



**Percepción de los estudiantes de la Facultad de Ciencias Económicas, de la  
Universidad de Antioquia, sobre la aplicación de herramientas de análisis de datos  
en las ciencias económicas y contables**

Ana María Tabares Agudelo

Juliana Álvarez Moreno

Julián Andrés González Ortiz

Trabajo de grado presentado para optar al título de Contador Público

Asesor

Daniel Cardona Valencia, Magíster (MSc) en Finanzas

Universidad de Antioquia  
Facultad de Ciencias Económicas  
Contaduría Pública  
Medellín, Antioquia, Colombia  
2025

---

Cita

(Tabares Agudelo et al., 2024)

**Referencia**

**Estilo APA 7 (2020)**

Tabares Agudelo, A. M., Álvarez Moreno, J., & González Ortiz, J. A. (2024) *Percepción de los estudiantes de la Facultad de Ciencias Económicas, de la Universidad de Antioquia, sobre la aplicación de herramientas de análisis de datos en las ciencias económicas y contables, 2024* [Trabajo de grado profesional]. Universidad de Antioquia, Medellín, Colombia.

---



**Repositorio Institucional:** <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - [www.udea.edu.co](http://www.udea.edu.co)

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

## Resumen

Este estudio analiza la percepción de los estudiantes de la Facultad de Ciencias Económicas de la Universidad de Antioquia (FCE) sobre el uso de herramientas de análisis de datos en su formación académica y su futura práctica profesional. La creciente importancia de estas herramientas en los campos económico y contable resalta la necesidad de entender cómo los estudiantes valoran su utilidad y aplicabilidad tanto en contextos académicos como laborales. Para ello, se utilizó una encuesta basada en el Modelo de Aceptación de Tecnología (TAM), que evaluó aspectos como la frecuencia de uso, la preparación percibida y la relevancia de estas herramientas. Este enfoque permitió medir la aceptación y disposición de los estudiantes hacia el análisis de datos, identificando factores clave para su adopción, como el apoyo institucional, la motivación para mejorar sus competencias en este ámbito y la percepción de competitividad en el mercado laboral.

*Palabras clave:* análisis de datos, percepción estudiantil, ciencias económicas, competencias tecnológicas, educación superior

### **Abstract**

This study examines the perception of students from the Faculty of Economic Sciences at the University of Antioquia (FCE) regarding the use of data analysis tools in their academic training and future professional practice. The growing importance of these tools in the economic and accounting fields highlights the need to understand how students value their usefulness and applicability in both academic and professional contexts. To achieve this, a survey based on the Technology Acceptance Model (TAM) was used, which assessed aspects such as frequency of use, perceived preparedness, and the relevance of these tools. This approach allowed for the measurement of students' acceptance and willingness toward data analysis, identifying key factors for its adoption, such as institutional support, motivation to improve their competencies in this area, and the perception of competitiveness in the labor market.

*Keywords:* data analysis, student perception, economic sciences, technological competencies, higher education

---

## Introducción

El uso de herramientas de análisis de datos en las ciencias económicas y contables ha ganado una relevancia destacada en los últimos años debido a su capacidad para extraer información significativa de grandes volúmenes de datos, permitiendo identificar patrones y generar estrategias efectivas. Según Saha et al. (2023), el impacto de la IA en el ámbito laboral es significativo, transformando y automatizando tareas, mejorando la precisión en la toma de decisiones y facilitando la detección de fraudes. En el ámbito académico, la necesidad de formar estudiantes que posean competencias tecnológicas y analíticas acordes a las exigencias del mercado laboral ha impulsado a las instituciones de educación superior a integrar estas herramientas en sus currículos (Zhang P, 2024) Así, es comprender cómo los futuros profesionales en ciencias económicas, contabilidad y administración perciben y adoptan estas tecnologías en su formación académica, considerando que su efectividad y aplicabilidad en el entorno profesional dependen, en gran medida, de la aceptación y disposición de los estudiantes hacia su uso. (Lazar y otros, 2020).

La inteligencia artificial, por su parte, se ha consolidado como una tecnología clave en diversos sectores, incluyendo el académico y el laboral. Su impacto trasciende las tareas básicas, ya que permite automatizar procesos, analizar grandes volúmenes de información y tomar decisiones basadas en datos, logrando mejoras significativas en la productividad y la eficiencia. En el ámbito económico, la IA ha facilitado la elaboración de informes financieros, la detección de fraudes y el cumplimiento normativo (Saha y otros, 2023). Sin embargo, su integración también plantea desafíos, especialmente en términos de la preparación de los estudiantes para manejarla y aprovecharla de manera efectiva. Según (Rickardo & Santos, 2023):

*[...] la inteligencia artificial (IA) afectará a casi el 40% de los empleos en todo el mundo, reemplazando algunos y complementando otros. Para aprovechar este potencial, las políticas deben encontrar un fino equilibrio*

Por consiguiente, la implementación de estas herramientas en las ciencias económicas presenta desafíos que pueden influir en la disposición de los estudiantes hacia su adopción. Entre estos desafíos, se encuentran la complejidad percibida en el aprendizaje de estas herramientas y la falta de familiaridad con el entorno digital avanzado, aspectos que pueden generar una actitud de resistencia o indiferencia (Telnova & Popov 2023) Además, la percepción de los estudiantes sobre

la utilidad de estas herramientas en su futura práctica profesional es un factor determinante para su aceptación. Entre las principales barreras, se encuentra la percepción de los estudiantes, quienes en muchos casos consideran que estas herramientas son difíciles de manejar, poco familiares o de utilidad incierta para sus trayectorias profesionales (Reche y otros, 2020). En este contexto, la investigación se ha enfocado en evaluar la disposición de sus estudiantes de Ciencias Económicas hacia el uso de estas tecnologías, identificando factores que influyen en su aceptación y los obstáculos percibidos que podrían limitar su implementación en el currículo.

Estudios como los de Dogan et al. (2023) han demostrado que la familiaridad con las herramientas y la percepción de su utilidad son factores determinantes en su adopción y uso efectivo. Comprender estas percepciones permite a las instituciones educativas diseñar currículos que no solo aborden las necesidades actuales del mercado laboral, sino que también preparen a los estudiantes para enfrentar los desafíos futuros con confianza y competencia.

Este trabajo plantea como hipótesis que la percepción de los estudiantes de FCE sobre el uso de herramientas de análisis de datos, está influenciada la utilidad percibida, la facilidad de uso y la intención de utilizar estas herramientas. Asimismo, se espera que exista una relación importante entre la disposición de los estudiantes para usar herramientas y los recursos que la universidad pone a su alcance, ya que el entorno educativo influye en la motivación y facilidad de aprendizaje. Esta idea se basa en estudios que muestran cómo la percepción de utilidad y acceso promueve el uso de tecnologías, sin que factores como el género o el nivel académico marquen diferencias notables en su frecuencia de uso o efectividad (Lee & Hsieh, 2019).

En este sentido, este trabajo se estructura en varias secciones, comenzando con el planteamiento del problema, donde se detalla la relevancia de las herramientas de análisis de datos en la formación académica de los estudiantes de ciencias económicas y contables. A continuación, el marco teórico expone las principales teorías y estudios que fundamentan el uso de estas herramientas en el contexto educativo. El diseño metodológico describe el enfoque cuantitativo y el diseño de la encuesta aplicada, mientras que la sección de resultados presenta los hallazgos obtenidos a partir del análisis estadístico de los datos. Finalmente, la discusión interpreta los resultados en relación con los objetivos de la investigación, y las conclusiones ofrecen reflexiones finales y recomendaciones para futuras investigaciones en este ámbito.

## **1. Marco teórico**

### **1.1. Conceptos**

El uso de herramientas de análisis de datos en las ciencias económicas se ha convertido en un pilar fundamental para el manejo eficiente de grandes volúmenes de información. Estas herramientas permiten extraer patrones significativos y mejorar la toma de decisiones en contextos complejos. Según Cantabella et al (2019) el análisis de datos en temas financieros muestra cómo la visualización de resultados facilita la comprensión y el descubrimiento de tendencias, modelar comportamientos de mercado y prever dinámicas; así mismo en la contabilidad apoya la automatización de auditorías, la detección de anomalías y el fortalecimiento del control financiero.

