you buy – and what you ought to buy. *The Conversation*.
- Mosleh, A. H., & Chang, Y. (2004). Model-based human reliability analysis: prospects and requirements. *Reliability Engineering and System Safety*, 83, 241–253.
- Mosleh, A., & Chang, Y. H. (2007). Cognitive modelling and dynamic probabilistic simulation of operating crew response to complex system accidents - Part 1. *Reliability Engineering and System Safety*, 997–1013.
- Munger, S., Smith, R., & Payne, D. (1962). *An index of electronic equipment operability, data store, AIR-C43-1/62-RP*. Pittsburgh: America Institute for research.
- O'leary, D.E. (2011). The Use of Social Media in the Supply Chain: Survey and Extensions: Use of Social Media in the Supply Chain. *Intelligent Systems in Accounting, Finance and Management* 18(2-3), 121–144.
- O'Reilly, C., & Binns, A.J.M. (2019). *The Three Stages of Disruptive Innovation: Idea Generation, Incubation, and Scaling*. California Management Review.
- Orji, I.J.; Kusi-Sarpong, S. & Gupta, H. (2020). The Critical Success Factors of Using Social Media for Supply Chain Social Sustainability in the Freight Logistics Industry. *International Journal of Production Research*, 58(6), 1522–1539.
- Overgoor, G., Chica, M., Rand, W. & Weishampel, A. (2019). Letting the computers take over: using AI to solve marketing problems. *California management review*, 61(4), 156–185.
- Pan, S., Zhang, L., Thompson, R.G. & Ghaderi, H. (2020). A parcel network flow approach for joint delivery networks using parcel lockers. *International Journal of Production Research*, 58(6), 1–26.
- Pasandideh, S.H.R., Niaki, S.T.A. & Nia, A.R. (2011). A genetic algorithm for vendor managed inventory control system of multi-product multi-constraint economic order quantity model. *Expert Systems with Applications*, 38, 2708–2716.
- Pournader, M., Ghaderi, H., Hassanzadegan, A., & Fahimnia, B. (2021). Artificial intelligence applications in supply chain management. *International Journal of Production Economics*, 241, 208–250.
- Priore, P., Ponte, B., Rosillo, R. & de la Fuente, D. (2019). Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments. *International Journal of Production Research*, 57, 3663–3677.
- Radhakrishnan, S., Harris, B., & Kamarthi, S. (2018). Supply Chain Resiliency: A Review. En *Supply Chain Risk Management* (págs. 215–235). Singapore: Springer.

- Ramos, C., Augusto, J.C. & Shapiro, D. (2008). Ambient intelligence—the next step for artificial intelligence. *IEEE intelligent systems*, 23, 15–18.
- Rasmussen, J. (1983). Skills, rules, knowledge, signals, signs, symbols, and other distinctions in human performance models. *Transactions on Systems, Man, and Cyber-netics*, 257-266.
- Reason, J. (1990). *Human Error*. Cambridge: Cambridge University Press.
- Reiner, G. (2005). Customer-oriented improvement and evaluation of supply chain processes supported by simulation models. *International Journal of Production Economics*, 96, 381–395.
- Riahi, Y., Saikouk, T., Gunasekaran, A., & Badraoui, I. (2021). Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions. *Expert Systems with Applications*, 173, 114702. <https://doi.org/10.1016/j.eswa.2021.114702>
- Rolón, M. & Martínez, E. (2012). Agent-based modeling and simulation of an autonomic manufacturing execution system. *Computers in industry*, 63(1), 53–78.
- Russell Stuart, J. & Norvig, P. (2009). *Artificial Intelligence: A Modern Approach*. Prentice Hall.
- Salkind, N.J. (2010). *Encyclopedia of Research Design*. Sage.
- Scarborough, J. (2007). *Risks during Transportation*. London: RPW Reports.
- Schlegel, G. L., & Trent, R. J. (2016). *Supply chain risk management: An emerging discipline*. Crc Press.
- Seligman, J. (2018). *Artificial intelligence and machine learning and marketing management*. Publisher Lulu.
- Sharma, R., Kamble, S.S., Gunasekaran, A., Kumar, V. & Kumar, A. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers & Operations Research*, 119, 104926.
- Singh, A.; Shukla, N. & Mishra, N. (2018). Social Media Data Analytics to Improve Supply Chain Management in Food Industries. *Transportation Research Part E: Logistics and Transportation Review*, 114, 398–415
- Soleimani, H., Chaharlang, Y. & Ghaderi, H. (2018). Collection and distribution of returned- remanufactured products in a vehicle routing problem with pickup and delivery considering sustainable and green criteria. *Journal of cleaner production*, 172, 960–970.
