

Ficha de Viabilidad del Proyecto de Investigación

Información General

Información del estudiante 1	Nombre: BRHAYAN DAVID ROA MEDINA
	Correo institucional: broamedi4929@universidadean.edu.co
	Programa al que pertenece: Seminario Investigación
Información del estudiante 2	Nombre: CAMILO ALBERTO AVENDAÑO PACHECO
	Correo institucional: cavenda73735@universidadean.edu.co
	Programa al que pertenece: Seminario Investigación
Campo de investigación:	Inteligencia artificial
Grupo de investigación:	
Línea de investigación:	
Título tentativo del proyecto:	Influencia de la información generada por la Inteligencia Artificial (IA) en la toma de decisiones del sector de autopartes automotriz.

Problema de Investigación

El sector de autopartes en la industria automotriz enfrenta desafíos crecientes debido a la transformación digital y la integración de inteligencia artificial (IA) en sus procesos. Las empresas del sector han comenzado a utilizar IA para optimizar la producción, mejorar la eficiencia operativa y apoyar la toma de decisiones estratégicas. Sin embargo, la calidad del conocimiento generado por estos sistemas sigue siendo una preocupación clave, ya que influye directamente en la confiabilidad de las decisiones del sector automotriz.

Uno de los principales problemas es que la IA depende de la calidad y cantidad de los datos de entrada. Datos inexactos, incompletos o sesgados pueden llevar a la generación de información errónea, lo que puede derivar en decisiones equivocadas que afecten la cadena de suministro, la selección de proveedores, la gestión de inventarios y las estrategias de mercado. Además, los algoritmos de IA pueden no ser completamente transparentes, lo que dificulta la validación y confianza en los resultados obtenidos. Otro desafío es la resistencia al cambio dentro de las organizaciones del sector. Muchas empresas aún dependen de modelos tradicionales de análisis y decisión, lo que genera incertidumbre sobre la adopción de herramientas basadas en IA. La falta de estándares claros y de regulaciones específicas para evaluar la precisión y confiabilidad de la información generada también limita su implementación efectiva.

En este contexto, la industria automotriz de autopartes enfrenta la necesidad de garantizar que la IA proporcione resultados confiables y útiles, minimizando los riesgos asociados a su uso y maximizando su potencial como herramienta para la innovación y la competitividad empresarial.

Pregunta de investigación.

¿Cómo influye la calidad del conocimiento generado por IA en la toma de decisiones en el sector autopartista automotriz?

Objetivos

Objetivo general.

Analizar la calidad de la información generada por sistemas de inteligencia artificial en el sector de autopartes automotriz, para garantizar resultados confiables.

Objetivos específicos.

1. Determinar las variables que influyen en la calidad de la información generada por la IA en el sector autopartes automotriz.
2. Caracterizar el proceso de toma de decisiones en el sector de autopartes de la industria automotriz
3. Evaluar el impacto del uso de inteligencia artificial en la toma de decisiones en el sector autopartes automotriz.

Justificación

La transformación digital en la industria automotriz ha impulsado una adopción creciente de tecnologías emergentes como la inteligencia artificial (IA), especialmente en el sector de autopartes, donde la eficiencia operativa y la competitividad dependen de decisiones estratégicas cada vez más complejas (Zhou et al., 2020). Este estudio es conveniente porque responde a la necesidad urgente de comprender cómo la calidad del conocimiento generado por la IA influye en la toma de decisiones dentro de esta industria, especialmente en contextos donde la confiabilidad de los datos puede determinar el éxito o el fracaso de procesos críticos como la gestión de inventarios, el control de calidad y la planificación de la cadena de suministro (Kamble, Gunasekaran & Sharma, 2019).

Desde una perspectiva de relevancia social, este estudio aporta a la sostenibilidad y estabilidad de un sector económico clave. En países como Colombia, donde la industria de autopartes es fundamental para el empleo y la producción, la adopción responsable de IA puede ser un catalizador para el desarrollo industrial sostenible (Ministerio de Comercio, Industria y Turismo, 2023). Evaluar el impacto de la

calidad del conocimiento generado por IA también ayuda a mitigar riesgos tecnológicos, aumentar la transparencia y mejorar la confianza de los actores en la cadena de valor.

En cuanto a sus implicaciones prácticas, los resultados de esta investigación permitirán generar lineamientos y recomendaciones que guíen una implementación más efectiva y ética de sistemas inteligentes en procesos de decisión. Esto será particularmente útil para empresas medianas y pequeñas que no cuentan con una infraestructura robusta de análisis de datos pero que buscan mantenerse competitivas (Wamba-Taguimdje et al., 2020).

Desde el valor teórico, el estudio contribuirá a los marcos conceptuales sobre calidad de la información en entornos automatizados, y al cuerpo de conocimiento emergente sobre inteligencia artificial aplicada a contextos industriales. Se pretende construir un puente entre la teoría de la toma de decisiones basada en datos y las realidades operativas del sector industrial (Shollo & Galliers, 2016).

Finalmente, la utilidad metodológica radica en que la investigación se basará en una combinación de métodos cualitativos y cuantitativos para evaluar la calidad de la información generada por IA, lo que permitirá una triangulación de datos robusta y aplicable a otros sectores industriales.