En esta misma línea, Prada et al. (2020) destacan la relevancia de la minería de datos y el aprendizaje automático en el desarrollo de herramientas de soporte para la educación superior y en términos contables, el uso de modelos predictivos y análisis automatizados fortalece la capacidad de las organizaciones para adaptarse a cambios regulatorios y económicos, promoviendo una gestión financiera más robusta y adaptativa.

### **1.2. Impacto de la inteligencia artificial en la Educación Superior**

La inteligencia artificial (IA) ha emergido como un componente transformador en la educación superior, impactando significativamente tanto la enseñanza como el aprendizaje. Según Aldowah et al. (2019), las instituciones educativas están aprovechando las capacidades analíticas de la IA para recopilar, procesar e interpretar grandes volúmenes de datos educativos. Permite una toma de decisiones más informada y mejora los sistemas de apoyo estudiantil, además de personalizar las experiencias de aprendizaje para ajustarse a las necesidades individuales. En el ámbito del análisis predictivo, Alkhalil (2021) destaca que la IA es capaz de examinar datos históricos educativos para predecir resultados estudiantiles, identificar a aquellos en riesgo y sugerir intervenciones oportunas. Esta capacidad proactiva para mejorar la retención de estudiantes y asegurar su éxito académico al anticipar y mitigar problemas potenciales antes de que se materialicen.

No obstante, la integración de la IA en la educación superior no está exenta de desafíos. Bahari et al. (2023) señalan preocupaciones éticas y de privacidad relacionadas con el uso de datos y algoritmos de IA, subrayando la importancia de estos problemas para garantizar un uso responsable de la tecnología en los entornos educativos. Alsariera et al. (2022) afirman que, aunque los beneficios son claros, es esencial enfrentar los desafíos éticos, de privacidad y de implementación para aprovechar completamente las ventajas de la IA en la educación superior, asegurando un equilibrio adecuado entre innovación y responsabilidad.

### **1.3. La Inteligencia Artificial y las Normas IFAC: Una Relación en Evolución**

La inteligencia artificial (IA) está revolucionando rápidamente el entorno empresarial, produciendo un impacto profundo en el campo de la contabilidad. A medida que las organizaciones integran sistemas y herramientas impulsadas por IA, surge la necesidad de desarrollar un marco normativo adecuado que permita regular y acompañar esta transformación. En este contexto, la Federación Internacional de Contadores (IFAC) desempeña un papel esencial al establecer directrices que buscan garantizar la calidad, transparencia y confiabilidad de la información financiera generada mediante tecnologías avanzadas. La implementación de estos estándares permite a los profesionales de la contabilidad adaptarse a los desafíos de un entorno en constante evolución, promoviendo el uso de la IA bajo principios éticos y salvaguardando la integridad de los procesos contables automatizados. La intervención de IFAC en este ámbito no solo contribuye a la alineación de los procesos contables con los avances tecnológicos, sino que también asegura que la información financiera producida bajo la influencia de la IA cumpla con altos estándares de precisión y ética, brindando confianza a los usuarios de dicha información y fortaleciendo el papel de la contabilidad en la economía global. (Oprea y otros, 2022)

La relación entre la inteligencia artificial (IA) y las normas de la Federación Internacional de Contadores (IFAC) abarca varios niveles de interacción que redefinen la práctica contable moderna, alineándose con los estándares, pero también planteando retos específicos. Por un lado, la IA introduce mejoras en la eficiencia y precisión de los procesos, lo que facilita el cumplimiento de las normativas y puede fortalecer la confiabilidad de los resultados. Sin embargo, esta tecnología no elimina la necesidad del juicio profesional, que sigue siendo esencial para interpretar



adecuadamente los resultados, identificar riesgos potenciales y tomar decisiones informadas. (Hniche & Saadane, 2023).

Además, la IFAC destaca la importancia de una preparación digital integral que permita a los contadores estar al día con los avances en tecnologías de IA y desarrollar las competencias necesarias para interpretar y aplicar estas herramientas en sus prácticas diarias (Bunget & Lungu, 2023).

#### **1.4. El rol de la educación superior en la formación de competencias analíticas**

Las tecnologías emergentes facilitan un entorno de aprendizaje que combina el análisis teórico con aplicaciones prácticas, permitiendo a los estudiantes explorar conceptos complejos de manera más accesible. Según Garrison y Exner (2019) la percepción de los estudiantes sobre su nivel de comprensión en cursos de estadística refleja cómo la exposición a estos enfoques analíticos puede influir en su rendimiento académico. Un alto porcentaje de estudiantes perciben su dominio de los conceptos estadísticos en categorías superiores, lo que evidencia la efectividad de los métodos de enseñanza que enfatizan el análisis de datos y la aplicación práctica de conocimientos (Diputera, 2021).

## **2. Diseño metodológico**

### **2.1. Tipo y Alcance de la Investigación**

La presente investigación es de tipo cuantitativo, enfocada en identificar los factores que explican la percepción de los estudiantes de la FCE de Universidad de Antioquia sobre la aplicación de herramientas de análisis de datos en su formación académica y futura práctica profesional. El alcance es explicativo, ya que busca no solo describir el fenómeno, sino también entender las relaciones de causa-efecto que pueden influir en la aceptación y el uso de estas herramientas. Para lograr este propósito, se analizaron variables independientes y dependientes en función de su impacto en la disposición de los estudiantes.

## **2.2. Composición de la Muestra**

El instrumento empleado en la investigación es la encuesta, cuyo cuestionario organiza sistemáticamente los indicadores de las variables relacionadas con los objetivos de la investigación. Esta encuesta está diseñada conforme al Modelo de Aceptación de la Tecnología (TAM), un marco teórico establecido por Davis (1989) para comprender y anticipar la aceptación y el uso de tecnologías de información y comunicación (TIC) entre los usuarios. Mediante el TAM, se pueden identificar los factores que influyen en la percepción de los estudiantes hacia el análisis de datos y prever su disposición para utilizar estas herramientas en su práctica profesional, considerando aspectos como la actitud positiva hacia la tecnología, la intención de uso y el uso efectivo del sistema. Dichos constructos se han aplicado en estudios “en” y “entre” organizaciones para examinar la difusión de TIC y los determinantes de su adopción (Adams, Nelson y Todd, 1992).

La muestra intencionada se compone de estudiantes activos en los programas de Contaduría Pública, Administración de Empresa y Economía de la Universidad de Antioquia para el semestre 2024-1 en la sede Medellín, de acuerdo con la información registrada en DATA UdeA (2024), esta plataforma dispone de los datos estadísticos oficiales de la Universidad de Antioquia, lo que garantiza la calidad y transparencia de la información.

La encuesta fue realizada por 113 estudiantes de la FCE, el objetivo fue analizar su percepción respecto al uso de herramientas de análisis de datos en su formación académica y futura práctica profesional. Para ello, se utilizó un cuestionario basado en el Modelo de Aceptación de Tecnología (TAM), ampliamente reconocido por su capacidad para evaluar variables como la percepción de utilidad, facilidad de uso y la intención de adopción de tecnologías.

## **2.3. Instrumentos de Medición**

El instrumento principal de recolección de datos fue un cuestionario basado en el Modelo de Aceptación de Tecnología (TAM), desarrollado por Davis (1989). Este modelo es ampliamente reconocido en la investigación sobre aceptación de tecnología y permite identificar factores que influyen en la percepción de los estudiantes, como la utilidad percibida, la facilidad de uso y la intención de utilizar estas herramientas en el ámbito profesional. Los constructos evaluados en el

cuestionario incluyeron la frecuencia de uso, la percepción de preparación, y la relevancia de estas herramientas para la práctica profesional en el ámbito de las ciencias económicas y contables.

