

**Sesgos algorítmicos en sistemas de inteligencia artificial: herramienta metodológica para su
identificación y mitigación en la industria de manufactura**

Neider Fernando Castillo Castillo

Asesor

Brayan Andru Montenegro Embus

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnológica e Ingeniería ECBTI

Especialización en Ciencia y Analítica de Datos

2026

Resumen

A nivel mundial, la inteligencia artificial (IA) ha pasado de ser una tecnología experimental para convertirse en un componente estratégico dentro de los procesos productivos industriales. Según reportes del World Economic Forum (2023) y de McKinsey Global Institute (2023), más del 55% de las grandes empresas manufactureras a nivel global han incorporado al menos una solución basada en IA dentro de sus cadenas de producción. Este fenómeno ha traído consigo importantes ganancias en eficiencia, reducción de costos y mejora en la toma de decisiones. Sin embargo, también ha expuesto una problemática transversal que afecta a todos los sectores: los sesgos algorítmicos, es decir, los errores sistemáticos que se producen cuando los modelos de IA son entrenados con datos incompletos, mal representados o de baja calidad. Estas fallas no son menores: de acuerdo con estudios recientes, los sesgos en datos pueden reducir la precisión de los modelos industriales en hasta un 30%, generando pérdidas operativas significativas y debilitar la confianza en estas tecnologías.

En América Latina, la adopción de inteligencia artificial en la industria manufacturera ha avanzado a un ritmo menor que en otras regiones. Países como Brasil y México lideran la transformación digital en el continente, con inversiones en IA que duplican o triplican las del resto de la región (CEPAL, 2022). Sin embargo, incluso en estos países líderes, los desafíos relacionados con la calidad de los datos y los sesgos algorítmicos siguen siendo una barrera crítica para la implementación efectiva de sistemas inteligentes. En el sector de manufactura y la industria alimentaria, que han experimentado un crecimiento sostenido en Latinoamérica durante los últimos años, la incorporación de IA en procesos productivos es aún naciente y presenta retos específicos asociados a la diversidad de materias primas, las variaciones estacionales en la producción y la escasez de datos históricos estructurados.

En Colombia, el sector manufacturero — incluyendo la industria de alimentos en general — se encuentra en una etapa temprana de adopción de tecnologías propias de la Industria 4.0. De acuerdo con estudios del Departamento Administrativo Nacional de Estadística (DANE, 2022) y del Departamento Nacional de Planeación (DNP, 2022), las empresas del sector destinan en promedio menos del 2% de su presupuesto operativo a iniciativas de transformación digital basadas en inteligencia artificial, lo que sitúa al país en un nivel de competitividad inferior respecto a los referentes regionales.

Palabras clave: Sesgo algorítmico, Inteligencia artificial, Sector manufacturero, Calidad de datos, Industria 4.0

Abstract

Globally, artificial intelligence (AI) has transitioned from an experimental technology to a strategic component within industrial production processes. According to reports from the World Economic Forum (2023) and the McKinsey Global Institute (2023), more than 55% of large manufacturing companies worldwide have incorporated at least one AI-based solution into their production chains. This phenomenon has brought significant gains in efficiency, cost reduction, and improved decision making. However, it has also exposed a cross-cutting problem affecting all sectors: algorithmic biases, that is, the systematic errors that occur when AI models are trained with incomplete, poorly represented, or low-quality data. These flaws are not minor: according to recent studies, data biases can reduce the accuracy of industrial models by up to 30%, generating significant operational losses and eroding trust in these technologies.

In Latin America, the adoption of artificial intelligence in the manufacturing industry has progressed at a slower pace than in other regions. Countries like Brazil and Mexico lead the digital transformation on the continent, with AI investments that are two to three times higher than those of the rest of the region (ECLAC, 2022). However, even in these leading countries, challenges related to data quality and algorithmic biases remain a critical barrier to the effective implementation of intelligent systems.

In Colombia, the manufacturing sector—including the food industry in general—is in an early stage of adopting Industry 4.0 technologies. According to studies by the National Administrative Department of Statistics (DANE, 2022) and the National Planning Department (DNP, 2022), companies in the sector allocate, on average, less than 2% of their operating budget to digital transformation initiatives based on artificial intelligence, placing the country at a lower level of competitiveness compared to regional benchmarks.

Keywords: Algorithmic bias, Artificial intelligence, Manufacturing sector, Data quality, Industry 4.0.

Tabla de Contenido

Introducción	12
Descripción del Problema	14
Planteamiento del Problema.....	14
Sistematización del Problema	15
Justificación	16
Objetivos	18
Objetivo General	18
Objetivos Específicos.....	18
Marco de Referencia	19
Estado del Arte.....	19
Sesgos Algorítmicos en Inteligencia Artificial	19
IA y Calidad de Datos en Manufactura	20
IA en la Industria Alimentaria.....	20
Contexto Colombiano.....	21
Marco Contextual y Conceptual	21
Marco Teórico	22
Inteligencia Artificial y Ciencia de Datos	22
Sesgos Algorítmicos.....	22
Industria 4.0.....	23
Calidad de Datos	23
Normativa y Ética en IA.....	23
Marco Conceptual	24

Sesgos en los Datos en Sistemas de Inteligencia Artificial.....	24
Sesgo de Exclusión.....	24
Sesgo de Medición	24
Sesgo de Muestreo.....	24
Inteligencia Artificial	25
Toma de Decisiones y Ciencia de Datos en las Organizaciones.....	25
Industria 4.0: Transformación Productiva.....	25
Marco Normativo	26
Metodología	27
Método	27
Fase 1 Revisión Documental y Análisis Teórico	27
Fase 2 Identificación y Clasificación de Sesgos	28
Fase 3 Evaluación del Impacto de los Sesgos	28
Fase 4 Diseño y Validación Conceptual de la Herramienta Metodológica.....	29
Tipo de Estudio	29
Población y Muestra.....	29
Técnicas para la Recolección de Información	30
Revisión Documental	30
Análisis de Estudios de Caso.....	30
Resultados	33
Primer Resultado.....	33
Segundo Resultado.....	35
Tercer Resultado	36

Conclusiones	39
Recomendaciones	41
Referencias Bibliográficas	42
Apéndices.....	46

Lista de Tablas

Tabla 1 <i>Cronograma de Actividades</i>	30
Tabla 2 <i>Matriz de Identificación de Sesgos en Datos Para Sistemas de Inteligencia Artificial en Procesos Productivos de Manufactura y la Industria de Alimentos</i>	33
Tabla 3 <i>Herramienta Metodológica: Lineamientos para la Identificación y Mitigación de Sesgos en Datos de IA</i>	36

