



# Factores Determinantes en la Aceptación y Uso de Herramientas de Inteligencia Artificial en Estudiantes Universitarios: Un Estudio en la Universidad Técnica Federico Santa María, Mediante Modelado de Ecuaciones Estructurales.

Dr. Oscar Saavedra Rodríguez, Universidad Santa María, oscar.saavedra@usm.cl

Dr. Cristóbal Fernández Robin, Universidad Santa María, cristobal.fernandez@usm.cl

Ing. Macarena Ramos Briones, Universidad Santa María, macarena.ramos@usm.cl

## RESUMEN

Este estudio analiza los factores que influyen en la aceptación y uso de herramientas de inteligencia artificial (IA) entre estudiantes de la Universidad Técnica Federico Santa María, utilizando el Modelo Unificado de Aceptación y Uso de Tecnología (UTAUT) como marco teórico. En un contexto de transformación digital, la IA adquiere relevancia en la educación superior, especialmente en la investigación académica.

A través de un enfoque cuantitativo, se aplicó una encuesta estructurada que incluyó variables del modelo UTAUT e información sociodemográfica. El análisis, realizado mediante Modelado de Ecuaciones Estructurales (SEM), reveló que la expectativa de rendimiento y la expectativa de esfuerzo son los principales predictores de la intención de uso, siendo esta última un fuerte antecedente del uso efectivo de la IA.

En cambio, la influencia social y las condiciones facilitadoras no mostraron efectos significativos. Además, se identificaron diferencias según género, edad, experiencia previa y sede, lo que sugiere la necesidad de estrategias diferenciadas para fomentar el uso de estas tecnologías. Se recomienda que la universidad promueva el aprendizaje práctico y el acceso a recursos de apoyo, adaptando las acciones a las características del estudiantado.

**PALABRAS CLAVE:** Inteligencia Artificial (IA), UTAUT, Aceptación tecnológica, Educación superior, Ecuaciones Estructurales (SEM).

## INTRODUCCIÓN

La sociedad contemporánea se encuentra inmersa en la denominada Cuarta Revolución Industrial, caracterizada por la convergencia de tecnologías emergentes como la inteligencia artificial (IA), la robótica, la computación cuántica y la biotecnología (Schwab, 2016). Estas innovaciones están redefiniendo los modelos productivos y sociales, planteando importantes oportunidades, pero también desafíos éticos, regulatorios y educativos (Dávila & Agüero, 2023). Particularmente, la IA ha demostrado un gran potencial para transformar la educación superior, mediante la personalización del aprendizaje, la automatización de tareas administrativas y el análisis predictivo del rendimiento académico (Shahzad et al., 2024).

En las disciplinas científico-tecnológicas, como ingeniería, ciencias básicas y tecnologías aplicadas, el avance acelerado de la IA está reformulando los perfiles profesionales requeridos por el entorno laboral. La incorporación temprana de estas herramientas en la formación universitaria puede potenciar el desarrollo de habilidades técnicas, analíticas y de resolución de problemas, fundamentales para una inserción laboral exitosa (Herrera Chusin, 2024; Valles & Cuaya, 2014). No obstante, para una integración efectiva, es imprescindible comprender cómo los estudiantes perciben y adoptan estas tecnologías, considerando tanto factores individuales como contextuales.

Este estudio se propone analizar los factores que influyen en la aceptación y uso de herramientas de inteligencia artificial entre estudiantes de la Universidad Técnica Federico Santa María, utilizando como marco teórico el Modelo Unificado de Aceptación y Uso de Tecnología (UTAUT). Mediante un enfoque cuantitativo basado en modelado de ecuaciones estructurales (SEM), se busca identificar los principales determinantes de la intención y uso efectivo de estas herramientas, considerando además variables sociodemográficas como género, edad, experiencia previa y campus de estudio. Comprender estos factores permitirá elaborar recomendaciones estratégicas orientadas a optimizar la formación académica en el uso de IA, y fortalecer la preparación de los futuros profesionales frente a los desafíos del entorno digital.