#### **2.4. Procedimiento de Recolección de Datos**

Los datos se recolectaron mediante la aplicación del cuestionario a los estudiantes. La recolección se realizó durante un período de un mes y medio, entre mayo y junio de 2024, para asegurar la calidad de los datos, el cuestionario fue diseñado y revisado en varias fases, incluyendo una validación de expertos que permitió ajustar los ítems para maximizar la claridad y efectividad en la obtención de respuestas válidas.

#### **2.5. Análisis estadístico**

Para analizar las respuestas del cuestionario, se aplicaron pruebas de independencia chi-cuadrado para contrastar las variables de interés. Estas pruebas se utilizaron para determinar la independencia o dependencia de diversas variables categóricas, como el género, el nivel académico y la percepción de la efectividad de las herramientas de análisis de datos. Los resultados incluyeron el valor-p y los grados de libertad correspondientes para cada cruce de variables, permitiendo una interpretación estadística de las relaciones observadas. Los análisis identificaron, entre otros hallazgos, una relación significativa entre el soporte institucional percibido y la disposición de los estudiantes a mejorar sus habilidades en análisis de datos.

Asimismo, en el análisis estadístico, la formulación de la hipótesis nula desempeña un papel central al reflejar de manera precisa los ítems planteados por el modelo propuesto, establece la ausencia de relación significativa entre las variables en estudio, funcionando como base para evaluar las relaciones planteadas. En este caso, su correcta definición permite garantizar que las comparaciones realizadas sean coherentes con los objetivos del análisis. En cuanto a las pruebas de Chi-cuadrado, estas se aplican para determinar la independencia entre variables categóricas, evaluando si las frecuencias observadas difieren de las esperadas bajo la hipótesis de independencia. El estadístico resultante mide el grado de desviación entre estos valores, y su interpretación se complementa con los grados de libertad, que reflejan el número de categorías menos las restricciones impuestas. Por último, se utiliza un nivel de significancia menor a 0.05

para definir el umbral en el que se rechaza la hipótesis nula, asegurando que las relaciones identificadas no se deban al azar. La incorporación de estos elementos aporta rigor a la interpretación de los resultados obtenidos. Fisher (1925) estableció el valor-p como una herramienta para evaluar la significancia en pruebas de hipótesis. Por tanto, cuando el valor-p es menor a 0.05, se interpreta que las variables categóricas tienen una asociación significativa dentro del contexto analizado

### 3. Análisis de Resultados

#### 3.1. Resumen de las pruebas de independencia

A continuación, se analizan estadísticamente los resultados de los cruces de variables de interés en la encuesta, su objetivo es identificar los potenciales factores que condicionan el uso y las preferencias por las herramientas de análisis de datos. Debido a que las respuestas de la encuesta son de naturaleza ordinal y las variables sociodemográficas son de naturaleza categórica, se realizaron pruebas estadísticas chi-cuadrado para contrastar la independencia entre las frecuencias relativas de las opciones múltiples.

**Tabla 1.** Resumen de los resultados de las pruebas de independencia

Contraste bivariado	Estadístico	Grados de libertad	Valor-p
1. Sexo biológico vs frecuencia de uso herramienta	4.70	4	0.3192
2. Nivel académico vs percepción de preparación	46.13	36	0.1202
3. Frecuencia de uso vs efectividad para toma de decisiones	14.56	16	0.5567
4. Relevancia de las herramientas vs recursos universitarios	50.85	16	0.0000*
5. Carrera académica vs calidad de la enseñanza	9.56	12	0.6546
6. Preparación percibida vs ventaja laboral competitiva	29.11	12	0.0038*

---

7. Disposición para esfuerzo vs recursos universitarios	32.63	16	0.0083*
---	-------	----	---------

---

*Nota.* Resultados de la prueba de independencia de chi-cuadrado, se muestra el estadístico de prueba, los grados de libertad y el valor-p de cada contraste. \*Los valores-p son significativos por debajo de 0.05

### 3.2. Interpretación específica de los contrastes

#### 3.2.1. Sexo biológico versus frecuencia de uso de herramientas

Al investigar la relación entre el género de los estudiantes y la frecuencia con la que se discuten o utilizan análisis de datos en sus cursos, el valor-p obtenido fue de 0.319. Este resultado sugiere que no existe evidencia suficiente para rechazar la hipótesis nula de independencia entre estas dos variables. En otras palabras, no se puede afirmar que haya diferencia significativa entre hombres y mujeres en cuanto a la frecuencia con la que los análisis de datos son integrados en sus cursos.

En particular, este hallazgo es relevante dentro del contexto de la investigación, ya que revela que el uso de herramientas de análisis de datos en el entorno académico no parece estar influenciado por el género. Esto podría interpretarse como un indicio de equidad en la implementación de tecnologías educativas, sugiriendo que tanto estudiantes masculinos como femeninos tienen acceso similar a las prácticas de análisis de datos. La ausencia de diferencias significativas según el género también invita a reflexionar sobre otros posibles factores que podrían influir en la frecuencia de uso de análisis de datos en los cursos, tales como la naturaleza de las asignaturas, el enfoque pedagógico de los profesores, o las políticas institucionales. Este resultado motiva a los educadores a asegurar que estas herramientas se integren de manera uniforme y efectiva, promoviendo un ambiente de aprendizaje inclusivo y equitativo.

**Tabla 2.** Tabla de contingencia chi-cuadrado del contraste 1

Sexo	En algunas clases	En cada clase	Frecuentemente	Nunca	Raramente	Total
<i>Femenino</i>	27	4	18	5	16	70
<i>Masculino</i>	14	1	7	6	15	43

---

<b>Total</b>	41	5	25	11	31	113
--------------	----	---	----	----	----	-----

---

*Nota.* Fuente: elaboración propia.

### 3.2.2. Nivel académico versus percepción de preparación

Con respecto al nivel académico y la percepción de preparación para el uso de herramientas de análisis de datos, los resultados de la prueba de Chi-cuadrado ( $\chi^2 = 46.13$ , valor-p = 0.120) no mostraron una relación significativa entre estas variables, indicando que dicha percepción en el futuro entorno laboral no depende necesariamente del nivel académico. Las frecuencias esperadas en la tabla de contingencia apoyan esta conclusión, ya que las discrepancias entre las frecuencias observadas y esperadas no son lo suficientemente grandes como para rechazar la hipótesis de independencia.

**Tabla 3.** Tabla de contingencia chi-cuadrado del contraste 2

<b>Nivel Académico</b>	<b>Sin preparación</b>	<b>Poco preparado</b>	<b>Moderadamente preparado</b>	<b>Bien preparado</b>	<b>Excelentemente preparado</b>	<b>Total</b>
<b>1</b>	2	2	3	2	0	9
<b>2</b>	2	6	2	0	1	11
<b>3</b>	3	5	2	0	0	10
<b>4</b>	2	4	4	0	0	10
<b>5</b>	2	3	3	0	0	8
<b>6</b>	0	5	4	0	0	9
<b>7</b>	6	18	5	0	1	30
<b>8</b>	0	2	5	0	1	8
<b>9</b>	0	3	4	2	0	9
<b>10</b>	2	2	4	0	1	9
<b>Total</b>	19	50	36	4	4	113

*Nota.* Fuente: elaboración propia

### 3.2.3. Frecuencia de uso versus efectividad para toma de decisiones

El contraste entre la frecuencia del uso de análisis de datos en los cursos y la percepción de su efectividad para la toma de decisiones obtuvo un valor-p de 0.557. Este resultado indica que no existe evidencia suficiente para rechazar la hipótesis nula de independencia entre estas dos variables. En efecto, la ausencia de una relación significativa podría indicar que, más allá del uso los análisis de datos en el aula, los estudiantes tienden a formarse opiniones similares sobre la efectividad de estas herramientas para la toma de decisiones. Esto podría deberse a una variedad de factores, como la calidad de la enseñanza, el contenido del currículo o las experiencias prácticas de los estudiantes fuera del aula.