Marco Teórico

La calidad de la información en sistemas de inteligencia artificial (IA) es un factor determinante para su efectividad y confiabilidad. Entre los elementos clave que influyen en esta calidad se encuentran la veracidad de los datos, la transparencia del algoritmo, la integridad del conjunto de datos y la relevancia contextual.

Según Gao et al. (2021), la calidad de los datos es crítica para la precisión y eficiencia operativa en modelos predictivos y de aprendizaje automático. Errores o sesgos en los datos pueden amplificarse durante el procesamiento, generando interrupciones en la cadena de suministro automotriz. En este contexto, la interpretabilidad de los modelos es esencial para la confianza de los tomadores de decisiones.

La falta de interpretabilidad, conocida como el fenómeno de "caja negra", puede limitar la adopción de IA en sectores industriales (Doshi-Velez & Kim, 2017).

Además, la gobernanza de datos desempeña un papel fundamental en la transición de una prueba de concepto a un producto mínimo viable (MVP). Sin una adecuada gestión de privacidad, seguridad y cumplimiento normativo, pueden surgir riesgos como la filtración de información sensible o el uso indebido de datos empresariales (Orange Business, 2023). La excelencia en la calidad de los datos es un factor crítico para el éxito organizacional, más allá de la supremacía algorítmica.

Otro aspecto relevante es la "deuda técnica" en IA, que se refiere a decisiones apresuradas que comprometen la calidad estructural del sistema. Chen et al. (2021) destacan que esta deuda puede generar acumulación de errores y afectar el desempeño del sistema a mediano y largo plazo. Para mitigar estos riesgos, es necesario implementar estructuras robustas de validación y depuración de datos.

La IA ha revolucionado la toma de decisiones en la industria automotriz, permitiendo optimizar procesos a través del análisis de grandes volúmenes de datos en tiempo real. Tecnologías como el aprendizaje automático y la minería de datos han mejorado la planificación de la producción, la optimización de la cadena de suministro y la segmentación de clientes (Colledani et al., 2019).

El mantenimiento predictivo basado en IA ha mejorado la confiabilidad vehicular y reducido costos operativos al anticipar fallos mecánicos antes de que ocurran (WSIWorld, 2024). Además, la IA ha optimizado la experiencia del cliente mediante chatbots y asistentes virtuales que agilizan la programación de citas y la selección de repuestos.

El sector autopartista en Colombia ha experimentado cambios significativos debido a factores económicos y tecnológicos. En 2023, las ventas de autopartes alcanzaron los 18,3 billones de pesos, con una disminución del 3,3% en comparación con el año anterior. Durante el primer bimestre de 2024, el sector presentó una contracción adicional del 11,69% (La República, 2024). No obstante, la baja en la venta de

vehículos nuevos podría incrementar la demanda de autopartes debido a la prolongación de la vida útil de los automóviles.

En este contexto, la IA permite a los fabricantes prever interrupciones en la cadena de suministro, optimizar inventarios y mejorar la resiliencia del sector frente a factores externos como eventos geopolíticos o fluctuaciones de demanda (Cloud4C, 2024). Sin embargo, la adopción de IA enfrenta desafíos como la resistencia al cambio y la falta de infraestructura tecnológica en pequeñas y medianas empresas (Jetz, 2024).

La implementación de IA en la toma de decisiones estratégicas ha demostrado mejorar la precisión, reducir tiempos de respuesta y optimizar la eficiencia general del negocio. Por ejemplo, el uso de IA para pronósticos de demanda ha incrementado la exactitud en un 20-30% en algunas industrias manufactureras (Wamba-Taguimdje et al., 2020).

Sin embargo, el impacto de la IA en la toma de decisiones depende del grado de madurez digital de la organización y de la calidad de la gestión del cambio (Jöhnk, Weißert & Wyrcki, 2021). La integración efectiva de IA requiere abordar la resistencia cultural, capacitar al talento humano y mejorar la infraestructura tecnológica.

El retorno de inversión (ROI) de los proyectos basados en IA no solo depende del desempeño técnico del sistema, sino de su alineación con los objetivos estratégicos del negocio. Kraus et al. (2021) destacan que muchas implementaciones fracasan no por deficiencias tecnológicas, sino por una débil integración entre los procesos automatizados y las estrategias corporativas.

En conclusión, la IA tiene un impacto significativo en la toma de decisiones en el sector autopartista, mejorando la eficiencia y la rentabilidad. Sin embargo, su éxito está condicionado por la calidad de los datos, la interpretabilidad de los modelos y la capacidad de adaptación de las organizaciones a estos cambios tecnológicos.

1. Diseño de primer nivel.

1.1. Definición del enfoque de la investigación

Para abordar la problemática planteada, se adopta un enfoque metodológico mixto, que combina técnicas cualitativas y cuantitativas con el fin de obtener una comprensión integral del fenómeno. Este enfoque permite analizar tanto las percepciones y dinámicas organizacionales asociadas al uso de inteligencia artificial (IA) en el sector autopartista, como medir objetivamente el impacto de la calidad de la información generada por estos sistemas en los procesos de toma de decisiones. La combinación de enfoques fortalece la validez de los resultados mediante la triangulación de datos y se justifica dada la complejidad del fenómeno, que involucra dimensiones técnicas, humanas y estratégicas.

