

# UNEMI

UNIVERSIDAD ESTATAL DE MILAGRO

REPÚBLICA DEL ECUADOR

UNIVERSIDAD ESTATAL DE MILAGRO

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO

PROYECTO DE INVESTIGACIÓN APLICADA Y/O DE DESARROLLO

PREVIO A LA OBTENCIÓN DEL TÍTULO DE:

**MAGÍSTER EN INTELIGENCIA ARTIFICIAL APLICADA A LA  
EDUCACIÓN**

**TEMA:**

**Brecha entre competencia conceptual y práctica pedagógica en el uso de  
inteligencia artificial generativa en docentes de la Universidad Estatal  
de Milagro, 2025**

**Autor:**

VINUEZA MORALES MARIUXI GEOVANNA

CASTRO CASTILLO GRACIELA JOSEFINA

**Tutor:**

Víctor Alejandro Bosquez Barcenas

*Milagro, 2026*

## Derechos de autor

**Sr. Dr.**

**Fabricio Guevara Viejó**

Rector de la Universidad Estatal de Milagro

Presente.

Yo, VINUEZA MORALES MARIUXI GEOVANNA Y CASTRO CASTILLO GRACIELA JOSEFINA en calidad de autor y titular de los derechos morales y patrimoniales de este informe de investigación, mediante el presente documento, libre y voluntariamente cedo los derechos de Autor de este proyecto de desarrollo, que fue realizada como requisito previo para la obtención de mi Grado, de **MAGÍSTER EN INTELIGENCIA ARTIFICIAL APLICADA A LA EDUCACIÓN**, como aporte a la Línea de Investigación EDUCACIÓN, CULTURA, TECNOLOGÍA EN INNOVACIÓN PARA LA SOCIEDAD – MAEB de conformidad con el Art. 114 del Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, concedo a favor de la Universidad Estatal de Milagro una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos. Conservo a mi favor todos los derechos de autor sobre la obra, establecidos en la normativa citada.

Así mismo, autorizo a la Universidad Estatal de Milagro para que realice la digitalización y publicación de este Proyecto de Investigación en el repositorio virtual, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

El autor declara que la obra objeto de la presente autorización es original en su forma de expresión y no infringe el derecho de autor de terceros, asumiendo la responsabilidad por cualquier reclamación que pudiera presentarse por esta causa y liberando a la Universidad de toda responsabilidad.

Milagro, 24 de marzo de 2026



VINUEZA MORALES MARIUXI GEOVANNA  
CÉDULA 0917189664



CASTRO CASTILLO GRACIELA JOSEFINA  
CÉDULA

## Aprobación del tutor del Trabajo de Titulación

Yo, Víctor Alejandro Bosquez Barcenes en mi calidad de director del trabajo de titulación, elaborado por VINUEZA MORALES MARIUXI GEOVANNA Y CASTRO CASTILLO GRACIELA JOSEFINA, cuyo tema es Brecha entre competencia conceptual y práctica pedagógica en el uso de inteligencia artificial generativa en docentes de la Universidad Estatal de Milagro, 2025, que aporta a la Línea de Investigación EDUCACIÓN, CULTURA, TECNOLOGÍA EN INNOVACIÓN PARA LA SOCIEDAD – MAEB , previo a la obtención del Grado **MAGÍSTER EN INTELIGENCIA ARTIFICIAL APLICADA A LA EDUCACIÓN**. Trabajo de titulación que consiste en una propuesta innovadora que contiene, como mínimo, una investigación exploratoria y diagnóstica, base conceptual, conclusiones y fuentes de consulta, considero que el mismo reúne los requisitos y méritos necesarios para ser sometido a la evaluación por parte del tribunal calificador que se designe, por lo que lo **APRUEBO**, a fin de que el trabajo sea habilitado para continuar con el proceso de titulación de la alternativa de Informe de Investigación de la Universidad Estatal de Milagro.