Este resultado sugiere la necesidad de explorar otros factores que podrían influir en la percepción de efectividad de las herramientas de análisis de datos, como la forma en que se enseñan, la relevancia del contenido para los estudiantes, y la oportunidad de aplicar estos conocimientos en escenarios prácticos. Además, subraya la importancia de diseñar estrategias educativas que no solo incrementen la frecuencia de uso de análisis de datos, sino que también mejoren la calidad y relevancia de la instrucción.

**Tabla 4.** Tabla de contingencia chi-cuadrado del contraste 3

<b>Frecuencia de Uso</b>	<b>Inefectivas</b>	<b>Ligeramente efectivas</b>	<b>Moderadamente efectivas</b>	<b>Muy efectivas</b>	<b>Extremadamente efectivas</b>	<b>Total</b>
<i>Nunca</i>	1	0	2	6	2	11
<i>Raramente</i>	0	1	5	19	6	31
<i>En algunas clases</i>	0	2	6	28	5	41
<i>Frecuentemente</i>	0	1	2	16	6	25
<i>En cada clase</i>	0	0	0	3	2	5
<b>Total</b>	1	4	15	72	21	113

*Nota.* Fuente: elaboración propia.

### 3.2.4. Relevancia de las herramientas versus recursos universitarios

En particular, el cruce entre la relevancia percibida de las herramientas de análisis de datos en la carrera de los estudiantes y el nivel de soporte y recursos ofrecidos por la universidad reveló un valor-p de 0.000. Este resultado indica una clara evidencia para rechazar la hipótesis nula de independencia entre estas dos variables; lo que sugiere una relación significativa entre cómo los estudiantes perciben la importancia de estas herramientas de análisis en sus carreras y el nivel de soporte y recursos que la universidad proporciona para el aprendizaje de estas herramientas.

En específico, este hallazgo destaca la importancia del apoyo institucional en la formación de percepciones estudiantiles sobre la utilidad de las herramientas de análisis de datos. De hecho, se observa que los estudiantes que perciben un alto nivel de soporte y recursos tienden a considerar las herramientas de análisis de datos como fundamentales o críticas para sus carreras; en contraste, una percepción de soporte insuficiente podría correlacionarse con una menor valoración de estas.

La significancia de este resultado invita a los docentes y a los diseñadores de currículo a considerar la mejora y expansión del soporte y los recursos disponibles para el aprendizaje de herramientas de análisis de datos. Incrementar la disponibilidad y calidad de estos recursos no solo puede mejorar la percepción de su relevancia entre los estudiantes, sino también potenciar su preparación y competitividad en el mercado laboral.

**Tabla 5.** Tabla de contingencia chi-cuadrado del contraste 4

<b>Relevancia de herramientas</b>	<b>Muy insuficientes</b>	<b>Insuficientes</b>	<b>Adecuados</b>	<b>Buenos</b>	<b>Excelentes</b>	<b>Total</b>
<i>No son relevantes para mi carrera</i>	1	0	0	0	1	2
<i>Son críticas para todas las áreas</i>	6	7	4	2	2	21



---

<i>Son fundamentales para la mayoría</i>	4	32	25	8	1	70
<i>Son necesarias para algunas áreas</i>	0	2	9	6	0	17
<i>Son un complemento útil pero no esencial</i>	0	0	1	2	0	3
<b>Total</b>	11	41	39	18	4	113

---

*Nota.* Fuente: elaboración propia.

### 3.2.5. Carrera académica versus calidad de la enseñanza

En el análisis de la independencia entre la carrera y la calidad de la enseñanza los resultados de la prueba chi-cuadrado (valor  $\chi^2$ : 9.559, valor-p: 0.655) indican que no hay suficiente evidencia para rechazar la hipótesis nula de independencia entre estas variables.

Contextualmente hablando, la ausencia de una relación significativa implica que, sin perjuicio de la carrera académica, los estudiantes tienden a tener percepciones similares sobre la calidad de la enseñanza en esta área. Esto puede indicar que la metodología y los recursos de enseñanza son uniformemente aplicados en distintas carreras, lo cual es un aspecto positivo en términos de igualdad educativa. Este resultado resalta la importancia de continuar evaluando y mejorando la calidad de la enseñanza de herramientas de análisis de datos de manera uniforme en todas las carreras. Aunque no se identificaron diferencias significativas entre las carreras, es esencial que las instituciones académicas mantengan altos estándares de calidad y adapten sus métodos de enseñanza para satisfacer las necesidades específicas de cada grupo de estudiantes.

**Tabla 6.** Tabla de contingencia chi-cuadrado del contraste 5

Carrera Académica	Muy pobre	Pobre	Aceptable	Buena	Excelente	Total
<i>Administración de empresas</i>	2	8	5	3	0	18
<i>Contaduría Pública</i>	9	20	29	8	1	67
<i>Economía</i>	3	12	5	5	0	25
<i>Otra</i>	1	0	1	1	0	3
<b>Total</b>	15	40	40	17	1	113

*Nota.* Fuente: elaboración propia.

### 3.2.6. Preparación percibida versus ventaja laboral competitiva

Ahora bien, un cruce muy importante, y que de hecho resultó significativo, es el de la preparación percibida en análisis de datos y la percepción sobre la ventaja laboral competitiva (valor-p de 0.004). Este resultado indica una fuerte evidencia para rechazar la hipótesis nula de independencia entre estas dos variables; en otras palabras, existe una relación estadísticamente significativa entre la preparación que los estudiantes sienten haber recibido y su percepción de la ventaja competitiva que el conocimiento en análisis de datos les proporciona.

Este hallazgo es bastante relevante en el contexto de esta investigación. Los estudiantes que sienten que han recibido una preparación adecuada o excelente tienden a percibir que el conocimiento en análisis de datos les convierte en profesionales más competentes. Por el contrario, aquellos que se sienten poco preparados o completamente sin preparación son menos propensos a reconocer esta ventaja. Este resultado resalta la importancia de la calidad de la formación académica en el uso de herramientas de análisis de datos. La percepción de una preparación sólida no solo mejora la confianza de los estudiantes en su capacidad para aplicar estas herramientas, sino que también influye directamente en su percepción del valor estratégico de estas habilidades en el ámbito profesional. Las instituciones educativas deben prestar atención a estos hallazgos para garantizar que los programas de formación en análisis de datos sean robustos y alineados con las necesidades del mercado laboral, fortaleciendo así la competitividad de sus egresados.

**Tabla 7.** Tabla de contingencia chi-cuadrado del contraste 6

<b>Preparación percibida</b>	<b>Ninguna ventaja</b>	<b>Ventaja moderada</b>	<b>Alta ventaja</b>	<b>Ventaja decisiva</b>	<b>Total</b>
<i>Totalmente preparación</i>	<i>sin</i> 0	1	9	9	19
<i>Poco preparado</i>	0	3	27	20	50
<i>Moderadamente preparado</i>	0	3	19	14	36
<i>Bien preparado</i>	0	0	2	2	4
<i>Excelentemente preparado</i>	1	0	1	2	4
<b>Total</b>	1	7	58	47	113

*Nota.* Fuente: elaboración propia.

### 3.2.7. Disposición para esfuerzo versus recursos universitarios

Por último, se identificó una relación significativa entre el nivel de soporte y recursos ofrecidos por la universidad y la disposición a invertir esfuerzo para mejorar habilidades en herramientas de análisis de datos. Esto se determinó mediante una prueba chi-cuadrado (valor-p de 0.008), indicando que estas dos variables son dependientes entre sí. La razón detrás de esta dependencia se puede explicar a través de la teoría de la autoeficacia en el contexto educativo.