- Sterne, J. (2018). From programming to statistics to machine learning for marketing. *Applied Marketing Analytics*, 3(4), 298-305(8).
- Sträter, O., Dang, V., Kaufer, B., & Daniels, A. (2004). On the way to assess errors of commission. *Reliability Engineering and System Safety*, 129-138.
- Swain, A.K.; Cao, R.Q. Using Sentiment Analysis to Improve Supply Chain Intelligence. *Inf. Syst. Front.* **2019**, *21*, 469–484.
- Swaminathan, J.M., Smith, S.F. & Sadeh, N.M. (1998). Model. Supply Chain Dynam: Multiagent Approach. *Decision sciences*, 29(3), 607–632.
- Swierczek, A. (2018). Supply Chain Risk Management in the Transmission and Amplification of Disruptions. En *Supply Chain Risk Management* (págs. 155-178). Singapore: Springer.
- Tang, C. S. (2006). Perspectives in supply chain risk management. *International Journal of Production Economics*, 103(2), 451-488.
- Tecuci, G. (2012). Artificial intelligence. *Wires Comput. Statist.* 4, 168–180.
- Tesla. (2021). *Tesla Gigafactory Shanghai*. Recuperado de: <https://www.tesla.com/gigafactory>.
- Tonț, G., Vlădăreanu, L., Munteanu, R. A., & Tonț, D. G. (2009). Some aspects regarding human error assessment in resilient socio-technical systems. *nd International Conference on VISUALIZATION, IMAGING and SIMULATION (VIS'09)*. Baltimore, Morgan State University, USA.
- UPS. (2021). *UPS Adds to its Industry-Leading Sustainable Fuel Strategy with Agreement to Purchase up to 10 Million Gallons of Renewable Diesel Annually*. Recuperado de: <https://www.pressroom.ups.com/pressroom/ContentDetailsViewer.page?ConceptType=PressReleases&id=1627462369247-801>.
- Van Der Zee, D.J. & Van Der Vorst, J.G.A.J. (2005). A Modeling Framework for Supply Chain Simulation: Opportunities for Improved Decision Making. *Decision sciences*, 36(1), 65-95.
- Walmart. (2020). *Walmart's Approach to Ethical AI*. Recuperado de: <https://corporate.walmart.com/newsroom/2020/01/28/walmarts-approach-to-ethical-ai>.
- Wang, H., Tu, C. & Chen, K. (2015). Supplier selection and production planning by using guided genetic algorithm and dynamic nondominated sorting genetic algorithm II approaches. *Mathematical Problems in Engineering*, 2015, 1-15.
- Waters, D. (2011). *Supply chain risk management: vulnerability and resilience in logistics*. Kogan Page Publishers.

- Webster, C., & Ivanov, S.H. (2019) *Robotics, Artificial Intelligence, and the Evolving Nature of Work*. In George, B., & Paul, J. (Eds.). *Business Transformation in Data Driven Societies*, Palgrave-MacMillan (Forthcoming). Retrieved from SSRN: <https://ssrn.com/abstract=3336104>
- Wiegmann, D. A., & Shappell, S. A. (1997). Human Factors Analysis of Postaccident Data: applying theoretical taxonomies of human error. *The International Journal of Aviation Psychology*, 67-81.
- Yao, W. (2017). Analysis on the Application of the Artificial Intelligence Neural Network on the New Energy Micro Grid. *Proceedings of the 2017 4th International Conference on Machinery, Materials and Computer (MACMC)* 22, 637–666.
- You, F., Wassick, J.M. & Grossmann, I.E. (2009). Risk management for a global supply chain planning under uncertainty: models and algorithms. *AIChE Journal*, 55(4), 931–946.
- Yu, J.-b. & Xi, L.-f. (2009). A neural network ensemble-based model for on-line monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes. *Expert Systems with Applications*, 36, 909–921.
- Zanon, L.G., Munhoz Arantes, R.F., Calache, L.D.D.R. & Carpinetti, L.C.R. (2020). A decision making model based on fuzzy inference to predict the impact of SCOR® indicators on customer perceived value. *International Journal of Production Economics*, 223, 107520
- Zarbakhshnia, N., Soleimani, H. & Ghaderi, H. (2018). Sustainable third-party reverse logistics provider evaluation and selection using fuzzy SWARA and developed fuzzy COPRAS in the presence of risk criteria. *Applied soft computing*, 65, 307–319.
- Zsidisin, G. A., & Ritchie, B. (2009). *Supply chain risk management—developments, issues and challenges*. Boston: Springer.