Milagro, 24 de marzo de 2026



Víctor Alejandro Bosquez Barcenes

0201819570

**FACULTAD DE POSGRADO**  
**ACTA DE SUSTENTACIÓN**  
**MAESTRÍA EN INTELIGENCIA ARTIFICIAL PARA LA EDUCACIÓN**

En la Facultad de Posgrado de la Universidad Estatal de Milagro, a los cuatro días del mes de mayo del dos mil veintiseis, siendo las 16:00 horas, de forma VIRTUAL comparece el/la maestrante LIC. CASTRO CASTELLO GRACIELA JOSEFINA, a defender el Trabajo de Titulación denominado " BRECHA ENTRE COMPETENCIA CONCEPTUAL Y PRÁCTICA PEDAGÓGICA EN EL USO DE INTELIGENCIA ARTIFICIAL GENERATIVA EN DOCENTES DE LA FACULTAD DE CIENCIAS E INGENIERÍAS DE LA UNIVERSIDAD ESTATAL DE MILAGRO, 2025", ante el Tribunal de Calificación integrado por: Mgtr. DELGADO SANTILLAN DAVID ANTONIO, Presidente(a), Mgs MENDOZA CARRERA JEFFERSON ESTUARDO en calidad de Vocal; y, Mgtr. CAMPUZANO RODRIGUEZ SANDRA MARICELA que actúa como Secretaria(a).

Una vez defendido el trabajo de titulación, examinado por los integrantes del Tribunal de Calificación, escuchada la defensa y las preguntas formuladas sobre el contenido del mismo al maestrante compareciente, durante el tiempo reglamentario, obtuvo las siguientes calificaciones:

TRABAJO DE TITULACIÓN	60.00
DEFENSA ORAL	40.00
PROMEDIO	100.00
EQUIVALENTE	EXCELENTE

Para constancia de lo actuado firman en unidad de acto el Tribunal de Calificación, siendo las 17:01 horas.



Mgtr. DELGADO SANTILLAN DAVID ANTONIO  
PRESIDENTE DEL TRIBUNAL

Mgtr. DELGADO SANTILLAN DAVID ANTONIO  
PRESIDENTE DEL TRIBUNAL



Mgs MENDOZA CARRERA JEFFERSON ESTUARDO  
VOCAL

Mgs MENDOZA CARRERA JEFFERSON ESTUARDO  
VOCAL



Mgtr. CAMPUZANO RODRIGUEZ SANDRA MARICELA  
SECRETARIA DEL TRIBUNAL

Mgtr. CAMPUZANO RODRIGUEZ SANDRA MARICELA  
SECRETARIA DEL TRIBUNAL



LIC. CASTRO CASTELLO GRACIELA JOSEFINA  
MAGISTER

LIC. CASTRO CASTELLO GRACIELA JOSEFINA  
MAGISTER

**FACULTAD DE POSGRADO**  
**ACTA DE SUSTENTACIÓN**  
**MAESTRÍA EN INTELIGENCIA ARTIFICIAL PARA LA EDUCACIÓN**

En la Facultad de Posgrado de la Universidad Estatal de Milagro, a los cuatro días del mes de mayo del dos mil veintiseis, siendo las 16:00 horas, de forma VIRTUAL compareció el/la maestrante, LIC. VINUEZA MORALES MARSUJO GIOVANNA, a defender el Trabajo de Titulación denominado: " BRECHA ENTRE COMPETENCIA CONCEPTUAL Y PRÁCTICA PEDAGÓGICA EN EL USO DE INTELIGENCIA ARTIFICIAL GENERATIVA EN DOCENTES DE LA FACULTAD DE CIENCIAS E INGENIERÍAS DE LA UNIVERSIDAD ESTATAL DE MILAGRO, 2026", ante el Tribunal de Calificación Integrado por: Mgr. DELGADO SANTILLAN DAVID ANTONIO, (Presidencia), Mgs MENDOZA CARRERA JEFFERSON ESTUARDO en calidad de Vocal y, Mgr. CAMPUZANO RODRIGUEZ SANDRA MARICELA que actúa como Secretaria.

Una vez defendido el trabajo de titulación; examinado por los integrantes del Tribunal de Calificación, escuchada la defensa y las preguntas formuladas sobre el contenido del mismo al maestrante compareciente, durante el tiempo reglamentario, obtuvo las siguientes calificaciones:

TRABAJO DE TITULACIÓN	60.00
DEFENSA ORAL	40.00
PROMEDIO	100.00
EQUIVALENTE	EXCELENTE

Para constancia de lo actuado firman en unidad de acto el Tribunal de Calificación, siendo las 17:31 horas.