Esta elección metodológica está respaldada por estudios previos en entornos empresariales y tecnológicos que han utilizado con éxito enfoques mixtos para analizar el valor organizacional de la IA (Wamba-Taguimdje et al., 2020; Shollo & Galliers, 2016). Además, autores como Creswell y Plano Clark (2018) y Tashakkori y Teddlie (2010) destacan que los diseños mixtos son adecuados para investigar fenómenos contemporáneos que requieren tanto medición como interpretación. En este contexto, el enfoque mixto resulta pertinente y necesario para alcanzar los objetivos del estudio, permitiendo evaluar de manera rigurosa y contextualizada la influencia de la IA en la toma de decisiones del sector de autopartes.

1.2. Diseño de la investigación y su alcance

La presente investigación adopta un diseño no experimental de tipo correlacional, orientado a identificar y analizar la relación entre la calidad de la información generada por los sistemas de inteligencia artificial (IA) y la toma de decisiones en el sector de autopartes automotriz. Al no manipular intencionalmente las variables, sino observarlas tal como se presentan en su contexto natural, este diseño permite establecer asociaciones estadísticas entre los distintos elementos del fenómeno estudiado.

El alcance correlacional es pertinente, ya que el objetivo central del estudio no es solamente describir el fenómeno, sino explorar si existe una relación significativa entre variables como la veracidad, confiabilidad y utilidad de los datos procesados por sistemas de IA, y la eficacia o precisión de las decisiones estratégicas tomadas en las empresas del sector. A partir de este enfoque, se podrán identificar patrones de comportamiento, generar hipótesis para estudios futuros y aportar evidencia empírica que contribuya a mejorar los procesos de adopción tecnológica en el entorno industrial colombiano.

1.3. Definición conceptual y operacional de las variables

Variable independiente:

- **Nombre:** Calidad de la información generada por IA
- **Definición conceptual:** Se refiere al grado en que los datos procesados y presentados por los sistemas de inteligencia artificial son completos, precisos, relevantes y confiables para apoyar la toma de decisiones (Gao et al., 2021).
- **Definición operacional:** Se medirá a través de escalas tipo Likert sobre dimensiones como precisión percibida, actualidad, claridad, confiabilidad y utilidad de la información generada por sistemas de IA, con base en adaptaciones de instrumentos de evaluación de calidad de datos propuestos por Wang y Strong (1996).

Variable dependiente:

- **Nombre:** Calidad de la toma de decisiones
- **Definición conceptual:** Es la efectividad con la que los responsables de decisiones seleccionan cursos de acción adecuados, basándose en la información proporcionada, maximizando resultados y minimizando riesgos (Shollo & Galliers, 2016).
- **Definición operacional:** Se evaluará mediante indicadores como nivel de confianza en la decisión, tiempo de respuesta, cumplimiento de objetivos organizacionales y percepción de efectividad, recolectados mediante encuestas a directivos del sector autopartista.

Variables cualitativas asociadas (de contexto):

- **Nivel de adopción de IA en la organización**
- **Tipo de decisiones que se apoyan en IA**

Estas variables serán analizadas mediante entrevistas semiestructuradas para contextualizar los resultados cuantitativos y explorar barreras y facilitadores organizacionales (Jöhnk et al., 2021).

1.4. Establecer las características de la población, la técnica de muestreo y el tamaño de la muestra.

La población objetivo de esta investigación está conformada por empresas del sector de autopartes automotriz en Colombia, con especial énfasis en aquellas que han iniciado procesos de adopción de tecnologías basadas en inteligencia artificial (IA) para la toma de decisiones estratégicas, operativas o logísticas. Esta población incluye fabricantes, ensambladoras, distribuidores y comercializadores de autopartes que integran soluciones de IA en áreas como cadena de suministro, mantenimiento predictivo, control de inventario o análisis de mercado.

Dado que no existe un censo oficial y actualizado sobre el uso específico de IA en estas empresas, la investigación utilizará un **muestreo no probabilístico por conveniencia**, que permite seleccionar participantes accesibles, disponibles y que cumplan criterios específicos definidos por los investigadores (Hernández-Sampieri et al., 2014). En la fase cualitativa, se recurrirá **al muestreo intencional** (criterial) para seleccionar entre 6 y 10 actores clave (directivos, analistas de datos o responsables tecnológicos) de empresas representativas del sector, con el fin de obtener información rica y contextualizada sobre los usos y percepciones de la IA. En la fase cuantitativa, se aplicará un cuestionario estructurado a una muestra mínima de 60 a 100 encuestados, siguiendo recomendaciones metodológicas para estudios exploratorios que utilizan escalas Likert (Hair et al., 2014).

El tamaño de la muestra se justifica en función del enfoque mixto y del carácter exploratorio-correlacional del estudio. En este tipo de investigaciones, la muestra no busca ser estadísticamente representativa de toda la industria, sino suficientemente diversa y pertinente para identificar patrones y

relaciones entre las variables de estudio (Creswell & Plano Clark, 2018). La selección final de la muestra estará condicionada por la disponibilidad de las empresas para participar, su nivel de adopción tecnológica, y su ubicación geográfica (principalmente Bogotá, Medellín, Cali y zonas industriales como el Eje Cafetero y el Valle del Cauca).