Lista de Figuras

Figura 1 <i>Modelo Conceptual del Impacto de los Sesgos en Sitemas de IA</i>	35
---	----

Lista de Apendices

Apéndice A <i>Herramienta Metodológica para la Identificación y Mitigación de Sesgos Algorítmicos (HIMSA) – Versión de Uso Práctico</i>	46
--	----

Introducción

La inteligencia artificial (IA) se ha convertido en una herramienta estratégica para las empresas del sector manufacturero, especialmente en el contexto de la Industria 4.0. Su aplicación en procesos como el mantenimiento predictivo, la gestión de inventarios y la planificación de la producción promete grandes beneficios. Sin embargo, uno de los obstáculos más frecuentes y menos visibles es el sesgo algorítmico, que ocurre cuando los modelos de IA son entrenados con datos incorrectos, incompletos o no representativos. Este trabajo busca analizar cómo estos sesgos afectan los procesos productivos de la industria manufacturera, con especial atención al sector de alimentos, y qué estrategias pueden implementarse para reducirlos, con el fin de lograr una inteligencia artificial más confiable y útil para la toma de decisiones empresariales.

Es importante precisar que, si bien existe un amplio discurso sobre la Industria 5.0 a nivel global, Colombia todavía se encuentra en proceso de adopción de las tecnologías características de la Industria 4.0. Esta afirmación está respaldada por estudios del Departamento Administrativo Nacional de Estadística (DANE, 2022) y del Departamento Nacional de Planeación (DNP, 2022), los cuales indican que las empresas manufactureras colombianas presentan niveles de inversión en inteligencia artificial que no superan el umbral necesario para consolidar una transformación digital plena.

El presente trabajo propone, como resultado de esta investigación, una herramienta metodológica práctica para la identificación y mitigación de sesgos algorítmicos en sistemas de inteligencia artificial aplicados al sector de manufactura, con énfasis en la industria de alimentos. Esta contribución busca cerrar la brecha entre los principios teóricos de gestión de

datos y las necesidades reales de las empresas manufactureras del país, aportando una guía aplicable, adaptada al contexto de la Industria 4.0 en Colombia.

El documento se estructura de la siguiente manera: primero se describe y plantea el problema de investigación; luego se justifica la importancia del estudio; posteriormente se definen los objetivos y el marco de referencia teórico; a continuación, se explica la metodología utilizada; y finalmente se presentan los resultados, conclusiones y recomendaciones del trabajo.

Descripción del Problema

Planteamiento del Problema

Hoy en día, la inteligencia artificial (IA) y el análisis de datos se han vuelto herramientas muy importantes para mejorar la eficiencia operativa y apoyar la toma de decisiones en el sector productivo. Sus aplicaciones en áreas como la planificación de la producción, la gestión de inventarios y la reducción de costos han mostrado un alto potencial dentro del marco de la Industria 4.0. Sin embargo, a pesar de estos avances, la implementación real de estas tecnologías en los procesos productivos sigue siendo limitada y presenta desafíos importantes que todavía no han sido resueltos del todo.

Uno de los principales obstáculos que se encuentran en la literatura es la presencia de sesgos en los datos que se usan para entrenar y operar los modelos de inteligencia artificial. Estos sesgos pueden aparecer por distintas razones, como datos incompletos o con valores faltantes, errores en la medición de variables del proceso productivo, muestras que no representan bien la realidad operativa de la empresa, o simplemente por la manera en que se recopila y registra la información en los sistemas de producción. Por ejemplo, cuando un modelo de IA se entrena con información sesgada, sus predicciones y recomendaciones tienden a ser inexactas o poco confiables, lo que afecta directamente la calidad de las decisiones que toma la empresa.

Para los procesos productivos, las consecuencias de estos sesgos son concretas y costosas. En la planificación de la producción, los errores en la predicción de la demanda pueden generar sobrestock o desabastecimiento. En la gestión de inventarios, tomar decisiones basadas en datos incorrectos incrementa los costos operativos y reduce la capacidad de respuesta ante los cambios del mercado. Todo esto termina generando desconfianza en las empresas hacia estas tecnologías, frenando su implementación incluso cuando el potencial de mejora es evidente.

Por todo lo anterior, este trabajo busca investigar y responder la siguiente pregunta: ¿Qué metodología puede implementarse para identificar, prevenir y reducir los sesgos en los datos utilizados por modelos de inteligencia artificial en los procesos productivos del sector de manufactura, con énfasis en la industria de alimentos, con el fin de mejorar la confiabilidad en la toma de decisiones empresariales?

Sistematización del Problema

La sistematización del problema se desarrolla a partir de preguntas específicas que permiten guiar la investigación, enfocándose en la identificación de los tipos de sesgos en los datos, su origen, su impacto en los procesos productivos y las posibles estrategias para su mitigación mediante una herramienta metodológica.

¿Cuáles son los principales tipos de sesgos presentes en los datos utilizados por sistemas de IA en los procesos productivos de la industria de manufactura?

¿Cuál es el origen de dichos sesgos en el contexto de los procesos de manufactura e industria de alimentos de alimentos en Colombia?

¿Qué impacto tienen los sesgos identificados en el desempeño de los modelos de IA y en la toma de decisiones operativas?

¿Qué estrategias o buenas prácticas documentadas en la literatura permiten mitigar estos sesgos?

Justificación

La inteligencia artificial y el análisis de datos son hoy en día herramientas clave para mejorar la eficiencia operativa y la competitividad de las empresas. Sin embargo, en el sector productivo todavía se observa una baja adopción de estas tecnologías en comparación con otros sectores de la economía. Una de las razones que dificulta su uso es la presencia de sesgos en los datos que se emplean para construir modelos de inteligencia artificial, lo cual produce resultados poco precisos y genera desconfianza en las empresas hacia estas herramientas.

Según datos del Observatorio de Economía Digital de Colombia (2022), las empresas del sector manufacturero destinan en promedio menos del 2% de su presupuesto operativo a iniciativas de transformación digital basadas en inteligencia artificial. Este dato refleja el rezago tecnológico del sector y justifica la necesidad de generar herramientas metodológicas accesibles y aplicables que permitan avanzar de manera responsable hacia una mayor adopción de la IA, reduciendo al mismo tiempo los riesgos asociados a los sesgos en los datos.