En este contexto, se busca responder preguntas como: ¿cuáles son los factores que determinan la intención de uso de herramientas de inteligencia artificial por parte del estudiantado? ¿Qué relevancia tienen variables como la expectativa de rendimiento o la influencia social en este proceso? Asimismo, se explora si existen diferencias en la aceptación de estas tecnologías según variables como género, edad o sede universitaria.

## DESARROLLO

### REVISIÓN DE LA LITERATURA

La aceptación de nuevas tecnologías ha sido ampliamente estudiada a través de modelos teóricos que buscan explicar y predecir la intención y el comportamiento de uso. Entre los modelos más influyentes se encuentra el Modelo de Aceptación de Tecnología (TAM), propuesto por Davis (1985), que plantea que la utilidad percibida y la facilidad de uso percibida influyen en la actitud hacia el uso, la cual afecta la intención y finalmente el uso real de la tecnología. Si bien el TAM ha demostrado ser útil en diversos contextos, su enfoque limitado a variables individuales motivó el desarrollo de extensiones como el TAM 2 (Venkatesh & Davis, 2000), que incorpora factores sociales y cognitivos, y el TAM 3 (Venkatesh & Bala, 2008), que introduce variables como la ansiedad informática y la autoeficacia.

Una evolución significativa en este campo fue el desarrollo del Modelo Unificado de Aceptación y Uso de Tecnología (UTAUT), formulado por Venkatesh et al. (2003), que integra elementos de ocho modelos previos para ofrecer una visión más comprensiva. El UTAUT identifica cuatro constructos principales que influyen en la intención de uso y en el uso efectivo: expectativa de rendimiento, expectativa de esfuerzo, influencia social y condiciones facilitadoras. Estos factores, a su vez, están moderados por variables como la edad, el género, la experiencia y la voluntariedad de uso. El modelo ha sido validado en múltiples estudios, especialmente en

contextos organizacionales, incluyendo entornos educativos, donde permite analizar la adopción tecnológica desde una perspectiva tanto individual como contextual.

Finalmente, el UTAUT 2 (Venkatesh et al., 2012) amplía el modelo original para contextos de consumo, incorporando constructos como la motivación hedónica, el valor precio y el hábito, lo que lo hace más adecuado para estudios centrados en usuarios finales. No obstante, en investigaciones realizadas en entornos universitarios, el UTAUT original se ha mostrado más pertinente debido a su enfoque en factores organizacionales y sociales. Por ello, este estudio adopta el modelo UTAUT como base conceptual, dada su robustez teórica y su capacidad para capturar los determinantes de aceptación tecnológica en el ámbito educativo superior.

## **DESARROLLO DE HIPÓTESIS Y MODELO CONCEPTUAL**

En esta investigación se adopta el Modelo Unificado de Aceptación y Uso de la Tecnología (UTAUT) propuesto por (Venkatesh et al., 2003), por su robustez teórica y validación empírica en contextos educativos. Este modelo permite comprender los factores que influyen en la adopción de tecnologías, considerando tanto aspectos individuales como contextuales.

El UTAUT original integra cuatro constructos clave, expectativa de rendimiento, expectativa de esfuerzo, influencia social y condiciones facilitadoras, que influyen en la intención de uso y el uso efectivo de una tecnología. Además, incluye variables moderadoras como edad, género, experiencia previa y ubicación geográfica, que permiten matizar los efectos del modelo según las características de los usuarios.

A continuación, se presenta cada variable incluida en el modelo propuesto, junto con las hipótesis de investigación correspondientes.

### **1. Expectativa de rendimiento (ER)**

Se refiere al grado en que el/la estudiante cree que el uso de herramientas de inteligencia artificial (IA) contribuirá a mejorar su desempeño académico o eficiencia en tareas profesionales.

*H1: La expectativa de rendimiento influye positivamente en la intención de uso de herramientas de IA.*

### **2. Expectativa de esfuerzo (EE)**

Hace referencia a la facilidad percibida por parte del/la estudiante para aprender y utilizar herramientas de IA en su contexto académico.