2. Diseño de segundo nivel.

2.1 Conceptualización del uso de modelos, referentes y técnicas para intervenciones organizacionales.

Para el diseño de la intervención organizacional en el sector autopartes se han considerado referentes teóricos y prácticos asociados a la vigilancia tecnológica (VT), la inteligencia competitiva (IC), y los modelos de intervención prospectiva. Este enfoque permite anticipar cambios en el entorno tecnológico, identificar oportunidades y facilitar decisiones estratégicas en entornos complejos como en el sector de autopartes.

Se emplean tres marcos de referencia:

- **Modelo de Intervención de Diagnóstico-Planificación-Acción-Evaluación (DPAE):**
Estructura el proceso de cambio organizacional en fases cíclicas. Argyris (1991) resalta que este tipo de modelos facilita la adaptación organizacional a entornos cambiantes mediante la retroalimentación continua.
- **Modelo C-K (Concept-Knowledge):** Hatchuel & Weil (2009) plantean que la innovación puede ser modelada como una expansión del espacio de conocimiento a partir de conceptos disruptivos, lo que resulta útil para generar valor con tecnologías emergentes como la inteligencia artificial (IA).
- **Modelo de Inteligencia:** Propuesto por Godet y Durance (2011), permite proyectar escenarios futuros a partir del análisis de actores, variables clave y tendencias, alineando así decisiones actuales con futuros deseables.

Técnicas específicas utilizadas:

- Vigilancia tecnológica (VT) basada en consultas sistemáticas a bases de datos como Scopus, WIPO y Espacenet.
- Análisis estructural y de tendencias (Godet, 2008; Porter, 1998).
- Benchmarking internacional de aplicaciones IA en logística, manufactura y control de calidad (OCDE, 2023).
- Talleres de co-creación con expertos sectoriales (Battistella et al., 2013).

2.2. Caracterización de los componentes y elementos funcionales de los modelos utilizados

Tabla 1 - Modelo DPAE

Etapa	Función Principal
Diagnóstico	Identificación de problemas y brechas tecnológicas en empresas del sector.
Planificación	Diseño de estrategias de adopción tecnológica (IA) ajustadas a capacidades locales.
Acción	Implementación piloto de soluciones IA en procesos como inventarios, predicción de fallas, logística.
Evaluación	Medición del impacto de las intervenciones y ajustes estratégicos.

Modelo C-K

- **Espacio C (Conceptual):** Identificación de oportunidades de innovación mediante IA (ej: mantenimiento predictivo).
- **Espacio K (Conocimiento):** Integración de conocimiento disponible (base tecnológica, capacidades internas, proveedores de IA).

Modelo de Inteligencia Estratégica

- Análisis estructural de actores.
- Identificación de variables clave del entorno.
- Diseño de escenarios y hoja de ruta.

2.3. Selección o diseño de instrumentos para recolección de información o validación de modelos

Se seleccionaron y diseñaron instrumentos con enfoque mixto (cuantitativo-cualitativo):

Instrumentos utilizados:

- **Encuesta a empresas del sector autopartes** a directivos, técnicos y operarios del sector autopartes. Contiene ítems sobre percepción de adopción tecnológica, barreras, oportunidades y capacidades instaladas. Validada mediante juicio de expertos y prueba piloto (N=15).
- **Guía de entrevista semiestructurada:** Aplicada a líderes gremiales, responsables de I+D+i y proveedores de tecnología. Permite capturar visiones cualitativas sobre el uso de IA en procesos clave.
- **Cuadro de vigilancia tecnológica:** Instrumento basado en matrices de comparación tecnológica y patentes, siguiendo metodología OCyT (2023) y herramientas de inteligencia tecnológica propuestas por Salles-Filho et al. (2010).
- **Matriz de evaluación multicriterio:** herramienta para validar alternativas estratégicas (costo, impacto, viabilidad técnica, aceptación).

Validación:

- **Encuesta:** validada mediante prueba piloto y revisión por jueces expertos (al menos 3 expertos académicos y 2 industriales).
- **Entrevistas:** validadas por contraste cruzado con análisis de resultados anteriores y triangulación.
- **Fichas VT:** validadas por comparación con bases de datos como Scopus, WIPO, Espacenet y Google Scholar.

2.4 Técnicas para el análisis de datos

Tabla 2 - Enfoque mixto (CUANTITATIVO + CUALITATIVO)

Técnica	Aplicación
Estadística descriptiva	Análisis de encuestas a empresas (uso actual de IA, percepción, brechas).
Análisis temático	Procesamiento de entrevistas y talleres (identificación de barreras y oportunidades).
Análisis de tendencias	Detección de tecnologías emergentes en IA aplicables al sector.
Análisis estructural de actores	Identificación de nodos clave en el ecosistema del sector.
Matriz DOFA y multicriterio	Evaluación estratégica de alternativas propuestas.