Mgr. DELGADO SANTILLAN DAVID ANTONIO  
PRESIDENCIA DEL TRIBUNAL



Mgs MENDOZA CARRERA JEFFERSON ESTUARDO  
VOCAL



Mgr. CAMPUZANO RODRIGUEZ SANDRA MARICELA  
SECRETARÍA DEL TRIBUNAL



LIC. VINUEZA MORALES MARSUJO GIOVANNA  
MAESTRANTE

## DEDICATORIA

Dedico este trabajo de investigación, en primer lugar, a Dios, por ser guía constante en mi vida, por brindarme fortaleza, sabiduría y perseverancia para alcanzar cada meta propuesta.

A mi familia, por su amor incondicional, comprensión y apoyo permanente durante este proceso académico. Su presencia ha sido un pilar fundamental para continuar con dedicación, responsabilidad y compromiso.

A mis estudiantes, quienes constituyen una fuente constante de inspiración y motivación para seguir aportando al fortalecimiento de la educación. Cada experiencia compartida ha reafirmado mi vocación docente y mi compromiso con la formación de profesionales íntegros, críticos y humanos.

A la Universidad Estatal de Milagro, por ser un espacio de crecimiento académico, profesional y humano, y por permitirme contribuir desde la gestión educativa al desarrollo de procesos formativos de calidad.

Finalmente, dedico este logro a todas aquellas personas que, de una u otra manera, han acompañado este camino, brindándome palabras de aliento, confianza y apoyo para culminar satisfactoriamente esta etapa significativa de mi vida profesional.

**PhD. Mariuxi Vinueza**  
**MSc. Graciela Castro Castillo**

## AGRADECIMIENTOS

(APA Séptima edición)

Expresamos nuestro profundo agradecimiento a Dios, por concedernos la sabiduría, fortaleza y perseverancia necesarias para culminar este importante proceso académico y profesional.

A nuestras familias, por su amor incondicional, comprensión y apoyo permanente durante cada etapa de este camino. Su presencia ha sido fundamental para mantenernos firmes en la consecución de esta meta.

A la **Universidad Estatal de Milagro**, por brindarnos la oportunidad de fortalecer nuestra formación académica, investigativa y profesional, en un entorno orientado a la calidad, la innovación y el compromiso con la educación superior.

Extendemos un especial agradecimiento a nuestros docentes, colegas y a todas aquellas personas que, de una u otra manera, aportaron con su guía, colaboración y palabras de aliento para el desarrollo y culminación de este trabajo de investigación.

Finalmente, agradecemos a quienes acompañaron este proceso con confianza y apoyo, permitiéndonos alcanzar un logro significativo que reafirma nuestro compromiso con la educación, la investigación y el servicio a la sociedad.

**PhD. Mariuxi Vinueza**

**MSc. Graciela Castro Castillo**

## Resumen

La integración de la inteligencia artificial generativa en la educación superior ha generado una paradoja documentada a nivel global: los docentes universitarios acumulan conocimiento declarativo sobre estas herramientas con mayor rapidez de la que logran trasladarlo a transformaciones reales de su práctica pedagógica. El presente estudio examinó esta brecha en los docentes de la Facultad de Ciencias de la Ingeniería de la Universidad Estatal de Milagro durante el año 2025. El objetivo general fue determinar la relación entre la competencia conceptual en IA generativa y la práctica pedagógica con estas herramientas, así como identificar las variables que modulan dicha relación. Se empleó un enfoque cuantitativo con diseño descriptivo-correlacional no experimental de corte transversal. La muestra fue censal: participaron 68 docentes activos, lo que representó una tasa de respuesta del 85%. El instrumento utilizado fue la Escala ECCPP-IAG, elaborada y validada específicamente para este estudio, con cuatro dimensiones: competencia conceptual (12 ítems,  $\alpha = 0,815$ ), práctica pedagógica (15 ítems,  $\alpha = 0,965$ ), autoeficacia docente (10 ítems,  $\alpha = 0,918$ ) y actitudes hacia la IA (8 ítems,  $\alpha = 0,927$ ). Los resultados revelaron que la competencia conceptual alcanzó una media del 69,6% del rango máximo posible, con el 76,5% de los participantes en nivel alto, mientras que la práctica pedagógica obtuvo el 64,1%, con el 55,9% en nivel alto, configurando una brecha de 5,44 puntos porcentuales. La correlación de Pearson entre ambas variables fue  $r = 0,443$  ( $p < 0,001$ ;  $R^2 = 0,196$ ). El modelo de regresión múltiple reveló que la autoeficacia docente es el predictor dominante de la práctica pedagógica ( $\beta = 0,668$ ;  $p < 0,001$ ), mientras que la competencia conceptual pierde significación cuando aquella es controlada ( $\beta = 0,030$ ;  $p = 0,800$ ). Ninguna variable sociodemográfica produjo diferencias significativas en las variables principales, pero la recencia de la formación sí resultó determinante ( $H = 8,405$ ;  $p = 0,038$ ). Se concluye que la brecha conocimiento-práctica en IA generativa no es atribuible al déficit de información sino a la insuficiente autoeficacia de integración pedagógica, lo que fundamenta un programa de formación continua propuesto como resultado aplicado del estudio.