*H2: La expectativa de esfuerzo influye positivamente en la intención de uso de herramientas de IA.*

### **3. Influencia social (IS)**

Corresponde al grado en que el/la estudiante percibe que personas significativas (pares, docentes, amigos) consideran que debería utilizar herramientas de IA.

*H3: La influencia social influye positivamente en la intención de uso de herramientas de IA.*

#### 4. Condiciones facilitadoras (CF)

Se refiere al grado en que el/la estudiante percibe contar con recursos, conocimientos y apoyo institucional para utilizar herramientas de IA.

**H4:** Las condiciones facilitadoras influyen positivamente en la intención de uso de herramientas de IA.

**H5:** Las condiciones facilitadoras influyen positivamente en el uso efectivo de herramientas de IA.

#### 5. Intención de uso (IU)

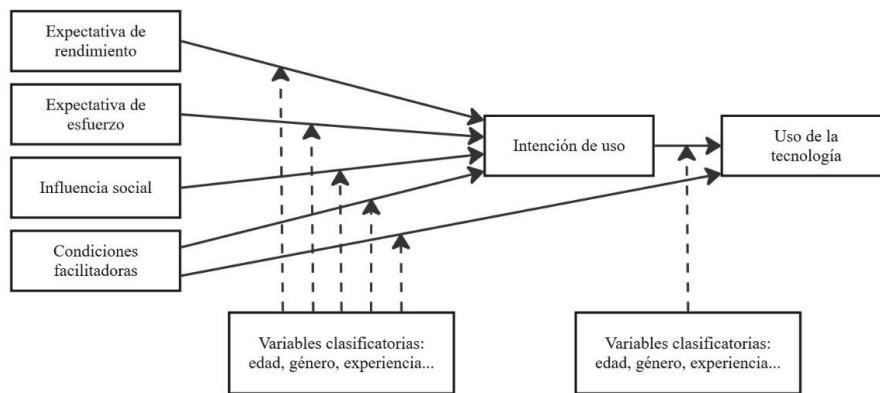
Es la disposición declarada por el/la estudiante a utilizar herramientas de IA en sus actividades académicas futuras.

**H6:** La intención de uso influye positivamente en el uso efectivo de herramientas de IA.

#### 6. Uso efectivo de la tecnología (U)

Representa la frecuencia y tipo de uso real de herramientas de IA por parte del/la estudiante en el contexto académico.

Este constructo se considera variable dependiente y se relaciona directamente con la intención de uso y las condiciones facilitadoras, además de estar moderado por variables sociodemográficas.



**Figura 1: Modelo Conceptual UTAUT**  
Fuente: Elaboración propia adaptada de Venkatesh et al. (2003)

## METODOLOGÍA

### Recolección de datos

Se elaboró una encuesta estructurada en línea a través de la plataforma SurveyMonkey, basada en una escala Likert de cinco puntos que mide el grado de acuerdo o desacuerdo de los estudiantes respecto de diferentes afirmaciones vinculadas a su uso y percepción de herramientas de inteligencia artificial. El cuestionario estuvo compuesto por 16 preguntas distribuidas en secciones correspondientes a cada variable del modelo UTAUT. Este fue adaptado a partir del instrumento propuesto por Herrera Díaz (2022), con modificaciones basadas en los estudios de Chatterjee & Bhattacharjee (2020) y Mohd Rahim et al. (2022).