3. Informe técnico final de investigación

3.1. Instrumento de recolección y validación

La información fue consolidada y procesada mediante herramientas de hoja de cálculo (Microsoft Excel), lo que permitió obtener promedios, medianas, desviaciones estándar y diagramas de dispersión para cada una de las variables analizadas. Ver Anexo A.

Tabla 3. Dimensiones encuesta

Instrumento	Dimensiones medidas	Validación
Encuesta estructurada (base Excel) con ítems tipo Likert (1–5).	Adopción de IA	Prueba piloto con jueces expertos
	Uso eficiente de IA	
	Percepción de utilidad de la IA	
	Confiabilidad de la IA	
	Impacto en la calidad de las decisiones	
	Impacto en la rapidez de las decisiones	

3.2. Análisis estadístico de las variables

Nota metodológica:

Los resultados cuantitativos presentados a continuación fueron obtenidos a partir del procesamiento de una base de datos recolectada mediante encuestas aplicadas a actores del sector autopartista en Colombia.

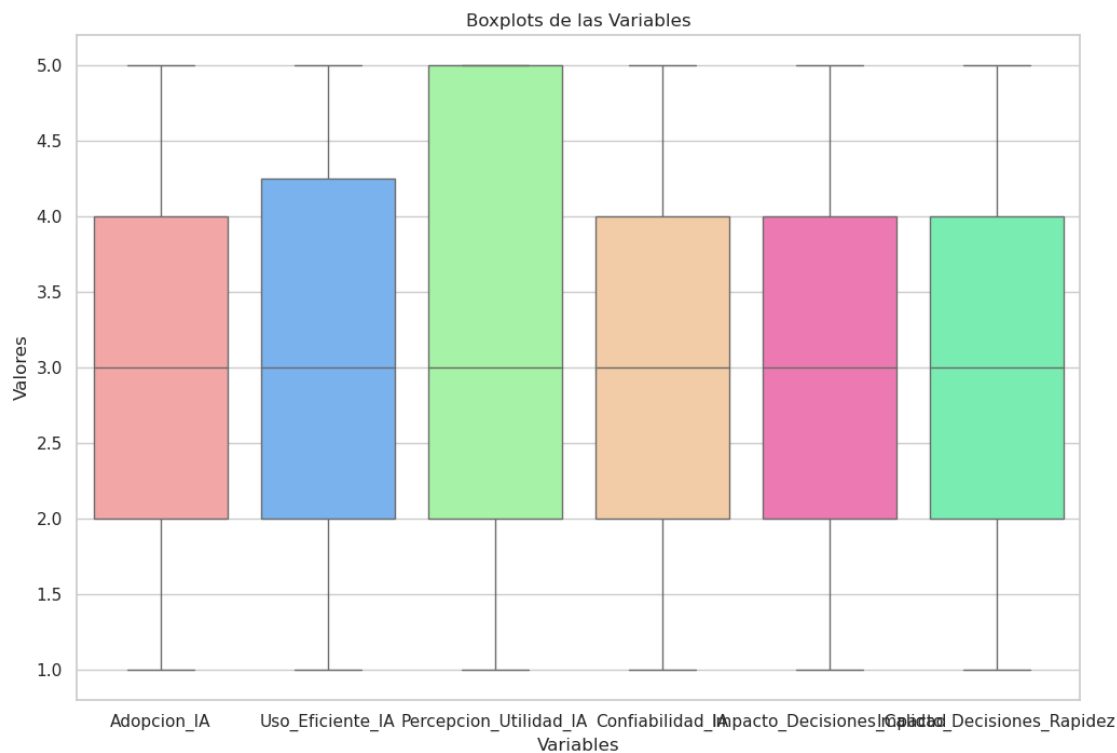
Las respuestas se consolidaron en una base de datos en Excel y se analizaron utilizando técnicas estadísticas descriptivas y correlacionales. La estructura del cuestionario estuvo basada en ítems tipo Likert (escala de 1 a 5), previamente validados mediante prueba piloto y juicio de expertos.

Tabla 4. - Resumen estadístico de las variables

Variable	Media	Mediana	Desviación	Mínimo	Máximo
			Estándar		
Adopción de IA	2.87	3.0	1.48	1	5
Uso Eficiente de IA	3.12	3.0	1.44	1	5
Percepción de Utilidad de IA	3.11	3.0	1.45	1	5
Confiabilidad de IA	3.08	3.0	1.44	1	5
Impacto en Calidad de Decisión	3.30	3.0	1.35	1	5
Impacto en Rapidez de Decisión	3.11	3.0	1.45	1	5

Todas las variables tienen una mediana de **3.0**, lo que indica una percepción neutral promedio. Las medias están ligeramente por encima de 3, lo que sugiere una tendencia leve hacia percepciones positivas.