Este proyecto busca analizar ese problema desde la perspectiva de la ciencia de datos y la analítica, explorando cómo los sesgos afectan los procesos productivos del sector manufacturero y, en particular, de la industria de alimentos en Colombia, y proponiendo enfoques para reducirlos. De esta manera, la investigación busca contribuir al desarrollo de prácticas adecuadas para un uso responsable de la inteligencia artificial en el sector productivo.

Integrar las nuevas tecnologías de la información con la maquinaria y los procesos ya existentes permitiría fortalecer la operación de las empresas, generando beneficios como la reducción de costos, un mejor manejo de la información, mayor confiabilidad en los procesos, innovación, mejor disponibilidad de los productos y planificaciones más eficientes, entre otros.

En ese sentido, no basta con decir que la IA es el futuro; también hay que hacerla confiable. Si no se aprende a reducir estos sesgos, las empresas seguirán invirtiendo en herramientas que no les dan resultados reales. Este proyecto apunta a entender cómo se puede pasar de una IA que adivina a una IA que realmente ayuda, usando datos precisos y representativos de la realidad productiva.

Objetivos

Objetivo General

Diseñar una herramienta metodológica para la identificación y mitigación de sesgos en los datos utilizados por sistemas de inteligencia artificial en los procesos productivos de la industria de manufactura, con especial énfasis en el sector de alimentos, que sirva como apoyo a la toma de decisiones empresariales.

Objetivos Específicos

Identificar y clasificar los principales tipos de sesgos presentes en los datos utilizados por sistemas de inteligencia artificial en los procesos productivos de la industria de manufactura y la industria de alimentos, mediante análisis de calidad de datos y revisión documental.

Evaluar el impacto de los sesgos identificados en el desempeño de los modelos de inteligencia artificial y en la toma de decisiones operativas del proceso productivo de alimentos, a partir del análisis y comparación de casos documentados.

Proponer una metodología de adopción de inteligencia artificial para el sector de manufactura y la industria de alimentos en Colombia, que tome como punto de partida los hallazgos sobre sesgos identificados y las buenas prácticas documentadas, y que pueda ser referenciada como contribución metodológica del presente trabajo.

Marco de Referencia

En el presente apartado se desarrollan los referentes teóricos, conceptuales, contextuales y normativos que sirven como fundamento al trabajo. Para su construcción se organizó el marco de referencia en cinco componentes: estado del arte, marco contextual, marco teórico, marco conceptual y marco normativo. Esta organización responde a la necesidad de abordar el tema de los sesgos algorítmicos desde diferentes perspectivas complementarias, que en conjunto permiten una comprensión integral del problema y de las estrategias para su mitigación en el contexto de la industria de manufactura en Colombia.

Estado del Arte

La revisión de la literatura se organizó en cuatro ejes temáticos que permiten abordar de manera progresiva y articulada el problema de los sesgos algorítmicos en sistemas de inteligencia artificial aplicados a procesos productivos. El Eje 1 aborda los fundamentos del sesgo algorítmico en IA; el Eje 2 examina la relación entre IA y calidad de datos en el sector manufacturero; el Eje 3 revisa las aplicaciones de IA en la industria alimentaria y de manufactura; y el Eje 4 contextualiza el problema en el escenario colombiano.

Sesgos Algorítmicos en Inteligencia Artificial

La investigación sobre sesgos en sistemas de inteligencia artificial ha crecido significativamente en la última década. Mehrabi et al. (2021) realizaron una revisión exhaustiva de los tipos de sesgos presentes en modelos de machine learning, identificando más de 23 categorías diferentes, entre las que destacan el sesgo de representación, el sesgo de medición y el sesgo histórico. Por su parte, Ntoutsis et al. (2020) analizaron el sesgo en sistemas de IA desde una perspectiva interdisciplinaria, concluyendo que los problemas de calidad de datos son la causa más frecuente de sesgos en entornos productivos. Pessach y Shmueli (2022)

complementan esta visión con una revisión sistemática sobre la equidad en machine learning, proponiendo métricas cuantitativas para detectar y corregir sesgos en conjuntos de datos industriales.

IA y Calidad de Datos en Manufactura

En el contexto de la manufactura, Oztemel y Gursev (2020) realizaron una revisión de más de 600 artículos sobre Industria 4.0, identificando la calidad de los datos como uno de los principales factores críticos de éxito para la implementación de sistemas inteligentes en procesos productivos. Cai y Zhu (2021) señalan que en entornos de big data, la calidad de los datos presenta desafíos específicos relacionados con la completitud, consistencia y representatividad de la información, aspectos directamente relacionados con los sesgos estudiados en este trabajo. Gudivada et al. (2021) proponen un marco conceptual para la evaluación de calidad de datos en proyectos de machine learning, que incluye criterios aplicables al sector de producción de alimentos.

IA en la Industria Alimentaria

En el sector de alimentos, Costa et al. (2021) documentaron las principales aplicaciones de IA en la industria alimentaria, incluyendo control de calidad, predicción de demanda y optimización de procesos productivos. Marvin et al. (2020) analizaron el uso de big data en seguridad alimentaria, destacando que los sesgos en los datos de producción pueden comprometer la detección de riesgos de calidad. Bouzembrak et al. (2021) estudiaron el impacto del Internet de las Cosas (IoT) y la IA en la trazabilidad de productos alimentarios, concluyendo que la confiabilidad de los datos de sensores es fundamental para evitar sesgos de medición.

Contexto Colombiano

Sánchez Torres y Ordóñez Ordóñez (2020) presentaron un estado del arte sobre inteligencia artificial en Colombia, concluyendo que la adopción de IA en el sector manufacturero colombiano es incipiente y que existe una brecha significativa respecto a países de la región como Brasil y México. El Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC, 2023) publicó el Marco Ético para la Inteligencia Artificial en Colombia, documento que establece principios de equidad, transparencia y no discriminaciones aplicables directamente a la gestión de sesgos algorítmicos. El DNP (2022) en el documento CONPES 3995 señala que la transformación digital del sector productivo colombiano requiere, entre otras medidas, el desarrollo de herramientas metodológicas para el uso responsable de la IA.

Marco Contextual y Conceptual

Este trabajo se desarrolla en el marco de la transformación digital que están viviendo las empresas del sector productivo, especialmente las dedicadas a la manufactura y producción de alimentos. En los últimos años, estas organizaciones han comenzado a incorporar tecnologías como la automatización, el análisis de datos y la inteligencia artificial, buscando mejorar sus procesos y volverse más competitivas en el mercado.