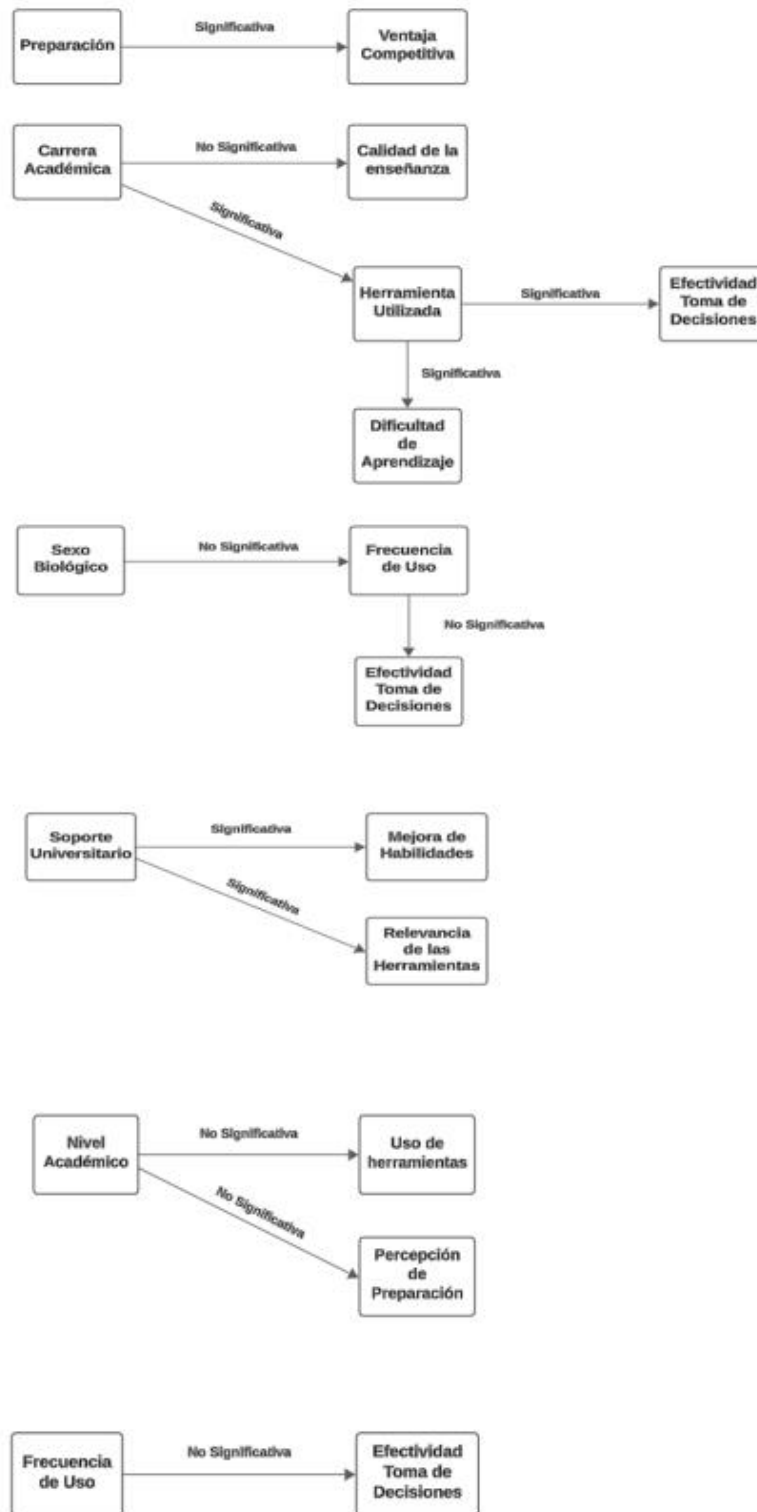
Este hallazgo es especialmente revelador en el contexto de la investigación, ya que destaca la importancia de un entorno de apoyo robusto en la motivación de los estudiantes. Aquellos que perciben un soporte adecuado o bueno están más inclinados a invertir un esfuerzo considerable o máximo en perfeccionar sus habilidades. Este comportamiento puede interpretarse como un ciclo virtuoso: un mayor apoyo institucional fomenta una mayor dedicación por parte de los estudiantes, lo que a su vez puede llevar a un uso más efectivo de las herramientas de análisis de datos.

Por otro lado, el hecho de que incluso aquellos que identifican el soporte como insuficiente estén dispuestos a invertir esfuerzo máximo refleja una conciencia de la importancia de estas habilidades para su futuro profesional, independientemente de las condiciones actuales. Este dato debería alentar a las instituciones educativas a reforzar sus programas de soporte y recursos, asegurando que todos los estudiantes tengan acceso a las herramientas y el apoyo necesarios para desarrollar sus habilidades al máximo.

### **3.3. Factores determinantes en la toma de decisiones académicas**

El siguiente diagrama presenta ilustra las relaciones entre diversas variables asociadas al uso de herramientas de análisis de datos en un entorno educativo. Las conexiones entre los diferentes aspectos se categorizan como significativas o no significativas.

*Figura 9. Grafo de dependencias e incidencias*



*Nota.* Fuente: elaboración propia a partir de pruebas de independencia

En el grafo se observa una relación significativa entre la preparación de los estudiantes y su percepción de tener una ventaja competitiva en el mercado laboral, lo que subraya la importancia de una formación adecuada para mejorar la autoeficacia y la confianza en el ámbito profesional. La carrera académica no presenta una relación significativa con la calidad de la enseñanza, aunque sí influye de manera significativa en la herramienta de análisis de datos utilizada, que a su vez tiene un impacto considerable en la percepción de dificultad de aprendizaje y en la efectividad para la toma de decisiones. Además, el sexo biológico muestra una relación significativa con la frecuencia de uso de las herramientas de análisis de datos, aunque esta frecuencia no presenta una conexión significativa con la efectividad para la toma de decisiones. La herramienta utilizada también está significativamente relacionada con la dificultad de aprendizaje, siendo Excel percibida como más accesible comparada con lenguajes de programación como R o Python.

#### **4. Discusión**

En principio, Ruffing et al (2015). han estudiado las diferencias de género en el uso de estrategias de aprendizaje y su impacto en el rendimiento académico. Su investigación muestra que, aunque las mujeres aplican estrategias de aprendizaje con más frecuencia que los hombres, estas diferencias no se traducen necesariamente en variaciones significativas en el rendimiento académico entre géneros. El estudio revela que, aunque los hombres reportan utilizar menos estrategias de aprendizaje, la importancia predictiva de estas estrategias en el rendimiento académico no difiere significativamente entre géneros. Es decir, tanto hombres como mujeres pueden lograr un rendimiento académico similar a pesar de sus diferencias en la aplicación de estrategias de aprendizaje. Por lo tanto, la independencia observada entre género y frecuencia de uso de herramientas de análisis de datos podría estar relacionada con el hecho de que las estrategias de aprendizaje, aunque diferentes entre géneros, no afectan de manera diferencial la capacidad de utilizar estas herramientas en un contexto académico.

De forma análoga, Mintu-Wimsatt y Lozada (2018) en su artículo "Business Analytics in the Marketing Curriculum: A Call for Integration" explican cómo la inclusión de herramientas de análisis de datos en los planes de estudio de marketing varía considerablemente y subrayan la importancia de integrar el análisis de datos en el currículo para desarrollar las habilidades y competencias de los estudiantes. Este razonamiento respalda los resultados del análisis cruzado entre las variables de carrera y herramienta de análisis de datos utilizada más frecuentemente, que mostró una dependencia significativa. Por ejemplo, los programas de Contaduría Pública a menudo hacen hincapié en el uso de Excel debido a su aplicabilidad en tareas contables y de auditoría, mientras que los programas de administración de empresas pueden enfocarse más en herramientas estadísticas y de visualización de datos para análisis de negocios. Por otro lado, los programas de economía suelen incorporar lenguajes de programación como R y Python para análisis econométricos y de grandes conjuntos de datos. Las otras carreras pueden tener una formación más variada o menos enfocada en herramientas específicas de análisis de datos, lo que se refleja en una menor uniformidad en las herramientas utilizadas, la elección de herramientas de análisis de datos está significativamente influenciada por la carrera del estudiante, y esta dependencia puede atribuirse a las diferencias en el enfoque curricular y las competencias específicas requeridas en cada programa académico.