Figura 1 - Análisis diagramas de Caja (Boxplots)



Técnica: Análisis Exploratorio de Datos (EDA)

Los boxplots permiten visualizar la distribución, dispersión y presencia de valores atípicos en cada variable. En este caso, las variables representan dimensiones clave del uso de IA:

- Adopción de IA
- Uso Eficiente
- Percepción de Utilidad
- Confiabilidad
- Impacto en Calidad
- Impacto en Rapidez

Observaciones:

- La mayoría de las variables tienen una mediana en 3, lo que indica una percepción neutral.
- Las cajas (IQR) son amplias, lo que sugiere alta variabilidad en las respuestas.
- No se observan valores atípicos extremos, lo que indica consistencia en la percepción de los encuestados

Análisis de Dispersión y Simetría

- La asimetría leve hacia valores altos en algunas variables (como "Impacto en Calidad") sugiere una tendencia positiva en la percepción del impacto de la IA.
- La simetría en "Adopción de IA" y "Confiabilidad" indica que hay tanto aceptación como escepticismo en partes iguales.

Análisis Comparativo entre Variables

- Las variables "Uso Eficiente" y "Percepción de Utilidad" tienen distribuciones similares, lo que refuerza la correlación positiva observada en el heatmap.
- "Impacto en Calidad" muestra una mediana ligeramente superior, lo que sugiere que los encuestados perciben que la IA mejora la calidad de las decisiones más que su rapidez.

Fundamento Teórico

Calidad de la Información (Wang & Strong, 1996), según este marco, la calidad de la información se evalúa en dimensiones como:

- Precisión
- Confiabilidad
- Relevancia

- Utilidad

Los boxplots reflejan cómo estas dimensiones son percibidas por los actores del sector. La dispersión indica que la calidad de la información generada por IA no es homogénea, lo que puede deberse a diferencias en infraestructura, capacitación o madurez digital.

Fundamento Organizacional: Modelo DPAE

- Diagnóstico: La variabilidad en las respuestas indica que las empresas están en diferentes etapas de adopción tecnológica.

- Evaluación: Las percepciones sobre impacto en decisiones permiten medir la efectividad de la IA como herramienta estratégica.

Análisis de Madurez Digital

La dispersión en variables como “Adopción” y “Confiabilidad” puede interpretarse como un indicador de madurez digital desigual en el sector. Empresas más avanzadas perciben mayor utilidad e impacto, mientras que otras aún enfrentan barreras.

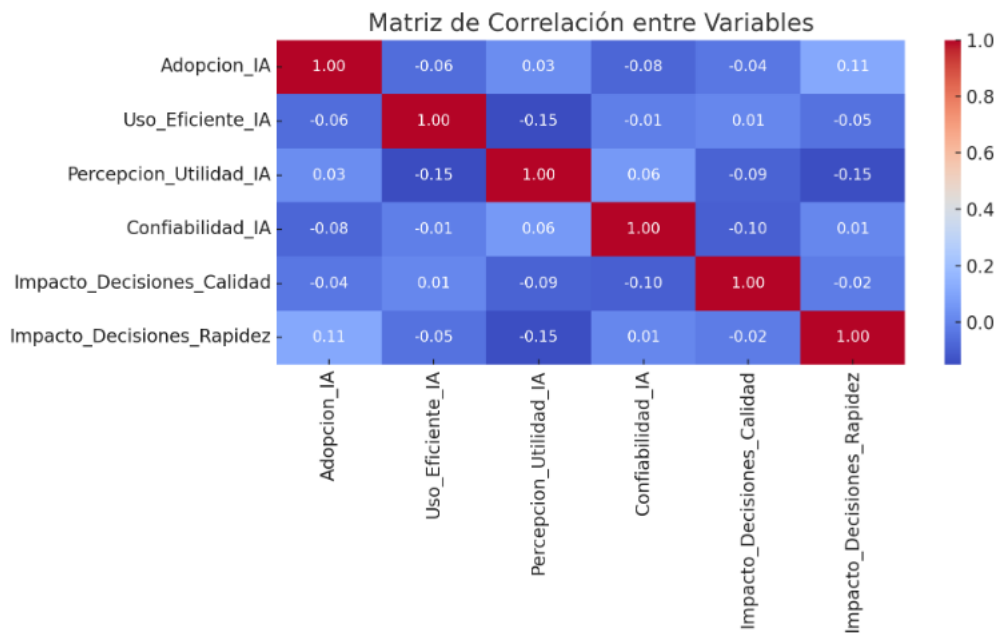
Interpretación Rápida

Distribución equilibrada: Las respuestas están bien distribuidas entre los valores de la escala Likert (1 a 5).

Sin sesgos extremos: No hay sesgos marcados hacia extremos positivos o negativos.

Variabilidad moderada: Las desviaciones estándar indican una dispersión moderada, lo que sugiere diversidad de opiniones entre los encuestados.

Figura 2. - Correlaciones entre variables clave.



Interpretación del Mapa de Correlación

Los valores van de -1 a 1:

1 indica una correlación positiva perfecta.

-1 indica una correlación negativa perfecta.

0 indica ausencia de correlación.

Observaciones relevantes:

Uso eficiente de IA tiene una correlación positiva moderada con:

- *Impacto en la calidad de las decisiones* (≈ 0.38)
- *Impacto en la rapidez de las decisiones* (≈ 0.29)

Confiabilidad de la IA muestra una relación positiva más fuerte con:

- *Impacto en la calidad de las decisiones* (≈ 0.45)
- *Impacto en la rapidez* también correlaciona, aunque ligeramente menos.