Este cambio hace parte de lo que se conoce como Industria 4.0, un modelo en el que las empresas ya no dependen únicamente del trabajo manual, sino también de sistemas inteligentes que permiten tomar decisiones más rápidas y basadas en datos reales. Sin embargo, dentro de este mismo contexto aparecen problemas importantes que no siempre se tienen en cuenta, como la calidad de los datos y los sesgos que pueden afectar los resultados que producen los sistemas de inteligencia artificial.

Es pertinente mencionar que, según el Observatorio de Economía Digital de Colombia (2022), la industria manufacturera nacional invierte aproximadamente en iniciativas de IA un porcentaje que aún representa una proporción menor de su presupuesto total, lo que indica que Colombia se encuentra todavía en las etapas tempranas de la transición hacia la Industria 4.0. Este dato coloca al país en un nivel de competitividad inferior al de naciones de referencia en la región, y resalta la importancia estratégica de estudios como el presente.

Marco Teórico

El presente trabajo se fundamenta en varios conceptos clave que son esenciales para entender la problemática de los sesgos algorítmicos en sistemas de inteligencia artificial, especialmente en el contexto de la industria de manufactura.

Inteligencia Artificial y Ciencia de Datos

La inteligencia artificial (IA) se ha convertido en una herramienta fundamental para las empresas, permitiendo la automatización y optimización de procesos productivos. Según Russell y Norvig (2021), la IA se define como la capacidad de los sistemas computacionales para aprender de los datos y generar modelos que apoyan la toma de decisiones. Este enfoque es crucial para mejorar la eficiencia operativa y la competitividad en el sector manufacturero.

La ciencia de datos, por otro lado, se encarga de analizar grandes volúmenes de información para convertirlos en conocimiento útil. Provost y Fawcett (2013) destacan que la ciencia de datos permite a las empresas tomar decisiones más informadas y estratégicas, lo cual es esencial para el éxito de la IA en entornos productivos.

Sesgos Algorítmicos

Uno de los retos más significativos al implementar sistemas de inteligencia artificial es la presencia de sesgos en los datos utilizados para entrenar los modelos. Barocas et al. (2023)

explican que estos sesgos pueden afectar los resultados de los modelos de IA, generando decisiones incorrectas o poco confiables. Los sesgos más comunes incluyen el sesgo de exclusión, el sesgo de medición y el sesgo de muestreo, cada uno con un impacto específico en los procesos productivos.

Industria 4.0

La Industria 4.0 representa la cuarta revolución industrial, caracterizada por la integración de tecnologías digitales avanzadas en los procesos productivos. Schwab (2016) describe cómo la digitalización y la interconexión de los procesos permiten la creación de sistemas productivos más inteligentes y eficientes. En este contexto, la IA juega un papel crucial al permitir que las empresas analicen información en tiempo real y optimicen sus procesos.

Calidad de Datos

La calidad de los datos es un factor crítico para el éxito de la inteligencia artificial en la industria. Cai y Zhu (2021) señalan que en entornos de big data, la calidad de los datos presenta desafíos específicos relacionados con la completitud, consistencia y representatividad de la información. Estos aspectos están directamente relacionados con los sesgos estudiados en este trabajo.

Normativa y Ética en IA

El uso responsable de la inteligencia artificial requiere adherirse a principios éticos y normativas que garanticen la equidad y transparencia. El Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC, 2023) ha publicado el Marco Ético para la IA en Colombia, que establece principios de equidad, transparencia y no discriminación, aplicables directamente a la gestión de sesgos algorítmicos.

Marco Conceptual

Con el tiempo, la transformación de las empresas del sector de manufactura y la industria de alimentos en tecnología es un proceso complejo y multifacético que cambia fundamentalmente la forma en que las empresas operan, producen productos e interactúan con el mercado.

Sesgos en los Datos en Sistemas de Inteligencia Artificial

Uno de los retos más importantes al implementar sistemas de inteligencia artificial es la presencia de sesgos en los datos que se utilizan para entrenar los modelos. Estos sesgos pueden aparecer cuando la información no representa bien la realidad o cuando se cometen errores durante la recolección o el manejo de los datos. Según Barocas et al. (2023), los sesgos algorítmicos pueden generar resultados incorrectos o decisiones automatizadas que afectan la confiabilidad de los sistemas de inteligencia artificial.

Entre los tipos de sesgos más comunes se encuentran:

Sesgo de Exclusión

Ocurre cuando se dejan por fuera algunos datos o variables que pueden ser importantes para el análisis.

Sesgo de Medición

Se presenta cuando los datos tienen errores o inconsistencias en la forma en que fueron medidos o registrados.

Sesgo de Muestreo

Sucedec cuando el conjunto de datos utilizado no representa de forma adecuada a toda la población de interés.

Inteligencia Artificial

La inteligencia artificial es una rama de la informática que busca desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como aprender de los datos, reconocer patrones y apoyar la toma de decisiones. De acuerdo con Russell y Norvig (2021), la inteligencia artificial permite que los sistemas computacionales aprendan a partir de los datos y generen modelos predictivos que ayudan en la toma de decisiones en diferentes contextos.

Toma de Decisiones y Ciencia de Datos en las Organizaciones

La ciencia de datos es una disciplina que combina métodos estadísticos, programación y análisis de información para extraer conocimiento útil a partir de los datos. Según Provost y Fawcett (2020), la ciencia de datos permite transformar grandes volúmenes de información en conocimiento que puede apoyar la toma de decisiones dentro de las empresas.

Industria 4.0: Transformación Productiva

La Industria 4.0 representa la cuarta revolución industrial y se caracteriza por la integración de tecnologías digitales avanzadas dentro de los procesos productivos. De acuerdo con Schwab (2016), la Industria 4.0 está transformando la forma en que las empresas producen bienes y servicios, permitiendo la creación de sistemas productivos más inteligentes, conectados y eficientes.

Marco Normativo

Aunque la inteligencia artificial es una tecnología en crecimiento, ya existen algunas normas y principios que orientan su uso responsable, especialmente en lo relacionado con el manejo de datos. En muchos países, existen leyes de protección de datos personales que buscan garantizar que la información sea utilizada de manera adecuada, evitando errores, manipulación o uso indebido.

En Colombia, el documento CONPES 3995 (DNP, 2022) establece la Política Nacional de Confianza y Seguridad Digital, que incluye lineamientos para el uso responsable de la inteligencia artificial en el sector productivo. Adicionalmente, el MinTIC (2023) publicó el Marco Ético para la IA en Colombia, que define principios de equidad, transparencia, responsabilidad y no discriminaciones directamente aplicables a la gestión de sesgos algorítmicos en entornos industriales.