Tabla 1: Cuestionario utilizado para la recolección de datos

<b>ER1</b>	El uso de estas Herramientas de Inteligencia Artificial mejora mi desempeño académico.
<b>ER2</b>	El uso de estas Herramientas de Inteligencia Artificial contribuye a mejorar mis habilidades académicas.
<b>ER3</b>	Cada vez que he usado una Herramienta de Inteligencia Artificial nueva, he tenido la sensación de que ha sido una buena inversión de mi tiempo.
<b>EE1</b>	Aprender a usar nuevas Herramientas de Inteligencia Artificial me resulta sencillo.
<b>EE2</b>	Las nuevas Herramientas de Inteligencia Artificial tienen una interfaz intuitiva y fácil de usar.
<b>EE3</b>	Toma poco tiempo aprender las nuevas Herramientas de Inteligencia Artificial.
<b>IS1</b>	Personas cuya opinión valoro suelen recomendar el uso de Herramientas de Inteligencia Artificial.
<b>IS2</b>	La sugerencia y recomendación de un amigo/a influye en mi decisión de utilizar Herramientas de Inteligencia Artificial.
<b>IS3</b>	Las personas que influyen en mi comportamiento piensan que debería usar Herramientas de Inteligencia Artificial.
<b>CF1</b>	La universidad proporciona apoyo para usar las nuevas Herramientas de Inteligencia Artificial.
<b>CF2</b>	He sentido que docentes o académicos/as promueven el uso de Herramientas de Inteligencia Artificial en el ámbito universitario.
<b>CF3</b>	En mi entorno académico, puedo acceder fácilmente a ayuda cuando tengo dificultades con Herramientas de Inteligencia Artificial.
<b>IU1</b>	Pretendo continuar usando estas Herramientas de Inteligencia Artificial en el futuro.
<b>IU2</b>	Utilizar estas Herramientas de Inteligencia Artificial será una parte importante de mis actividades académicas o laborales en el futuro.
<b>U1</b>	Durante la semana utilizo Herramientas de Inteligencia Artificial con regularidad.
<b>U2</b>	Adapto el uso de Herramientas de Inteligencia Artificial según las necesidades de cada actividad académica.

Fuente: Elaboración propia

La población objetivo correspondió a estudiantes de distintas carreras de la Universidad Técnica Federico Santa María de todas las sedes, excepto Concepción. Se utilizó un muestreo no probabilístico por conveniencia. Para garantizar un tamaño de muestra estadísticamente significativo, se aplicó la fórmula propuesta por Miot (2011), considerando una población total de 19.083 estudiantes, lo que arrojó un mínimo de 377 respuestas requeridas.

### Preparación y Análisis Preliminar de los Datos

Los datos fueron procesados en SPSS tras una revisión preliminar y limpieza que eliminó respuestas incompletas, patrones repetitivos y casos de estudiantes sin conocimiento de IA. Para

evaluar la confiabilidad del instrumento, se calculó el coeficiente alfa de Cronbach para cada variable del modelo UTAUT, considerando aceptables valores superiores a 0,7.

Se aplicó la prueba de Kolmogórov-Smirnov para examinar la normalidad de las variables y se evaluó la multicolinealidad mediante coeficientes de correlación de Pearson o Spearman, según la distribución de los datos. Se desarrolló un análisis descriptivo para caracterizar la muestra mediante medias, frecuencias, porcentajes y desviaciones estándar.

### **Análisis de Ecuaciones Estructurales (SEM)**

El análisis de ecuaciones estructurales se llevó a cabo utilizando AMOS. Se realizó un análisis factorial confirmatorio (AFC) modelando cada variable latente con sus respectivas variables observadas, evaluando la validez convergente de cada constructo. Se consideraron adecuadas las cargas factoriales estandarizadas superiores a 0,50 y estadísticamente significativas ( $p < 0,05$ ) (Hair et al., 2019).

Una vez modeladas las relaciones entre variables latentes acorde con UTAUT, se evaluó el ajuste global del modelo teórico. Si el ajuste no fue adecuado, se revisaron los índices de modificación ( $MI \geq 10$ ), implementando ajustes solo con justificación teórica y evaluando las mejoras con umbrales  $\Delta CFI \geq 0,005$  y  $\Delta RMSEA \leq -0,005$  (Cheung & Rensvold, 2002).

Posteriormente, se analizaron las rutas estructurales estimadas, eliminando aquellas no significativas ( $p > 0,05$ ) únicamente si su eliminación no afectaba negativamente el ajuste general ni contradecía el modelo teórico.