**Palabras clave:** inteligencia artificial generativa, práctica pedagógica, competencia conceptual docente, brecha conocimiento-práctica, formación continua del profesorado.

## Abstract

The integration of generative artificial intelligence in higher education has produced a globally documented paradox: university teachers accumulate declarative knowledge about these tools faster than they manage to translate it into real transformations of their pedagogical practice. This study examined such a gap among teachers at the Faculty of Engineering and Sciences of the Universidad Estatal de Milagro during 2025. The general objective was to determine the relationship between conceptual competence in generative AI and pedagogical practice with these tools, as well as to identify the variables that moderate this relationship. A quantitative approach was used with a non-experimental, descriptive-correlational, cross-sectional design. The sample was census-based: 68 active teachers participated, representing an 85% response rate. The instrument used was the ECCPP-IAG Scale, specifically designed and validated for this study, with four dimensions: conceptual competence (12 items,  $\alpha = .815$ ), pedagogical practice (15 items,  $\alpha = .965$ ), teaching self-efficacy (10 items,  $\alpha = .918$ ), and attitudes toward AI (8 items,  $\alpha = .927$ ). Results showed that conceptual competence reached a mean of 69.6% of the maximum possible range, with 76.5% of participants at a high level, while pedagogical practice reached 64.1%, with 55.9% at a high level, establishing a gap of 5.44 percentage points. The Pearson correlation between both variables was  $r = .443$  ( $p < .001$ ;  $R^2 = .196$ ). The multiple regression model revealed that teaching self-efficacy is the dominant predictor of pedagogical practice ( $\beta = .668$ ;  $p < .001$ ), while conceptual competence loses significance when self-efficacy is controlled ( $\beta = .030$ ;  $p = .800$ ). No sociodemographic variable produced significant differences in the main variables; however, training recency was a determining factor ( $H = 8.405$ ;  $p = .038$ ). It is concluded that the knowledge-practice gap in generative AI is not attributable to an information deficit but to insufficient pedagogical integration self-efficacy, which underpins a continuous professional development program proposed as an applied outcome of the study.

**Keywords:** generative artificial intelligence, pedagogical practice, teacher conceptual competence, knowing-doing gap, continuous teacher training.

## Lista de Figuras

Figura 1 Perfil de puntuaciones por subdimensión en Competencia Conceptual y Práctica Pedagógica (% del rango máximo posible), docentes FACI-UNEMI, 2025.....	32
Figura 2 Diagrama radial de las cuatro dimensiones del instrumento: síntesis del perfil docente en IAG, FACI-UNEMI, 2025 .....	34
Figura 3 Distribución porcentual de docentes por nivel de desempeño en Competencia Conceptual y Práctica Pedagógica (Alto / Medio / Bajo), FACI-UNEMI, 2025 .....	35
Figura 4 Perfil de autoeficacia docente en IAG por ítem y subdimensión (% del rango máximo, escala 1–5), FACI-UNEMI, 2025 .....	37
Figura 5 Diagrama de dispersión con línea de regresión OLS entre Competencia Conceptual y Práctica Pedagógica (valores normalizados al % del rango), docentes FACI-UNEMI, 2025. ....	41
Figura 6 Matriz de correlaciones de Pearson entre las cuatro dimensiones del estudio: Competencia Conceptual (CC), Práctica Pedagógica (PP), Autoeficacia (AE) y Actitudes (ACT), docentes FACI-UNEMI, 2025 .....	46
Figura 7 Coeficientes de regresión estandarizados ( $\beta$ ) del modelo de predicción de la Práctica Pedagógica a partir de Competencia Conceptual, Autoeficacia y Actitudes, docentes FACI-UNEMI, 2025.....	48
Figura 8 Puntuaciones en CC, PP y AE y magnitud de la brecha según recencia de la última capacitación en tecnologías educativas, docentes FACI-UNEMI, 2025.....	50
Figura 9 Brecha entre Competencia Conceptual y Práctica Pedagógica (puntos porcentuales) por carrera docente, FACI-UNEMI, 2025 — Gráfico de mancuernas (dumbbell plot)	52