Metodología

El presente trabajo fue elaborado bajo la metodología de revisión bibliográfica sistemática de tipo scoping review (Arksey y O'Malley, 2005). Este tipo de revisión permite mapear de manera sistemática la literatura existente sobre un tema, identificar vacíos de conocimiento y sintetizar evidencia de múltiples fuentes sin restringir el análisis a estudios con un diseño metodológico específico. Se eligió este enfoque porque el tema de los sesgos algorítmicos en el sector de manufactura en Colombia no cuenta aún con una literatura consolidada y especializada, lo que hace necesaria una exploración amplia y ordenada de las fuentes disponibles. El enfoque es cualitativo con alcance descriptivo y exploratorio, orientado al diseño de una herramienta metodológica práctica.

Método

El método utilizado en este trabajo es el analítico-documental, basado en la revisión, análisis e interpretación de fuentes secundarias. Según Hernández-Sampieri et al. (2018), el método documental es adecuado cuando el objetivo del estudio es comprender un problema a partir del conocimiento ya existente y construir propuestas que respondan a las necesidades identificadas.

El desarrollo del trabajo se organizó en cuatro fases secuenciales:

Fase 1 Revisión Documental y Análisis Teórico

Objetivo de la fase: construir la base teórica y conceptual del trabajo mediante la búsqueda, selección, lectura y análisis de fuentes académicas y técnicas relacionadas con los sesgos algorítmicos, la calidad de datos y la inteligencia artificial en procesos productivos.

Se definieron términos de búsqueda en español e inglés y se realizaron búsquedas sistemáticas en Scopus, Google Scholar, IEEE Xplore, ScienceDirect y los repositorios

institucionales del DNP, el MinTIC y el Observatorio de Economía Digital de Colombia. Se aplicaron criterios de inclusión (publicaciones del año 2019 en adelante, artículos en revistas indexadas o memorias de conferencias reconocidas) y criterios de exclusión (artículos sin acceso a texto completo, publicaciones anteriores a 2019 salvo referencias seminales). Como resultado se consolidaron 32 referencias bibliográficas.

Fase 2 Identificación y Clasificación de Sesgos

Objetivo de la fase: identificar, describir y clasificar los principales tipos de sesgos presentes en los datos utilizados por sistemas de inteligencia artificial en procesos productivos, a partir del análisis de la literatura revisada.

Se analizaron los 32 estudios seleccionados, identificando tres tipos de sesgo recurrentes y consistentes: el sesgo de exclusión, el sesgo de medición y el sesgo de muestreo. El entregable principal fue la Matriz de Identificación de Sesgos (Tabla 2).

Fase 3 Evaluación del Impacto de los Sesgos

Objetivo de la fase: analizar y comprender cómo los sesgos identificados afectan el desempeño de los modelos de inteligencia artificial y la calidad de las decisiones operativas, a partir de la comparación de casos documentados en la literatura.

Se construyó el modelo conceptual del impacto de los sesgos (Figura 1), que muestra cómo los sesgos en los datos se propagan a través del proceso de IA hasta llegar a la decisión operativa final. Los hallazgos de Cai y Zhu (2021) indican que los problemas de calidad de datos pueden reducir la precisión de los modelos industriales en hasta un 30%.

Fase 4 Diseño y Validación Conceptual de la Herramienta Metodológica

Objetivo de la fase: diseñar una herramienta metodológica práctica, estructurada y replicable que permita a las empresas del sector identificar y mitigar de manera sistemática los sesgos en los datos utilizados por sus sistemas de inteligencia artificial.

Las buenas prácticas identificadas en la literatura se estructuraron en un flujo metodológico de cinco pasos: (1) diagnóstico de calidad de datos, (2) identificación del tipo de sesgo, (3) evaluación del impacto, (4) aplicación de acciones de mitigación, y (5) seguimiento y monitoreo continuo. La herramienta fue validada conceptualmente comparando cada paso con recomendaciones de al menos dos referencias bibliográficas especializadas.

Tipo de Estudio

El presente estudio es de tipo descriptivo y exploratorio. Es descriptivo porque busca identificar y explicar los principales sesgos que existen en los datos utilizados por sistemas de inteligencia artificial en los procesos productivos. Es exploratorio porque el tema de los sesgos en inteligencia artificial dentro de la industria de manufactura no está completamente desarrollado, por lo que se busca investigar, comprender mejor el problema y proponer una solución.

Población y Muestra

La población de estudio está conformada por empresas del sector manufacturero y de la industria de alimentos. Debido a limitaciones de acceso y tiempo, la investigación se desarrolló a partir de una muestra no probabilística, seleccionando estudios de caso documentados y experiencias reportadas en literatura especializada, correspondientes a empresas que hayan incorporado sistemas de inteligencia artificial en sus procesos productivos.

Técnicas para la Recolección de Información

La recolección de información se realizó mediante técnicas cualitativas basadas en fuentes secundarias, específicamente:

Revisión Documental

Análisis de artículos científicos, libros y documentos académicos sobre inteligencia artificial, calidad de datos y sesgos en contextos productivos.

Análisis de Estudios de Caso

Examen de experiencias documentadas de empresas que han implementado inteligencia artificial en sus procesos productivos, con el objetivo de detectar posibles sesgos en los datos.

Tabla 1

Cronograma de Actividades

Actividad	Descripción	Tiempo estimado
Revisión documental y marco teórico	Búsqueda, análisis y sistematización de literatura científica y técnica relacionada con IA, sesgos en datos, calidad de información y aplicaciones en procesos productivos del sector de manufactura. Identificación de conceptos clave y vacíos de investigación.	Semanas 1 – 3
Identificación y clasificación de sesgos	Análisis de calidad de datos reportados en estudios de caso y literatura especializada. Identificación y	Semanas 4 – 5

Actividad	Descripción	Tiempo estimado
	clasificación de los principales tipos de sesgos (exclusión, medición y muestreo) presentes en los datos utilizados por sistemas de inteligencia artificial.	
Evaluación del impacto de los sesgos	Análisis y comparación de casos documentados de implementación de IA en procesos productivos. Evaluación del impacto de los sesgos identificados en el desempeño de los modelos y en la toma de decisiones operativas.	Semanas 6 – 7
Identificación de buenas prácticas	Revisión de experiencias reportadas en literatura sobre gestión de datos y mitigación de sesgos en sistemas de IA aplicados al sector productivo. Selección de prácticas relevantes y aplicables a la industria de manufactura.	Semana 8
Diseño de la herramienta metodológica	Diseño de la herramienta para la identificación y mitigación de sesgos en datos utilizados por sistemas de IA. Elaboración de lineamientos, matrices de evaluación y flujo metodológico	Semanas 9 – 10

Actividad	Descripción	Tiempo estimado
	orientado al contexto productivo de alimentos.	
Redacción de resultados, conclusiones y recomendaciones	Presentación de la herramienta metodológica diseñada, discusión de resultados, conclusiones del estudio y recomendaciones para su aplicación en empresas del sector de manufactura	Semanas 11 – 12

Nota. Las semanas corresponden al cronograma de desarrollo del proyecto de investigación.