En una fase posterior, se efectuaron análisis de moderación. Para las variables categóricas (como género y campus), se aplicó un análisis multigrupo, siguiendo las recomendaciones metodológicas de Byrne (2016) y Hair et al. (2019). Este proceso incluyó la evaluación de la invarianza configural y métrica, y la comparación entre modelos libres y restringidos. Se consideró que una relación estructural difería significativamente entre grupos si la restricción producía un deterioro significativo del ajuste ( $p < 0,05$ ).

En cuanto a las variables continuas, se aplicó un análisis de interacción con variables latentes. Para ello, se centraron las variables involucradas y se incluyó en el modelo el producto entre la moderadora y la variable latente. Se interpretó la existencia de un efecto moderador cuando el coeficiente del término de interacción fue estadísticamente significativo ( $p < 0,05$ ), determinando su dirección según el signo del coeficiente estimado.

Para evaluar el ajuste del modelo, se consideraron los siguientes índices recomendados:

Tabla 2: Valores recomendados de índices de ajuste

Índice	Nombre completo	Ajuste bueno	Ajuste aceptable
CMIN/DF	Chi-cuadrado normalizado	< 3	< 5
SRMR	Standardized Root Mean Square Residual	< 0,05	< 0,08
RMSEA	Root Mean Square Error of Approximation	< 0,06	< 0,08
CFI	Comparative Fit Index	≥ 0,95	≥ 0,90
TLI	Tucker-Lewis Index	≥ 0,95	≥ 0,90

Fuente: Elaboración propia basada en Hair et al. (2019), Hu & Bentler (1999) y Kline (2016)

## RESULTADOS

### Validación del Instrumento y Análisis Preliminares

Para garantizar la validez del instrumento de medición, se realizó inicialmente una revisión de comprensión con un grupo reducido de personas, seguida de una encuesta piloto a cinco participantes que confirmaron la claridad y coherencia de los ítems.

La recolección final alcanzó 520 respuestas, de las cuales se excluyeron 50 por estar incompletas, 20 por presentar patrones de respuesta homogéneos y 11 casos que no respondieron la pregunta filtro sobre conocimiento de inteligencia artificial. La muestra final quedó compuesta por 439 casos válidos.

El análisis de confiabilidad mediante Alpha de Cronbach mostró valores superiores al umbral recomendado de 0,7 en todas las dimensiones, confirmando la consistencia interna del instrumento (Tabla 3).

Tabla 3: Análisis de confiabilidad de las dimensiones

Factores	Alpha de Cronbach
Expectativa de Rendimiento	0,760
Expectativa de Esfuerzo	0,747
Influencia Social	0,708
Condiciones Facilitadoras	0,702
Intención de Uso	0,729
Uso	0,757

Fuente: Elaboración propia

La prueba de Kolmogórov-Smirnov reveló que los datos no siguen una distribución normal ( $p < 0,001$  en todos los ítems), por lo que se descartó el uso de pruebas paramétricas. El análisis de correlación de Spearman no detectó problemas de multicolinealidad, ya que ningún coeficiente superó el valor absoluto de 0,7.

## Resultados descriptivos

La muestra estuvo compuesta por 439 estudiantes con edad media de 20,66 años, con predominio masculino (70,84%) y participación equilibrada entre campus: San Joaquín (33,26%), Casa Central Valparaíso (32,35%), Vitacura (23,01%) y Viña del Mar (11,39%).

Los estadísticos descriptivos revelaron percepciones mayoritariamente positivas hacia la inteligencia artificial. Expectativa de Rendimiento y Expectativa de Esfuerzo presentaron valores elevados (medias entre 3,88-4,22), indicando que los estudiantes consideran estas herramientas útiles y fáciles de usar. Influencia Social mostró valoraciones moderadas (medias 3,32-3,84), mientras que Condiciones Facilitadoras presentó los valores más bajos (medias 2,47-3,31), sugiriendo limitaciones en recursos y apoyo institucional. La Intención de Uso alcanzó la media más alta (4,29) y el Uso mostró valores elevados (3,87-4,10), reflejando buena aceptación práctica.

## Análisis del modelo estructural

Para validar la estructura del instrumento, se realizó un Análisis Factorial Confirmatorio (AFC) utilizando AMOS con el método de estimación por máxima verosimilitud con corrección Bootstrap, dado que no se cumplía el supuesto de normalidad multivariada.