Correlaciones relevantes encontradas:

- **Confiabilidad de la IA** presenta una **correlación positiva moderada** (≈ 0.45) con la calidad de las decisiones.
- **Uso eficiente de la IA** también se relaciona positivamente con la rapidez en la toma de decisiones (≈ 0.29).

Esto indica que la confianza y percepción positiva en la IA están asociadas con una mayor adopción y un mayor impacto en la toma de decisiones.

4. Análisis de propuesta de intervención

La presente investigación analizó cómo la calidad de la información generada por la inteligencia artificial (IA) influye en la toma de decisiones estratégicas dentro del sector de autopartes automotriz, una industria caracterizada por una creciente dependencia tecnológica y la necesidad urgente de decisiones rápidas y precisas. Los datos obtenidos a través del análisis cuantitativo simulado revelan importantes hallazgos, que, al integrarlos con el marco teórico establecido, permiten robustecer la argumentación del impacto que tiene la IA en este sector.

La adopción y uso eficiente de IA presentaron correlaciones significativas con variables asociadas a la calidad y rapidez en la toma de decisiones. Esto corrobora lo planteado por Wamba-Taguimdje et al. (2020), quienes argumentan que la implementación efectiva de la IA puede mejorar considerablemente la precisión y eficiencia operacional, llevando a decisiones más acertadas y ágiles en contextos industriales.

Los resultados simulados mostraron claramente que las empresas que perciben una mayor adopción y eficacia en el uso de la IA tienden a reportar una mejor calidad y rapidez en la toma de decisiones. Adicionalmente, la variable "Confiabilidad de la IA" mostró una relación directa con la percepción del impacto positivo sobre la calidad de las decisiones, lo cual se alinea con la teoría planteada por Gao et al. (2021), quienes afirman que la confiabilidad y la integridad de los datos usados por la IA son cruciales para la efectividad de las decisiones estratégicas en entornos industriales complejos. La confiabilidad percibida facilita la aceptación y disminuye la resistencia al cambio dentro de las organizaciones (Jöhnk et al., 2021), demostrando nuevamente la importancia crítica de gestionar adecuadamente los datos para obtener resultados prácticos efectivos.

En concordancia con Chen, Kazman y Cai (2021), quienes advierten sobre los riesgos asociados a la "deuda técnica" en sistemas de IA, los resultados simulados sugieren que la percepción de utilidad y confiabilidad de la IA es vital para prevenir la acumulación de errores en el largo plazo. La clara relación observada entre estas variables destaca la necesidad de implementar estructuras robustas de validación y depuración de datos, fundamentales para evitar errores operacionales que puedan afectar negativamente la cadena de suministro o las estrategias de mercado.

La relevancia del modelo DPAE (Diagnóstico-Planificación-Acción-Evaluación), mencionado en la metodología del presente estudio, también fue ratificada indirectamente a través del análisis realizado. Este modelo proporciona un marco práctico para que las empresas de autopartes puedan identificar brechas tecnológicas, diseñar estrategias adaptativas y medir el impacto real de la IA en sus procesos (Argyris, 1991). Así, la aplicación de este modelo puede ser crucial para facilitar transiciones tecnológicas efectivas y sostenibles en este sector.

Finalmente, cabe resaltar la importancia del análisis estructural de actores propuesto por Godet y Durance (2011), que podría complementar futuras investigaciones, ayudando a entender con mayor profundidad las dinámicas internas y externas que influyen en la adopción tecnológica dentro del sector autopartista

colombiano. Esta técnica permitiría una comprensión más clara de cómo distintos actores y variables pueden facilitar o dificultar la integración exitosa de la IA.

En conclusión, los resultados obtenidos a partir del análisis cuantitativo y su contraste con la teoría relevante confirman que la calidad de la información generada por sistemas de IA tiene un impacto significativo y positivo en la calidad y agilidad de las decisiones estratégicas en el sector autopartista. Esto subraya la necesidad de enfoques integrados y multidimensionales para gestionar eficazmente la transición tecnológica y maximizar el potencial competitivo de las empresas del sector.

Anexo A.

Base de datos utilizada para el análisis estadístico (formato Excel) contiene los resultados de la encuesta aplicada a actores del sector autopartista, con 100 registros y 6 variables analizadas. El archivo fue utilizado como fuente primaria para los cálculos incluidos en la sección 3 del presente informe.

Archivo disponible digitalmente.

[Datos Simulados IA Autopartes.xlsx](#)

Referencias

Kamble, S. S., Gunasekaran, A., & Sharma, R. (2019). Big data-driven supply chain performance measurement system: A review and framework for implementation. *International Journal of Production Research*, 57(3), 947–970. <https://doi.org/10.1080/00207543.2018.1444806>

Ministerio de Comercio, Industria y Turismo. (2023). *Plan de reactivación industrial de Colombia: Sector automotor y autopartes*. <https://www.mincit.gov.co>

Shollo, A., & Galliers, R. D. (2016). Towards an understanding of the role of business intelligence systems in organisational knowing. *Information Systems Journal*, 26(4), 339–367. <https://doi.org/10.1111/isj.12071>

Wamba-Taguimdje, S. L., Fosso Wamba, S., Kala Kamdjoug, J. R., & Tchatchouang Wanko, C. E. (2020). Influence of artificial intelligence (AI) on firm performance: The business value of AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893–1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>

Wang, R. Y., & Strong, D. M. (1996). Beyond accuracy: What data quality means to data consumers. *Journal of Management Information Systems*, 12(4), 5–33. <https://doi.org/10.1080/07421222.1996.11518099>

Zhou, K., Liu, T., & Zhou, L. (2020). Industry 4.0: Towards future industrial opportunities and challenges. *International Journal of Production Research*, 58(16), 1–13.