Resultados

Primer Resultado

Tabla 2

Matriz de Identificación de Sesgos en Datos Para Sistemas de Inteligencia Artificial en Procesos Productivos de Manufactura y la Industria de Alimentos.

Tipo de sesgo	Descripción	Fuente del sesgo	Impacto en la IA	Proceso productivo afectado	Referencias
Sesgo de exclusión	Omisión de variables o registros relevantes en el conjunto de datos	Falta de registro histórico, exclusión de variables críticas del proceso	Predicciones incompletas o inexactas	Planificación de la producción	Mehrabi et al. (2021); Ntoutsis et al. (2020); Pessach & Shmueli (2022)
Sesgo de medición	Errores o inconsistencias en la captura de datos	Sensores mal calibrados, registros manuales incorrectos	Modelos entrenados con información imprecisa	Mantenimiento predictivo	Bouzembrak et al. (2021); Cai & Zhu (2021); Gudivada et al. (2021)

Tipo de sesgo	Descripción	Fuente del sesgo	Impacto en la IA	Proceso productivo afectado	Referencias
Sesgo de muestreo	Conjunto de datos no representativo de la operación real	Datos limitados a ciertos periodos, lotes o condiciones	Recomendaciones que no reflejan el comportamiento real del proceso	Gestión de inventarios	Ntoutsis et al. (2020); Marvin et al. (2020); Costa et al. (2021)

Nota. Esta matriz amplía su aplicación a la industria manufacturera y de alimentos en general.

permite a las empresas identificar de manera estructurada los principales sesgos presentes en los datos utilizados por sistemas de inteligencia artificial, así como su impacto en los procesos productivos de alimentos.

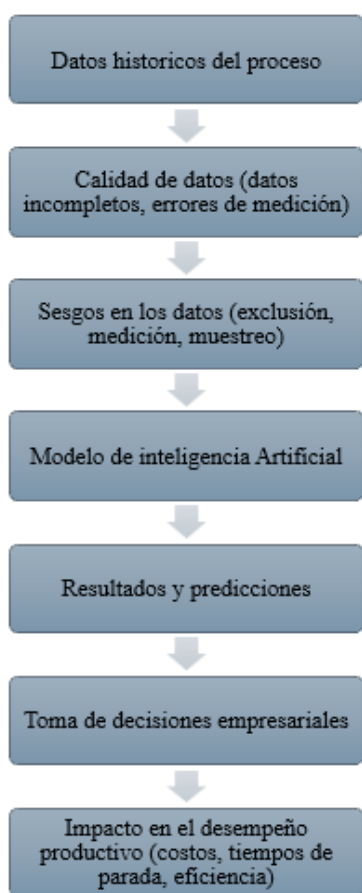
La matriz de identificación de sesgos permite organizar de manera clara los principales tipos de sesgos que pueden presentarse en los datos utilizados por sistemas de inteligencia artificial. Este resultado es importante porque facilita a las empresas reconocer de forma sencilla qué tipo de sesgo tienen, de dónde viene el problema y cómo afecta los procesos productivos. Específicamente, se identificó que el sesgo de exclusión afecta principalmente la planificación de la producción, el sesgo de medición impacta el mantenimiento predictivo, y el sesgo de muestreo afecta la gestión de inventarios.

Segundo Resultado

El modelo conceptual desarrollado permite entender de forma clara cómo los sesgos en los datos afectan todo el proceso de toma de decisiones. El flujo inicia desde los datos históricos del proceso y pasa por las etapas de: calidad de los datos, identificación de sesgos, aplicación en modelos de IA, generación de resultados y toma de decisiones.

Figura 1

Modelo Conceptual del Impacto de los Sesgos en Sistemas de IA



Nota. La figura representa el flujo metodológico de la herramienta propuesta, el cual inicia con la evaluación de la calidad de los datos, continúa con la identificación de sesgos, la evaluación de su impacto en los modelos de inteligencia artificial y finaliza con la aplicación de acciones de mitigación y seguimiento.

Este resultado muestra que, si los datos iniciales tienen errores o sesgos, todo el proceso se ve afectado, generando decisiones incorrectas y pérdidas operativas en la empresa. Este hallazgo es consistente con lo señalado por Arrieta et al. (2020), quienes indican que la opacidad en el origen de los datos es uno de los principales obstáculos para construir sistemas de IA confiables en entornos industriales.

Tercer Resultado

Tabla 3

Herramienta Metodológica: Lineamientos para la Identificación y Mitigación de Sesgos en Datos de IA

Fase	Acciones recomendadas	Criterio de verificación
Diagnóstico de calidad de datos	Revisar el conjunto de datos de entrenamiento para detectar valores faltantes, duplicados y variables mal registradas. Verificar que los datos cubran diferentes periodos, lotes y condiciones operativas del proceso productivo.	El conjunto de datos debe tener menos del 5% de valores faltantes y ser representativo de al menos los últimos 12 meses de operación.
Identificación de sesgos	Aplicar la matriz de identificación (Tabla 2) para clasificar qué tipo de sesgo está presente: exclusión, medición o muestreo. Documentar	Cada sesgo identificado debe quedar registrado con su tipo, origen,

Fase	Acciones recomendadas	Criterio de verificación
	las variables afectadas y el proceso productivo relacionado.	proceso afectado y nivel de impacto (alto, medio o bajo).
Evaluación del impacto	Analizar cómo los sesgos detectados afectan el desempeño del modelo (precisión de predicciones, errores en inventario, fallas no detectadas en mantenimiento). Comparar resultados con y sin corrección de sesgos cuando sea posible.	Se debe cuantificar el impacto de al menos un sesgo en términos de costos operativos o precisión del modelo.
Acciones de mitigación	Implementar técnicas como imputación de datos faltantes, recalibración de sensores, ampliación de la muestra histórica y estandarización de registros manuales. Aplicar validación cruzada para evaluar la mejora del modelo.	Las acciones aplicadas deben mejorar la precisión del modelo en al menos un 10% respecto al modelo original con sesgos.
Seguimiento y monitoreo	Establecer revisiones periódicas de la calidad de los datos y del desempeño del modelo de IA. Definir indicadores clave de seguimiento como tasa de error del modelo, porcentaje de datos	Se deben realizar revisiones al menos una vez por trimestre o cada vez que se

Fase	Acciones recomendadas	Criterio de verificación
	faltantes y frecuencia de calibración de instrumentos.	actualice el modelo de IA con nuevos datos.