## Lista de Tablas

Tabla 1 Caracterización sociodemográfica de la muestra (n = 68) .....	25
Tabla 2 Índices de confiabilidad por dimensión.....	26
Tabla 3 Estadísticos descriptivos por ítem — Competencia Conceptual (escala 1–7, n = 68) .....	27
Tabla 4 Distribución de frecuencias y forma de la distribución — Competencia Conceptual (n = 68).....	28
Tabla 5 Estadísticos descriptivos por ítem — Práctica Pedagógica (escala 1–5, n = 68) ....	29
Tabla 6 Distribución de frecuencias y forma de la distribución — Práctica Pedagógica (n = 68).....	30
Tabla 7 Comparación de medias por subdimensión — Práctica Pedagógica .....	31
Tabla 8 Comparación de medias globales entre las dos variables principales .....	32
Tabla 9 Clasificación por nivel en cada dimensión principal .....	35
Tabla 10 Estadísticos descriptivos por ítem — Autoeficacia docente (escala 1–5, n = 68). 36	
Tabla 11 Subdimensiones de la Autoeficacia docente .....	37
Tabla 12 Estadísticos descriptivos por ítem — Actitudes hacia la IAG en el aula (escala 1–7, n = 68).....	39
Tabla 13 Prueba de Kolmogorov-Smirnov para las variables principales (n = 68) .....	40
Tabla 14 Coeficientes de correlación entre Competencia Conceptual y Práctica Pedagógica .....	41
Tabla 15 Comparación de medias en Competencia Conceptual y Práctica Pedagógica según variables sociodemográficas.....	42
Tabla 16 Comparación de medias por carrera/área de conocimiento.....	44

Tabla 17 Comparación de medias según recencia de la capacitación en tecnologías educativas.....	45
Tabla 18 Modelo de regresión simple: Competencia Conceptual → Práctica Pedagógica .	45
Tabla 19 Modelo de regresión múltiple: Práctica Pedagógica ~ CC + AE + ACT (n = 68) ...	46
Tabla 20 Brechas CC%–PP% y autoeficacia según recencia de la última capacitación en tecnologías educativas .....	48
Tabla 21 Brechas CC%–PP% y autoeficacia según frecuencia de uso de IAG .....	50
Tabla 22 Brecha conocimiento-práctica según carrera docente .....	51
Tabla 23 Prueba t pareada para la diferencia entre Competencia Conceptual y Práctica Pedagógica (valores normalizados al rango, n = 68) .....	52

## Lista de Siglas / Acrónimos

**AFC** — Análisis Factorial Confirmatorio

**AE** — Autoeficacia docente en inteligencia artificial generativa (*dimensión del instrumento ECCPP-IAG*)

**AI-TPACK** — *Artificial Intelligence — Technological Pedagogical Content Knowledge* (Marco de conocimiento tecnológico-pedagógico del contenido aplicado a la inteligencia artificial)