En contraste, Brooks (2011), encontró que los entornos de aprendizaje mejorados tecnológicamente tienen un impacto significativo y positivo en los resultados de aprendizaje de los estudiantes. Este hallazgo sugiere que cuando los entornos de aprendizaje son consistentes y están bien diseñados, pueden mitigar diferencias que de otro modo se esperarían debido a variaciones en el nivel académico. En el análisis cruzado de Nivel Académico vs. Percepción de Preparación para el Uso de Herramientas de Análisis de Datos en el Entorno Laboral, los resultados de la prueba de independencia no mostraron una relación significativa entre estas variables, indicando que la percepción de preparación no depende del nivel académico. Las frecuencias esperadas en la tabla de contingencia apoyan esta conclusión, ya que las discrepancias entre las frecuencias observadas y esperadas no son lo suficientemente grandes como para rechazar la hipótesis de independencia. Una posible razón para esta independencia es la uniformidad en la enseñanza de herramientas de

análisis de datos a lo largo de los diferentes niveles académicos, lo cual puede llevar a percepciones similares de preparación entre los estudiantes, independientemente de su año o nivel de estudio.

Según Pehlivanoglu et al (2021), la habilidad de razonamiento analítico y la credibilidad de la fuente influyen en la evaluación de la información, donde herramientas más complejas requieren un mayor razonamiento analítico, afectando la percepción de dificultad. Esto se alinea con la teoría del procesamiento dual de Kahneman, el autor sugiere que el procesamiento de información puede ser intuitivo y rápido o deliberado y lento. Herramientas como Excel, que son más intuitivas, probablemente se procesan mediante el, mientras que herramientas como R o Python, que requieren un procesamiento más deliberado, se procesan mediante el Sistema. La prueba de Chi-Cuadrado se utilizó para determinar la dependencia entre las herramientas de análisis de datos utilizadas y la percepción de la dificultad para aprender a usarlas. Los resultados sugieren que la percepción de dificultad varía según la herramienta utilizada, siendo Excel percibida como más accesible comparada con lenguajes de programación como R o Python, que requieren habilidades más avanzadas. La dependencia observada puede estar relacionada con la variabilidad en la complejidad y la curva de aprendizaje asociada a diferentes herramientas de análisis de datos.

Por otra parte, Según Zhao et al (2022), la independencia observada entre la frecuencia de uso de herramientas de análisis de datos en los cursos y la percepción de su efectividad para mejorar la toma de decisiones puede explicarse por varios factores teóricos y empíricos. En primer lugar, la relevancia percibida y el compromiso del usuario son críticos para la adopción y percepción de una tecnología. Si los estudiantes no perciben las herramientas de análisis de datos como relevantes para sus necesidades específicas, su frecuencia de uso no necesariamente influirá en su percepción de efectividad. En un entorno educativo, los estudiantes pueden no estar motivados a procesar profundamente la utilidad de las herramientas si no ven una aplicación directa e inmediata en sus estudios o futuros trabajos. La percepción de la efectividad de las herramientas de análisis de datos puede estar influenciada por una variedad de experiencias educativas, como la calidad de la enseñanza, la claridad en la instrucción y el contexto en el que se utilizan las herramientas.



Asimismo, según Lonbay (2008) el análisis realizado mediante la prueba de Chi-cuadrado mostró que no existe una relación significativa entre la relevancia percibida de las herramientas de análisis de datos en la carrera y el nivel de soporte y recursos ofrecidos por la universidad. Esto sugiere que la percepción de la relevancia de las herramientas de análisis de datos no está influenciada por el nivel de soporte y recursos proporcionados por la universidad. Una posible razón para la independencia observada entre estas variables podría estar relacionada con el enfoque general de la educación superior en la formación de competencias específicas. Las universidades tienden a diseñar sus programas curriculares para desarrollar competencias genéricas y específicas en sus estudiantes, independientemente de los recursos adicionales disponibles. Esto significa que la relevancia de las herramientas de análisis de datos es percibida como inherentemente importante para el campo de estudio de los estudiantes, más allá del nivel de soporte y recursos que la universidad pueda ofrecer. Este fenómeno puede explicarse porque la educación superior en Europa, siguiendo el proceso de Bolonia, se ha enfocado en desarrollar competencias que aseguren la empleabilidad y movilidad de los graduados en un mercado laboral cada vez más internacional. Destaca que las competencias se desarrollan a través de programas de estudio diseñados para ser comparables, compatibles y transparentes a nivel europeo. Esto incluye tanto competencias genéricas como específicas, que son vistas para el éxito profesional independientemente del contexto institucional específico. Además, las competencias en herramientas de análisis de datos son consideradas esenciales en muchos campos debido a su creciente importancia en la toma de decisiones basada en datos. La percepción de los estudiantes sobre la relevancia de estas herramientas probablemente se basa en la comprensión de su valor intrínseco en el ámbito profesional, lo que puede explicar por qué no depende significativamente del nivel de soporte y recursos proporcionados por la universidad. La integración de estas competencias en los programas de estudio es una prioridad educativa que trasciende la disponibilidad de recursos adicionales, lo que refuerza la independencia observada en el análisis.

Con respecto a la calidad de enseñanza, Malhotra y Galletta (1999) en su estudio sobre la ampliación del Modelo de Aceptación de la Tecnología (TAM) para incluir la influencia social, destacan cómo los factores sociales, como la internalización, identificación y cumplimiento, pueden afectar la actitud de los usuarios hacia el uso de nuevas tecnologías. En el contexto de la

enseñanza de herramientas de análisis de datos, esto sugiere que la calidad percibida de la enseñanza puede estar más influenciada por factores institucionales y de diseño curricular que por la carrera específica de los estudiantes. En el análisis de la independencia entre carrera y calidad de la enseñanza en el uso de herramientas de análisis de datos, los resultados de la prueba Chi-cuadrado (valor  $\chi^2$ : 9.559, valor p: 0.655) indican que no hay suficiente evidencia para rechazar la hipótesis nula de independencia entre estas variables. Esto significa que no se puede concluir que exista una relación significativa entre la carrera de los estudiantes y su percepción sobre la calidad de la enseñanza en el uso de herramientas de análisis de datos. La razón de esta independencia puede explicarse mediante la influencia de factores sociales y organizacionales en la adopción y uso de nuevas tecnologías, como se describe el autor. Las instituciones educativas tienden a implementar estándares uniformes en la enseñanza de herramientas de análisis de datos, asegurando que todos los estudiantes, independientemente de su carrera, reciban una educación de calidad similar. Este enfoque homogéneo puede llevar a percepciones similares de la calidad de la enseñanza entre estudiantes de diferentes disciplinas, explicando así la falta de una relación significativa entre las variables estudiadas. Esta uniformidad en la calidad de la enseñanza, influenciada por políticas institucionales y factores sociales, podría ser una razón clave para la independencia observada entre la carrera y la percepción de la calidad de la enseñanza en el uso de herramientas de análisis de datos.

Ahora bien, con relación a la ventaja competitiva, Zimmerman (2000) demuestra que la autoeficacia es un predictor de la motivación y el rendimiento académico de los estudiantes. La autoeficacia se refiere a las creencias de las personas sobre sus capacidades para organizar y ejecutar las acciones necesarias para alcanzar objetivos específicos. Los estudiantes con alta autoeficacia están más motivados, persisten más en sus tareas y tienen mejores resultados académicos. Esta teoría puede explicar la dependencia observada en el análisis estadístico, donde la prueba de chi-cuadrado arrojó un valor de p de 0.0038, indicando una correlación significativa entre la percepción de preparación y la ventaja competitiva percibida en el mercado laboral. En el contexto del estudio, los estudiantes que perciben que están bien preparados para utilizar herramientas de análisis de datos pueden tener una mayor autoeficacia, lo que a su vez aumenta su percepción de tener una ventaja competitiva en el mercado laboral. Esta relación se alinea con la

evidencia de que la autoeficacia influye en las decisiones de los estudiantes, su esfuerzo y su persistencia, llevando a mejores resultados en su desempeño académico y profesional. En resumen, la dependencia entre estas variables puede atribuirse a la influencia positiva de la autoeficacia en la percepción de las propias capacidades y en la motivación para alcanzar el éxito en el entorno laboral.