El modelo de medición mostró que todas las cargas factoriales estandarizadas fueron superiores a 0,5 y estadísticamente significativas ( $p < 0,05$ ), indicando adecuada validez convergente. Los índices globales de ajuste fueron satisfactorios: CMIN/DF = 2,163; SRMR = 0,048; RMSEA = 0,052; CFI = 0,955; TLI = 0,940, respaldando la validez factorial del instrumento.

Posteriormente, se estimó el modelo estructural UTAUT inicial, que incluía todas las relaciones teóricas propuestas (Figura 2).

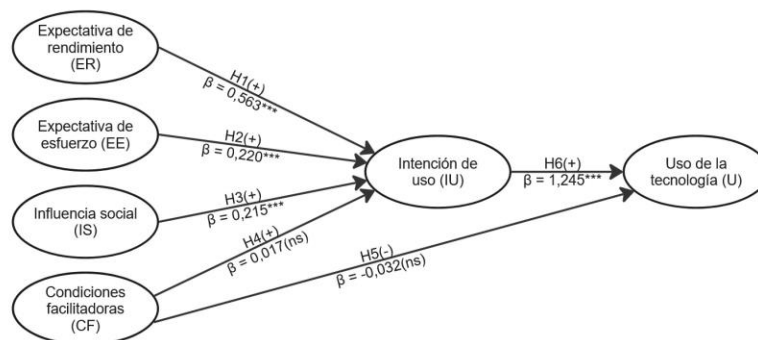


Figura 2: Modelo estructural inicial  
 Fuente: Elaboración propia

El modelo inicial mostró ajuste deficiente (CMIN/DF = 4,051; SRMR = 0,153; RMSEA = 0,083; CFI = 0,871; TLI = 0,842), sugiriendo mala especificación. Se añadieron progresivamente, según los índices de modificación, las covarianzas entre factores exógenos (ER ↔ IS, ER ↔ EE, EE ↔ IS), mejorando significativamente el ajuste.

Sin embargo, el análisis de las relaciones estructurales reveló que Influencia Social y Condiciones Facilitadoras no presentaron efectos directos significativos (Tabla 4).

Tabla 4. Coeficientes estructurales del modelo con covarianzas

Relación	Coefficiente	C.R.	P	Significancia
IU ← ER	0,590	7,875	<,001	***( $p < 0,001$ )
IU ← EE	0,154	2,249	0,025	*( $p < 0,05$ )
IU ← IS	0,117	1,468	0,142	ns
IU ← CF	0,003	0,07	0,944	ns
U ← CF	-0,031	-0,537	0,591	ns
U ← IU	1,244	14,201	<,001	***( $p < 0,001$ )

Fuente: Elaboración propia

Siguiendo la teoría UTAUT, que indica que la influencia de IS y CF puede ser contingente al contexto, se eliminaron ambos constructos para obtener un modelo más parsimonioso centrado en ER, EE, IU y U (Figura 3).




Figura 3: Modelo estructural final  
 Fuente: Elaboración propia

El modelo final presentó excelente ajuste cumpliendo todos los criterios establecidos (CMIN/DF = 2,515; SRMR = 0,037; RMSEA = 0,059; CFI = 0,971; TLI = 0,958), con todas las relaciones estructurales significativas. La Expectativa de Rendimiento mostró el efecto más fuerte sobre la Intención de Uso ( $\beta = 0,637$ ,  $p < 0,001$ ), seguida por la Expectativa de Esfuerzo ( $\beta = 0,191$ ,  $p = 0,004$ ). La Intención de Uso predijo significativamente el Uso real ( $\beta = 1,216$ ,  $p < 0,001$ ).

## Análisis moderador

### 1. Género

El análisis multigrupo confirmó invarianza configural y métrica, permitiendo comparar las trayectorias estructurales. El análisis reveló que el género modera significativamente las relaciones ER → IU ( $\Delta$ CMIN = 5,256,  $p = 0,022$ ) y EE → IU ( $\Delta$ CMIN = 5,602,  $p = 0,018$ ), mientras que IU → U permaneció invariante entre grupos.