**ANOVA** — *Analysis of Variance* (Análisis de Varianza)

**APA** — *American Psychological Association* (Asociación Americana de Psicología)

**CACES** — Consejo de Aseguramiento de la Calidad de la Educación Superior

**CC** — Competencia Conceptual en inteligencia artificial generativa (*dimensión del instrumento ECCPP-IAG*)

**CEPAL** — Comisión Económica para América Latina y el Caribe

**CES** — Consejo de Educación Superior

**CFI** — *Comparative Fit Index* (Índice de Ajuste Comparativo)

**DigComp** — *Digital Competence Framework* (Marco Europeo de Competencia Digital)

**DigCompEdu** — *Digital Competence Framework for Educators* (Marco Europeo de Competencia Digital para Docentes)

**ECCPP-IAG** — Escala de Competencia Conceptual y Práctica Pedagógica en Inteligencia Artificial Generativa (*instrumento construido y validado en este estudio*)

**FACI** — Facultad de Ciencias de la Ingeniería (Universidad Estatal de Milagro)

**GPT-4** — *Generative Pre-trained Transformer 4* (Transformador Generativo Preentrenado, versión 4)

**IA** — Inteligencia Artificial

**IAG** — Inteligencia Artificial Generativa

**IC** — Intervalo de Confianza

**IESALC** — Instituto Internacional para la Educación Superior en América Latina y el Caribe

**ISTE** — *International Society for Technology in Education* (Sociedad Internacional para la Tecnología en Educación)

**LLM** — *Large Language Model* (Modelo de Lenguaje de Gran Escala)

**LMS** — *Learning Management System* (Sistema de Gestión del Aprendizaje)

**LOES** — Ley Orgánica de Educación Superior

**OCDE** — Organización para la Cooperación y el Desarrollo Económicos (*también referida en el documento como OECD, por sus siglas en inglés*)

**OECD** — *Organisation for Economic Co-operation and Development* (Organización para la Cooperación y el Desarrollo Económicos)

**OLS** — *Ordinary Least Squares* (Mínimos Cuadrados Ordinarios)

**PP** — Práctica Pedagógica con inteligencia artificial generativa (*dimensión del instrumento ECCPP-IAG*)

**RAT** — *Replace, Amplify, Transform* (Reemplazar, Amplificar, Transformar; modelo de integración tecnológica)

**RMSEA** — *Root Mean Square Error of Approximation* (Error Cuadrático Medio de Aproximación)

**SAMR** — *Substitution, Augmentation, Modification, Redefinition* (Sustitución, Ampliación, Modificación, Redefinición; modelo de integración tecnológica de Puentedura)

**SENESCYT** — Secretaría de Educación Superior, Ciencia, Tecnología e Innovación

**SPSS** — *Statistical Package for the Social Sciences* (Paquete Estadístico para las Ciencias Sociales)

**SRMR** — *Standardized Root Mean Square Residual* (Residuo Cuadrático Medio Estandarizado)

**STEM** — *Science, Technology, Engineering and Mathematics* (Ciencias, Tecnología, Ingeniería y Matemáticas)

**TIC** — Tecnologías de la Información y la Comunicación

**TLI** — *Tucker-Lewis Index* (Índice de Tucker-Lewis)

**TPACK** — *Technological Pedagogical Content Knowledge* (Conocimiento Tecnológico-Pedagógico del Contenido)

**UNESCO** — *United Nations Educational, Scientific and Cultural Organization* (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura)

**UNESCO-IESALC** — Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura — Instituto Internacional para la Educación Superior en América Latina y el Caribe

**UNEMI** — Universidad Estatal de Milagro

**VIF** — *Variance Inflation Factor* (Factor de Inflación de Varianza)

## Lista de Abreviaturas

$\alpha$  — Alfa de Cronbach; coeficiente de consistencia interna de una escala

$\beta$  — Coeficiente de regresión estandarizado (beta); indica la magnitud del efecto de un predictor en unidades de desviación estándar

$\omega$  — Omega de McDonald; coeficiente alternativo de confiabilidad basado en análisis factorial