En el contexto académico, Heale y Noble (2019) destacaron que la estandarización en la integración de herramientas y conceptos dentro del currículo asegura que todos los estudiantes, independientemente de su nivel académico, tengan acceso a las mismas oportunidades de aprendizaje y desarrollo de habilidades. En el análisis de dependencia entre el nivel académico y la frecuencia de uso de herramientas de análisis de datos en cursos, se generaron tablas de frecuencias observadas y esperadas para evaluar esta relación. La prueba Chi-Cuadrado indica que no hay evidencia suficiente para rechazar la hipótesis nula de independencia. Es decir, no existe una relación estadísticamente significativa entre el nivel académico y la frecuencia de uso de herramientas de análisis de datos en los cursos. La tabla de frecuencias observadas muestra cómo se distribuyen las respuestas en diferentes niveles académicos y frecuencias de uso, mientras que la tabla de frecuencias esperadas proporciona una referencia de cómo se esperarían las respuestas si las variables fueran independientes.

Por otra parte, Guo et al (2012) identificaron que existe una relación significativa entre el nivel de soporte y recursos ofrecidos por la universidad y la disposición a invertir esfuerzo para mejorar habilidades en herramientas de análisis de datos. Esto se determinó mediante una prueba chi-cuadrado, que arrojó un valor de  $\chi^2 = 32.63$  y un valor p de 0.008, indicando que estas dos variables son dependientes entre sí. La razón detrás de esta dependencia se puede explicar a través de la teoría de la autoeficacia en el contexto educativo propuesta por el autor. La autoeficacia se define como la creencia en la propia capacidad para organizar y ejecutar las acciones necesarias para gestionar situaciones futuras. El autor destaca que el apoyo institucional y los recursos adecuados aumentan la autoeficacia de los estudiantes, lo que incrementa su disposición a invertir esfuerzo en el aprendizaje y desarrollo de nuevas habilidades. Esta teoría sugiere que cuando los estudiantes perciben que la universidad proporciona un buen nivel de soporte y recursos, sienten una mayor

confianza en su capacidad para aprender y utilizar herramientas de análisis de datos. Esta mayor autoeficacia se traduce en una mayor disposición a invertir esfuerzo en mejorar sus habilidades en estas herramientas.

En el contexto del análisis de datos en ciencias económicas, Han et al (2019) encontraron que la familiaridad con la plataforma de análisis y el conocimiento de fondo son factores determinantes que influyen en la percepción y efectividad de las tareas realizadas. En esta investigación, se demostró estadísticamente que hay una relación significativa entre las herramientas de análisis de datos más utilizadas y la efectividad percibida en la toma de decisiones. Esto sugiere que la elección de la herramienta de análisis de datos influye en cómo se percibe su efectividad para la toma de decisiones. Los hallazgos de Han et al. revelan que la familiaridad con el conocimiento de fondo significativamente influye en el rendimiento de la tarea, lo que sugiere que los usuarios que están más familiarizados con el contexto y los conceptos subyacentes de una herramienta de análisis de datos tienden a percibirla como más efectiva. Además, la familiaridad con la plataforma de análisis de datos también es un factor importante que influye en la finalización de tareas, indicando que los usuarios que conocen bien cómo usar una herramienta específica tienen más probabilidades de completarla exitosamente y percibirla como efectiva. Aunque la autoeficacia no tuvo un impacto significativo en la finalización y el rendimiento de las tareas en este estudio, sigue siendo un factor relevante para considerar en estudios futuros que examinen cómo la confianza de un individuo en su capacidad para usar una herramienta puede influir en su percepción de efectividad.

## **5. Conclusiones**

Un aspecto identificado es la relación entre el nivel de soporte universitario percibido y la relevancia asignada a las herramientas de análisis de datos en la carrera profesional. Los estudiantes que perciben un alto nivel de soporte institucional tienden a considerar estas herramientas como esenciales para su desarrollo profesional, mientras que aquellos con menor percepción de apoyo institucional les asignan una relevancia más baja. Este hallazgo subraya la importancia de los recursos y el respaldo académico en la configuración de la percepción estudiantil sobre el valor de estas tecnologías para su futuro profesional. La presencia de un soporte adecuado y accesible

fomenta una valoración positiva hacia las herramientas de análisis de datos, incentivando su adopción y aumentando la percepción de utilidad en el ámbito laboral.

La percepción de ventaja competitiva en el mercado laboral está fuertemente relacionada con el nivel de preparación percibido por los estudiantes en el uso de herramientas de análisis de datos. Aquellos que se sienten bien preparados en estas competencias tienden a percibir que poseen una ventaja en el ámbito profesional, mientras que los que se sienten menos preparados muestran una menor percepción de dicha ventaja. Este vínculo entre preparación y ventaja competitiva evidencia la relevancia de la capacitación académica en el fortalecimiento de la confianza de los estudiantes y su percepción de estar listos para enfrentar desafíos laborales. La formación en análisis de datos emerge, entonces, como un factor diferenciador en la preparación para el mercado, incrementando la autoeficacia y el valor profesional percibido.

El soporte institucional y los recursos disponibles también influyen en la disposición de los estudiantes a invertir esfuerzo para mejorar sus habilidades en el análisis de datos. Los resultados muestran una relación significativa entre ambas variables, indicando que aquellos estudiantes que perciben un soporte institucional adecuado están más motivados a dedicar tiempo y esfuerzo al desarrollo de estas competencias. Este hallazgo resalta el papel del entorno de apoyo en la motivación académica, promoviendo un ciclo de crecimiento en el cual el acceso a recursos fomenta una mayor dedicación al aprendizaje, lo cual, a su vez, refuerza el uso efectivo de estas herramientas. La motivación para mejorar las habilidades en análisis de datos se encuentra, por tanto, asociada a la percepción de disponibilidad de recursos y al respaldo brindado por la institución.

Respecto al uso de herramientas específicas, el estudio indica que la elección de una herramienta de análisis de datos depende significativamente de la carrera académica del estudiante. Por ejemplo, los estudiantes de Contaduría suelen emplear más Excel debido a su aplicabilidad en tareas contables, mientras que los de economía optan por lenguajes como R o Python para análisis más avanzados. Esta preferencia por herramientas específicas se relaciona con los requerimientos curriculares y las competencias demandadas en cada campo de estudio. La variabilidad en la

elección de herramientas, conforme al enfoque de cada carrera, sugiere que la instrucción en análisis de datos se adapta a las necesidades profesionales particulares de los estudiantes, garantizando que las competencias desarrolladas sean pertinentes y alineadas con las demandas laborales específicas de cada disciplina.