Los resultados mostraron que en hombres, la Expectativa de Rendimiento tuvo mayor impacto ( $\beta = 0,702$ ,  $p < 0,001$ ) comparado con mujeres ( $\beta = 0,475$ ,  $p < 0,001$ ), mientras que la Expectativa de Esfuerzo solo fue significativa en mujeres ( $\beta = 0,478$ ,  $p < 0,001$ ) pero no en hombres ( $\beta = 0,082$ , ns). Esto indica que los hombres se basan principalmente en la utilidad percibida, mientras que las mujeres consideran equilibradamente tanto la utilidad como la facilidad de uso.

### 2. Campus

El análisis por campus confirmó invarianza configural y métrica. Se identificó moderación significativa en las relaciones  $ER \rightarrow IU$  ( $\Delta CMIN = 17,680$ ,  $p = 0,001$ ) y  $EE \rightarrow IU$  ( $\Delta CMIN = 9,269$ ,  $p = 0,026$ ).

En Casa Central Valparaíso, San Joaquín y Viña del Mar, solo la Expectativa de Rendimiento mostró efectos significativos sobre la Intención de Uso, con Casa Central presentando el mayor efecto ( $\beta = 0,904$ ,  $p < 0,001$ ), seguido por San Joaquín ( $\beta = 0,736$ ,  $p < 0,001$ ) y Viña del Mar ( $\beta = 0,447$ ,  $p < 0,001$ ). En estos tres campus, la Expectativa de Esfuerzo no fue significativa.

En contraste, Vitacura presentó un patrón diferenciado donde solo la Expectativa de Esfuerzo fue significativa ( $\beta = 0,529$ ,  $p < 0,001$ ), mientras que la Expectativa de Rendimiento no mostró efectos significativos. Esto sugiere que Vitacura es el único campus donde la facilidad de uso percibida es más determinante que la utilidad percibida para la intención de adoptar herramientas de IA.

### 3. Edad y Experiencia

Los análisis de moderación por edad y experiencia no mostraron efectos de interacción significativos ( $p > 0,05$  para todas las interacciones evaluadas). Sin embargo, ambas variables presentaron efectos directos positivos sobre la Intención de Uso. Para edad, se observó un efecto directo significativo ( $\beta = 0,026-0,029$ ,  $p < 0,05$ ), mientras que para experiencia el efecto fue más fuerte ( $\beta = 0,438-0,469$ ,  $p < 0,001$ ). Esto sugiere que estudiantes de mayor edad y con más experiencia en tecnologías digitales muestran mayor intención de usar herramientas de IA, pero estas variables no modifican la fuerza de las relaciones estructurales del modelo.

## CONCLUSIONES

Este estudio revela que la adopción de herramientas de IA en el contexto universitario responde a una lógica pragmática e individualizada. Los estudiantes evalúan estas tecnologías principalmente desde una perspectiva utilitaria, priorizando los beneficios académicos concretos por encima de factores externos como el apoyo institucional o las presiones sociales. Esta tendencia sugiere una generación de estudiantes que ejerce autonomía tecnológica, tomando decisiones basadas en su propia evaluación costo-beneficio.

La ausencia de influencia significativa de las condiciones facilitadoras indica que los estudiantes no esperan que las instituciones les proporcionen acceso o formación en IA, sino que buscan y adoptan estas herramientas de manera independiente. Esto plantea importantes implicaciones para las universidades, que pueden estar quedando rezagadas en la integración formal de tecnologías que sus estudiantes ya utilizan informalmente.

Las diferencias por género y campus revelan patrones de adopción diferenciados que requieren estrategias segmentadas. Particularmente, la menor sensibilidad al esfuerzo requerido en ciertos grupos sugiere mayor confianza tecnológica o experiencia previa, lo que podría crear brechas en el aprovechamiento educativo de estas herramientas.