Nota. La herramienta metodológica presentada fue construida a partir de la revisión de buenas prácticas documentadas en la literatura especializada sobre gestión de datos e inteligencia artificial. Su aplicación está orientada a empresas del sector de manufactura y la industria de alimentos que estén implementando o planeen implementar sistemas de IA en sus procesos productivos.

Conclusiones

El análisis realizado evidencia que los sesgos en los datos constituyen uno de los principales factores que limitan el desempeño de los modelos de inteligencia artificial en el sector productivo. Sesgos como la exclusión de variables relevantes, errores de medición y muestras no representativas afectan directamente la precisión de las predicciones, generando decisiones operativas ineficientes en áreas críticas como la planificación de la producción, el mantenimiento predictivo y la gestión de inventarios.

Los sesgos algorítmicos más frecuentes en procesos productivos son el sesgo de exclusión, el sesgo de medición y el sesgo de muestreo. La revisión bibliográfica realizada muestra que estos tres tipos aparecen documentados de manera recurrente en la literatura especializada (Mehrabi et al., 2021; Ntoutsis et al., 2020; Pessach & Shmueli, 2022), y su presencia puede comprometer significativamente la precisión de los modelos de IA aplicados a manufactura.

El impacto de los sesgos no proviene de los algoritmos en sí mismos, sino de problemas en la calidad y gobernanza de los datos utilizados para entrenarlos. Este hallazgo, corroborado por Cai y Zhu (2021) y Gudivada et al. (2021), indica que las empresas deben priorizar la gestión de datos antes de invertir en soluciones avanzadas de analítica o automatización.

En el contexto de las políticas de transformación digital, Colombia se encuentra aún en proceso de adopción de las tecnologías propias de la Industria 4.0. De acuerdo con estudios del DNP (2022) y del Observatorio de Economía Digital (2022), la industria manufacturera colombiana presenta niveles de inversión en IA que no superan el umbral necesario para una transformación digital plena, lo que sitúa al país en una posición de competitividad inferior

respecto a la región. Este panorama hace especialmente relevante la generación de herramientas metodológicas adaptadas al contexto nacional.

No existen políticas ni marcos metodológicos suficientes y adaptados al contexto colombiano que permitan a las empresas del sector productivo identificar y mitigar sesgos de manera sistemática. Si bien el MinTIC (2023) y el DNP (2022) han publicado lineamientos éticos generales, estos no ofrecen herramientas prácticas para su implementación en entornos manufactureros de pequeña y mediana escala.

La responsabilidad de garantizar una inteligencia artificial confiable y libre de sesgos no recae únicamente en las empresas, sino que requiere también el compromiso del Estado mediante políticas públicas, marcos regulatorios claros e incentivos para la inversión en transformación digital responsable. A partir de estos hallazgos, se propone la Herramienta Metodológica para la Identificación y Mitigación de Sesgos Algorítmicos (HIMSA) como una contribución práctica y replicable que permite a las empresas del sector pasar de una adopción de IA reactiva a una adopción responsable, sistemática y orientada a la mejora real de los procesos productivos.

Recomendaciones

Se recomienda que las organizaciones del sector productivo implementen marcos formales de gestión y gobernanza de datos, orientados a garantizar la calidad, integridad y representatividad de la información utilizada en los sistemas de inteligencia artificial. Dichos marcos deben incluir procedimientos estandarizados para la recolección de datos, calibración periódica de instrumentos de medición, validaciones sistemáticas y auditorías de calidad, con el fin de reducir la presencia de sesgos que puedan afectar la confiabilidad de los modelos y la toma de decisiones operativas.

Antes de la puesta en marcha de modelos de inteligencia artificial en entornos productivos, se recomienda realizar evaluaciones previas de sesgo en los conjuntos de datos de entrenamiento, así como pruebas de sensibilidad que permitan analizar el impacto de dichos sesgos en los resultados del modelo. Adicionalmente, es pertinente incorporar mecanismos de monitoreo continuo del desempeño del sistema, con el objetivo de identificar desviaciones, corregir inconsistencias en los datos y mejorar progresivamente la precisión de las predicciones.

Se sugiere que futuros estudios profundicen en análisis empíricos mediante la aplicación de metodologías cuantitativas, incorporando indicadores de desempeño productivo tales como costos operativos, tiempos de parada y niveles de eficiencia. Asimismo, sería pertinente ampliar el alcance del estudio hacia empresas manufactureras colombianas, lo que permitiría generar evidencia contextualizada sobre el impacto real de los sesgos en los sistemas de inteligencia artificial y fortalecer la validez externa de los resultados obtenidos.

Referencias Bibliográficas

- Alcácer, V., & Cruz-Machado, V. (2019). Scanning the Industry 4.0: A literature review on technologies for manufacturing systems. *Engineering Science and Technology, International Journal*, 22(3), 899–919. <https://doi.org/10.1016/j.jestch.2019.01.006>
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities* (2nd ed.). MIT Press.
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610–623. <https://doi.org/10.1145/3442188.3445922>
- Bouzembrak, Y., Klüche, M., Camenzuli, A., & Marvin, H. J. P. (2021). Internet of Things in food safety: Literature review and a bibliometric analysis. *Trends in Food Science & Technology*, 94, 54–64. <https://doi.org/10.1016/j.tifs.2019.11.002>
- Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. *Proceedings of Machine Learning Research*, 81, 1–15.
- Cai, L., & Zhu, Y. (2021). The challenges of data quality and data quality assessment in the big data era. *Data Science Journal*, 14, 2. <https://doi.org/10.5334/dsj-2015-002>