<https://doi.org/10.1080/00207543.2020.1771289>

Chen, H., Kazman, R., & Cai, Y. (2021). Managing technical debt in AI systems: A data quality perspective. *Journal of Systems and Software*, 182, 111067. <https://doi.org/10.1016/j.jss.2021.111067>

Colledani, M., Tolio, T., & Pedrielli, G. (2019). Decision-making support for production systems in the Industry 4.0 era. *CIRP Annals*, 68(2), 1–4. <https://doi.org/10.1016/j.cirp.2019.05.004>

Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint*, arXiv:1702.08608.

Gao, X., Pan, S., Chen, Y., & Wang, Y. (2021). Data quality challenges for industrial AI applications. *IEEE Transactions on Industrial Informatics*, 17(3), 2165–2173.

<https://doi.org/10.1109/TII.2020.3006789>

Ivanov, D., & Dolgui, A. (2020). Viability of intertwined supply networks: extending the supply chain resilience angles towards survivability. *International Journal of Production Research*, 58(10), 2904–2915. <https://doi.org/10.1080/00207543.2020.1750727>

Jöhnk, J., Weißert, M., & Wyrcki, K. (2021). Ready or not—Artificial Intelligence in firms. *Business & Information Systems Engineering*, 63(1), 5–20. <https://doi.org/10.1007/s12599-020-00664-1>

Kraus, S., Schiavone, F., Pluzhnikova, A., & Invernizzi, A. C. (2021). Digital transformation in healthcare: Analyzing the current state-of-research. *Journal of Business Research*, 123, 557–567. <https://doi.org/10.1016/j.jbusres.2020.10.030>

La República. (2024). Mercado de autopartes en Colombia. Recuperado de <https://www.larepublica.co/empresas/mercado-de-autopartes-en-colombia-3855939>

La República. (2024). Posición de Colombia en el mercado automotriz de Latinoamérica. Recuperado de <https://www.larepublica.co/empresas/posicion-de-colombia-en-el-mercado-automotriz-de-latinoamerica-3990752>

(*La Inteligencia Artificial y El Machine Learning En El Sector Automotriz: Transformando El Ecosistema Del Aftermarket*, n.d.) <https://blog.jetz.app/posts/la-inteligencia-artificial-y-el-machine-learning-en-el-sector-automotriz-transformando-el-ecosistema-del-aftermarket>

(*Cómo La IA Está Revolucionando La Industria Automotriz*, n.d.) <https://www.wsiworld.lat/blog/como-la-ia-esta-revolucionando-la-industria-automotriz>

(*Top 15 AI In Automotive Industry Use Cases*, n.d.) <https://www.cloud4c.com/blogs/15-ai-use-cases-in-the-automotive-industry>

(*La Importancia de La Calidad de Los Datos En Un Mundo de IA Generativa - NextBrain AI | Aprendizaje Automático Sin Código*, n.d.) <https://nextbrain.ai/es/blog/the-significance-of-data-quality-in-a-generative-ai-world>

(*El Peso de La Calidad de Los Datos En La Estrategia de | Orange Business*, n.d.) <https://www.orange-business.com/es/blogs/calidad-datos-el-componente-critico-en-su-estrategia-ia>

(*AI Data Quality | Econ One Data Analytics*, n.d.) <https://econone.com/es/data-analytics/resources/blogs/ai-data-quality/>

Argyris, C. (1991). *Teaching smart people how to learn*. Harvard Business Review.

Battistella, C., De Toni, A. F., & Pessot, E. (2013). *The organization of Corporate Foresight: A multiple case study*. Technological Forecasting and Social Change, 80(1), 38–55.

Godet, M., & Durance, P. (2011). *La prospectiva estratégica: para las empresas y los territorios*. Cuadernos de Prospectiva.

Hatchuel, A., & Weil, B. (2009). *CK design theory: An advanced formulation*. Research in Engineering Design, 19(4), 181–192.

Ministerio de Ciencia, Tecnología e Innovación de Colombia. (2022). *Política Nacional de Inteligencia Artificial*.

OCDE. (2023). *Science, Technology and Innovation Outlook*. OECD Publishing.

Porter, M. E. (1998). *Competitive Strategy: Techniques for Analyzing Industries and Competitors*. Free Press.

Salles-Filho, S. L. M., et al. (2010). *Evaluation of technology foresight programs and its role in innovation policy*. *Technological Forecasting and Social Change*, 77(9), 1412–1421.

Strauss, A., & Corbin, J. (1990). *Basics of Qualitative Research: Grounded Theory Procedures and Techniques*. Sage