El efecto directo de la edad y experiencia previa sobre la intención de uso confirma que la familiaridad tecnológica reduce barreras de adopción. Esto implica que las diferencias generacionales y de experiencia pueden profundizarse si no se implementan estrategias inclusivas de alfabetización en IA.

## REFERENCIAS

- Byrne, B. M. (2016). *Structural Equation Modeling With AMOS: Basic Concepts, Applications, and Programming* (Tercera ed.). Routledge. <https://doi.org/10.4324/9781315757421>
- Chatterjee, S., & Bhattacharjee, K. K. (2020). Adoption of artificial intelligence in higher education: a quantitative analysis using structural equation modelling. *Educ Inf Technol*, 25, 3443–3463. <https://doi.org/10.1007/s10639-020-10159-7>
- Cheung, G. W., & Rensvold, R. B. (2002). Evaluating Goodness-of-Fit Indexes for Testing Measurement Invariance. *Structural Equation Modeling*, 9(2), 233-255. [https://doi.org/10.1207/S15328007SEM0902\\_5](https://doi.org/10.1207/S15328007SEM0902_5)
- Dávila, R. C., & Agüero, E. D. (2023). *Desafíos éticos de la inteligencia artificial: implicaciones para la sociedad y la economía*. SciELO: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1990-86442023000500137&lng=es&tng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442023000500137&lng=es&tng=es)
- Davis, F. D. (1985). *A technology acceptance model for empirically testing new end-user information systems: theory and results*. Massachusetts Institute of Technology.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (Octava ed.). Cengage.
- Herrera Chusin, K. A. (2024). *Análisis exploratorio de herramientas de inteligencia artificial aplicadas a la Ingeniería Industrial*. Ecuador: Universidad Técnica de Cotopaxi. <http://repositorio.utc.edu.ec/handle/27000/12042>
- Herrera Díaz, M. A. (2022). *Estudio De Los Factores Que Afectan La Aceptación Y Uso De Las Tecnologías De La Información En Los Estudiantes De Ingeniería Civil Industrial De La Universidad Federico Santa María*. Universidad Técnica Federico Santa María, Departamento De Industrias.
- Hu, L.-t., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6(1), 1-55. <https://doi.org/10.1080/10705519909540118>
- Kline, R. B. (2016). *Principles and Practice of Structural Equation Modeling* (Cuarta ed.). The Guilford Press.
- Miot, H. A. (2011). Tamanho da amostra em estudos clínicos e experimentais. *Jornal Vascular Brasileiro*, 10(4), 275–278. <https://doi.org/10.1590/S1677-54492011000400001>
- Mohd Rahim, N. I., A. Iahad, N., Yusof, A. F., & A. Al-Sharafi, M. (2022). AI-Based Chatbots Adoption Model for Higher-Education Institutions: A Hybrid PLS-SEM-Neural Network Modelling Approach. *Sustainability*, 19(12726), 14. <https://doi.org/10.3390/su141912726>
- Schwab, K. (2016). *La cuarta revolución industrial*. España: Penguin Random House Grupo Editorial España.
- Shahzad, M. F., Xu, S., Yang, X., Lim, W., & Khan, Q. (2024, Abril 15). *Artificial intelligence and social media on academic performance and mental well-being: Student perceptions of positive impact in the age of smart learning*. sciencedirect: <https://doi.org/10.1016/j.heliyon.2024.e29523>
- Valles, J. A., & Cuaya, G. (2014). *La relevancia de la inteligencia artificial en la ingeniería industrial*. Instituto Tecnológico Superior de Huichapan.
- Venkatesh, V., & Bala, H. (2008). Technology Acceptance Model 3 and a Research Agenda on Interventions. *Decision Sciences*, 39(2), 273-315. <https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V., & Davis, F. D. (2000). A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. *Management Science*, 46(2), 186-204. <https://doi.org/10.1287/mnsc.46.2.186.11926>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: toward a unified view. *MIS Quarterly*. <https://doi.org/10.2307/30036540>
- Venkatesh, V., Thong, J. Y., & Xu, X. (2012, Marzo). *Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology*. JSTOR: <https://doi.org/10.2307/41410412>