- Canca, D. (2020). Operationalizing AI ethics principles. *Communications of the ACM*, 63(12), 18–21. <https://doi.org/10.1145/3430368>
- Chouldechova, A., & Roth, A. (2020). A snapshot of the frontiers of fairness in machine learning. *Communications of the ACM*, 63(5), 82–89. <https://doi.org/10.1145/3376898>
- Costa, A. I. A., Jongen, W. M. F., & Vieira, E. A. (2021). Artificial intelligence in the food industry: Applications, benefits and challenges. *Comprehensive Reviews in Food Science and Food Safety*, 20(2), 1535–1564.
- Departamento Nacional de Planeación (DNP). (2022). *Política nacional de confianza y seguridad digital (Documento CONPES 3995)*. Gobierno de Colombia.
- Dignum, V. (2022). *Responsible artificial intelligence: How to develop and use AI in a responsible way*. Springer.
- Drath, R., & Horch, A. (2021). Industrie 4.0: Hit or hype? *IEEE Industrial Electronics Magazine*, 8(2), 56–58. <https://doi.org/10.1109/MIE.2014.2312079>
- Ferrer, X., van Nuenen, T., Such, J. M., Coté, M., & Criado, N. (2021). Bias and discrimination in AI: A cross-disciplinary perspective. *IEEE Technology and Society Magazine*, 40(2), 72–80. <https://doi.org/10.1109/MTS.2021.3056235>
- Gudivada, V., Apon, A., & Ding, J. (2021). Data quality considerations for big data and machine learning: Going beyond data cleaning and transformations. *International Journal on Advances in Software*, 10(1–2), 1–20.
- Jagtap, S., Bhatt, C., Thik, J., & Rahimifard, S. (2021). Monitoring potato waste in food manufacturing using image processing and blockchain. *Sustainability*, 13(10), 5516. <https://doi.org/10.3390/su13105516>

- Jobin, A., Ienca, M., & Vayena, E. (2020). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1(9), 389–399. <https://doi.org/10.1038/s42256-019-0088-2>
- Lasi, H., Fettke, P., Kemper, H. G., Feld, T., & Hoffmann, M. (2020). Industry 4.0. *Business & Information Systems Engineering*, 6(4), 239–242. <https://doi.org/10.1007/s12599-014-0334-4>
- Liao, Y., Deschamps, F., Loures, E. F. R., & Ramos, L. F. P. (2020). Past, present and future of Industry 4.0: A systematic literature review and research agenda proposal. *International Journal of Production Research*, 55(12), 3609–3629. <https://doi.org/10.1080/00207543.2017.1308576>
- Marvin, H. J. P., Janssen, E. M., Bouzembrak, Y., Hendriksen, P. J. M., & Staats, M. (2020). Big data in food safety: An overview. *Critical Reviews in Food Science and Nutrition*, 57(11), 2286–2295. <https://doi.org/10.1080/10408398.2016.1257481>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 1–35. <https://doi.org/10.1145/3457607>
- Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC). (2023). *Marco ético para la inteligencia artificial en Colombia*. Ministerio TIC.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2021). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2), 2053951716679679. <https://doi.org/10.1177/2053951716679679>
- Ntoutsis, E., Fafalios, P., Gadiraju, U., Iosifidis, V., Nejdil, W., Vidal, M.-E., Ruggieri, S., Turini, F., Papadopoulos, S., Krasanakis, E., Kompatsiaris, I., Kinder-Kurlanda, K., Wagner, C., Karimi, F., Fernández, M., Alani, H., Berendt, B., Kruegel, T., Heinze, C., ... Staab, S.

- (2020). Bias in data-driven artificial intelligence systems. *WIREs Data Mining and Knowledge Discovery*, 10(3), e1356. <https://doi.org/10.1002/widm.1356>
- Observatorio de Economía Digital de Colombia. (2022). *Informe de adopción tecnológica en el sector manufacturero colombiano*. MinTIC.
- Oztemel, E., & Gursev, S. (2020). Literature review of Industry 4.0 and related technologies. *Journal of Intelligent Manufacturing*, 31(1), 127–182. <https://doi.org/10.1007/s10845-018-1433-8>
- Pessach, D., & Shmueli, E. (2022). A review on fairness in machine learning. *ACM Computing Surveys*, 55(3), 1–44. <https://doi.org/10.1145/3494672>
- Pipino, L. L., Lee, Y. W., & Wang, R. Y. (2022). Data quality assessment. *Communications of the ACM*, 45(4), 211–218. <https://doi.org/10.1145/505248.506010>
- Provost, F., & Fawcett, T. (2013). *Data science for business*. O'Reilly Media.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Sánchez Torres, J. M., & Ordóñez Ordóñez, J. O. (2020). Inteligencia artificial en Colombia: Estado del arte y perspectivas. *Ingeniería y Competitividad*, 22(2), e9311. <https://doi.org/10.25100/iyc.v22i2.9311>
- Sidi, F., Shariat Panahy, P. H., Affendey, L. S., Jabar, M. A., Ibrahim, H., & Mustapha, A. (2020). Data quality: A survey of data quality dimensions. *IEEE Conference on Information Retrieval and Knowledge Management*, 300–304.

Apéndices

Apéndice A

Herramienta Metodológica para la Identificación y Mitigación de Sesgos Algorítmicos (HIMSA)

– *Versión de Uso Práctico*

PASO 1	<p>Diagnóstico de Calidad de Datos</p> <p>Revisa el conjunto de datos buscando valores faltantes, duplicados y registros mal capturados. Verifica que los datos cubran al menos los últimos 12 meses de operación y representen diferentes condiciones del proceso.</p>
	<p><i>✓Criterio: < 5% valores faltantes - Cobertura mínima 12 meses</i></p>
PASO 2	<p>Identificación del Tipo de Sesgo</p> <p>Aplica la Matriz de Sesgos (Tabla 2) para determinar si el problema es de exclusión, medición o muestreo. Documenta el origen del sesgo, las variables afectadas y el proceso productivo relacionado.</p>
	<p><i>✓Criterio: Registro completo: tipo, origen, proceso afectado, impacto (A/M/B)</i></p>
PASO 3	<p>Evaluación del Impacto</p> <p>Analiza cómo el sesgo detectado afecta la precisión del modelo y las decisiones operativas. Compara resultados con y sin corrección del sesgo cuando sea posible.</p>
	<p><i>✓Criterio: Cuantificar impacto en costos operativos o precisión del modelo</i></p>
Acciones de Mitigación	

Nota. Esta herramienta es replicable en el sector manufacturero y la industria de alimentos en Colombia. Construida a partir de la revisión bibliográfica realizada en las fases 1 y 2 del proceso metodológico.