---

## Referencias

- Aldowah, H., Al-Samarraie, H., & Fauzy, W. (2019). Educational data mining and learning analytics for 21st century higher education: A review and synthesis. *Telematics Informatics*, 13-49. <https://doi.org/https://doi.org/10.1016/J.TELE.2019.01.007>
- Alkhalil, A. (2021). Decision support model to adopt big data analytics in higher education systems. *International Journal of ADVANCED AND APPLIED SCIENCES*. <https://doi.org/https://doi.org/10.21833/IJAAS.2021.06.008>
- Alsariera, Y., Baashar, Y., Alkawsi, G., Mustafa, A., Alkahtani, A., & Ali, N. (2022). Assessment and Evaluation of Different Machine Learning Algorithms for Predicting Student Performance. *Computational Intelligence and Neuroscience*. <https://doi.org/https://doi.org/10.1155/2022/4151487>
- Bahari, M., Arpaci, I., Azmi, N., & Shuib, L. (2023). Predicting the Intention to Use Learning Analytics for Academic Advising in Higher Education. *Sustainability*. <https://doi.org/https://doi.org/10.3390/su152115190>
- Brooks, D. (2011). Space matters: The impact of formal learning environments on student learning. *British Journal of Educational Technology*, 719-726. <https://doi.org/https://doi.org/10.1111/j.1467-8535.2010.01098.x>
- Bunget, O., & Lungu, C. (2023). A Bibliometric Analysis of the Implications of Artificial Intelligence on the Accounting Profession. *CECCAR Business Review*. <https://doi.org/https://doi.org/10.37945/cbr.2023.04.02>
- Cantabella, M., Martínez-España, R., Ayuso, B., Yáñez, J., & Muñoz, A. (2019). Analysis of student behavior in learning management systems through a Big Data framework. *Future Gener Comput. Syst*, 262-272. <https://doi.org/https://doi.org/10.1016/j.future.2018.08.003>
- Diputera, A. (2021). Perception analysis of students' level of understanding in statistics course. *Journal of Mathematics and Natural Sciences*. <https://doi.org/https://doi.org/10.24114/jmns.v1i2.33217>

- Dogan, M., Dogan, T., & Bozkurt, A. (2023). The Use of Artificial Intelligence (AI) in Online Learning and Distance Education Processes: A Systematic Review of Empirical Studies. *Applied Sciences*. <https://doi.org/https://doi.org/10.3390/app13053056>
- Garrison, B., & Exner, N. (2019). Data Seeking Behavior of Economics Undergraduate Students: An Exploratory Study. *Reference & User Services Quarterly*. <https://doi.org/https://doi.org/10.5860/RUSQ.58.2.6930>.
- Guo, Y., Connor, C., Yang, Y., Roehrig, A., & Morrison, F. (2012). The Effects of Teacher Qualification, Teacher Self-Efficacy, and Classroom Practices on Fifth Graders' Literacy Outcomes. *The Elementary School Journal*, 3-24. <https://doi.org/https://doi.org/10.1086/665816>.
- Han, W., Song, S., Zhao, Y., & Zhu, Q. (2019). The Role of Self-Efficacy and Familiarity in Digital Humanity Crowdsourcing: A Preliminary Study from Transcribe-Sheng Project. *Joint Conference on Digital Libraries*, 408409. <https://doi.org/https://doi.org/10.1109/JCDL.2019.00093>
- Heale, R., & Noble, H. (2019). Integration of a theoretical framework into your research study. *Evidence Based Journals*, 36-37. <https://doi.org/https://doi.org/10.1136/ebnurs-2019-103077>.
- Hniche, O., & Saadane, R. (2023). Challenges and Opportunities of Integrating AI with IFRS in Accounting Systems Insights from Morocco. *Proceedings of the 6th International Conference on Networking, Intelligent Systems & Security*. <https://doi.org/https://doi.org/10.1145/3607720.3607785>.
- Lazar, I., Pânișoară, G., & Pânișoară, I. (2020). Digital technology adoption scale in the blended learning context in higher education: Development, validation and testing of a specific tool. *PLoS ONE*, 15. <https://doi.org/https://doi.org/10.1371/journal.pone.0235957>.
- Lee, J., & Hsieh, J. (2019). Affective variables and willingness to communicate of EFL learners in in-class, out-of-class, and digital contexts. *System*. <https://doi.org/https://doi.org/10.1016/J.SYSTEM.2019.03.002>.



- Lonbay, J., Pederson, T., Kasteelen, M., Pelissier, A., Petzel, J., Bell, J., Wilhelmsen, L., Gonzales, J., & Wagenaar, R. (2008). Using Legal Studies in Europe: Initial Findings. <https://doi.org/https://doi.org/10.2139/ssrn.1677820>.
- Malhotra, Y., & Galletta, D. (1999). Extending the technology acceptance model to account for social influence: theoretical bases and empirical validation. *Proceedings of the 32nd Annual Hawaii International Conference on Systems Sciences*. <https://doi.org/https://doi.org/10.1109/HICSS.1999.772658>.
- Mintu-Wimsatt, A., & Lozada, H. (2018). Business Analytics in the Marketing Curriculum: A Call for Integration. *Marketing Education Review*, 28, 1-5. <https://doi.org/https://doi.org/10.1080/10528008.2018.1436974>.
- Oprea, O., Hoinaru, R., Păcuraru-Ionescu, C., & Neamțu, D. (2022). Accounting for the future: practice, Artificial Intelligence and regulation. *Proceedings of the International Conference on Business Excellence*, 817 - 826. <https://doi.org/https://doi.org/10.2478/picbe-2022-0076>
- Pehlivanoglu, D., Lin, T., & Deceus, F. (2021). The role of analytical reasoning and source credibility on the evaluation of real and fake full-length news articles. *Cogn. Research*. <https://doi.org/https://doi.org/10.1186/s41235-021-00292-3>
- Prada, M., Domínguez, M., Vicario, J., Alves, P., Barbu, M., Podpora, M., & Spagnolini, U. (2020). Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees. *IEEE Access*, 212818-212836. <https://doi.org/https://doi.org/10.1109/ACCESS.2020.3040858>
- Reche, P., Rodríguez-García, A., García, G., & Jiménez, C. (2020). Analíticas de aprendizaje en educación superior: una revisión de la literatura científica de impacto. *IJERI: International Journal of Educational Research and Innovation*, 13, 32-46. <https://doi.org/DOI:10.46661/IJERI.4584>
- Rickardo, G., & Santos, M. (2023). Artificial intelligence: Its impact on employability. *World Journal of Advanced Research and Reviews*, 18(03), 198-203. <https://doi.org/https://doi.org/10.30574/wjarr.2023.18.3.1056>

- Ruffing, S., Wach, F., Spinath, F., Brünken, R., & Karbach, J. (2015). Learning strategies and general cognitive ability as predictors of gender- specific academic achievement. *Frontiers in Psychology*. <https://doi.org/10.3389/fpsyg.2015.01238>.
- Saha, G., Menon, R., Paulin, M., Yerasuri, S., Saha, H., & Dongol, P. (2023). The impact of artificial intelligence on business strategy and decision-making processes. *European Economic Letters*, 13(3), 926-934. <https://doi.org/10.52783/eel.v13i3.386>
- Telnova, H., & Popov, V. (2023). Modeling economic growth by intelligent data analysis . *National Aviation University*. . <https://doi.org/10.32782/2520-2200/2023-1-8>
- Universidad de Antioquia. (2024). Formación: Matriculados. *Universidad de Antioquia*. <https://www.udea.edu.co/wps/portal/udea/web/inicio/institucional/data-udea/formacion/matriculados>
- Yang, X., & Ge, J. (2022). Predicting Student Learning Effectiveness in Higher Education Based on Big Data Analysis. *Mobile Information Systems*. . <https://doi.org/10.1155/2022/8409780>.
- Zhang, P. (2024). A study on the management of big data technology in financial decision-making of enterprise cloud accounting. *Applied Mathematics and Nonlinear Sciences*, 9(1), 1-17. <https://doi.org/10.2478/amns.2023.2.00208>
- Zhao, X., Toronjo, H., & Shaw, C. (2022). Perceived communication effectiveness in implementation strategies: a measurement scale. *Implement Sci Commun*. <https://doi.org/10.1186/s43058-022-00284-4>
- Zimmerman, B. (2000). Self-Efficacy: An Essential Motive to Learn. *Contemporary educational psychology*, 21(1), 82-91. <https://doi.org/10.1006/CEPS.1999.1016>.
- Fisher, R. A. (1925). *Statistical Methods for Research Workers*. Edinburgh: Oliver and Boyd.
- IFAC. (2022). Exploring the IESBA Code: A Focus on Technology: Artificial Intelligence. International Federation of Accountants. Recuperado de <https://www.ifac.org>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. <https://doi.org/10.2307/249008>
- Adams, D. A., Nelson, R. R., & Todd, P. A. (1992). Perceived usefulness, ease of use, and usage of information technology: A replication. *MIS Quarterly*, 16(2), 227-247. <https://doi.org/10.2307/249577>