$\rho$  — Rho de Spearman; coeficiente de correlación no paramétrico por rangos

$\eta^2$  — Eta cuadrado; índice del tamaño del efecto en análisis de varianza

**Art.** — Artículo (referido a articulado de cuerpos normativos)

**B** — Coeficiente de regresión no estandarizado (en puntos de la escala original)

**d** — d de Cohen; índice del tamaño del efecto para comparaciones entre dos medias

**D** — Estadístico de la prueba de Kolmogorov-Smirnov

**DE** — Desviación Estándar

**et al.** — *et alii* (latín: «y otros»); se usa en citas con tres o más autores

**F** — Estadístico F de la distribución de Fisher; empleado en el ANOVA y en la prueba global del modelo de regresión

**gl** — Grados de libertad

**H** — Estadístico H de la prueba de Kruskal-Wallis

**H<sub>i</sub>** — Hipótesis de investigación (hipótesis alternativa)

**H<sub>0</sub>** — Hipótesis nula

**He<sub>1</sub>, He<sub>2</sub>, He<sub>3</sub>** — Hipótesis específicas primera, segunda y tercera

**IC** — Intervalo de Confianza

**inv.** — Ítem inverso (ítem redactado en sentido negativo que requiere inversión de su puntuación antes del análisis)

**M** — Media aritmética

**Mdn** — Mediana

**n** — Tamaño de la submuestra o subgrupo

**N** — Tamaño total de la población o muestra

**N°** — Número

**ns** — No significativo estadísticamente ( $p > 0,05$ )

**p** — Valor de probabilidad (nivel de significación estadística observado)

**pp** — Puntos porcentuales; diferencia entre dos porcentajes expresada en términos absolutos

**r** — Coeficiente de correlación de Pearson

**R<sup>2</sup>** — Coeficiente de determinación; proporción de varianza de la variable dependiente explicada por el modelo

**R<sup>2</sup>aj** — R<sup>2</sup> ajustado; versión corregida del coeficiente de determinación que penaliza la inclusión de predictores no significativos

**SE** — *Standard Error* (error estándar de la media o del coeficiente)

**t** — Estadístico t de Student; empleado en pruebas de comparación de medias para muestras independientes o pareadas

**V** — Coeficiente V de Aiken; índice de validez de contenido por juicio de expertos

**vs.** — Versus (frente a; en comparación con)

## Lista de Símbolos

$\alpha$  — Alfa de Cronbach; coeficiente de consistencia interna utilizado para estimar la confiabilidad de las escalas del instrumento

$\beta$  — Beta; coeficiente de regresión estandarizado que expresa el peso de un predictor en el modelo en unidades de desviación estándar

$\eta^2$  — Eta cuadrado; índice del tamaño del efecto en el análisis de varianza (ANOVA y Kruskal-Wallis), interpretado según los criterios de Cohen (1988): pequeño = 0,01; mediano = 0,06; grande = 0,14

$\rho$  — Rho de Spearman; coeficiente de correlación no paramétrico basado en rangos, empleado como verificación complementaria a  $r$  de Pearson

$\omega$  — Omega de McDonald; coeficiente alternativo de confiabilidad basado en análisis factorial, reportado junto con  $\alpha$  para cada dimensión del instrumento

$\Delta$  — Delta; representa la variación o incremento entre dos valores; empleado en el texto como  $\Delta R^2$  para indicar el incremento en el coeficiente de determinación al añadir predictores al modelo de regresión

$\pm$  — Más-menos; indica la amplitud del error estándar alrededor de la media en los gráficos de barras de error ( $\pm 1$  SE)

$\leq$  — Menor o igual que; empleado en criterios de ajuste de modelos (RMSEA  $\leq$  0,06; SRMR  $\leq$  0,08) y en comparaciones estadísticas

$\geq$  — Mayor o igual que; empleado en umbrales de aceptación de coeficientes ( $V$  de Aiken  $\geq$  0,80;  $\alpha \geq$  0,80; CFI y TLI  $\geq$  0,95)

$<$  — Menor que; empleado en criterios de significación estadística ( $p <$  0,05;  $p <$  0,001) y en umbrales del factor de inflación de varianza (VIF  $<$  10)

$>$  — Mayor que; empleado en comparaciones de valores y en la clasificación por niveles del instrumento

- — Signo de sustracción o diferencia; empleado en la inversión de ítems negativos (puntuación = 8 - valor original) y en la notación de brechas negativas entre variables (PP > CC)

→ — Flecha de dirección; indica la relación predictiva entre variables en la notación de los modelos de regresión (Competencia Conceptual → Práctica Pedagógica)

← — Flecha indicadora; señala visualmente el valor de interés en tablas comparativas (brecha mínima o máxima)

% — Porcentaje; unidad de medida empleada para expresar proporciones muestrales, tasas de respuesta por categoría y puntuaciones normalizadas al rango máximo de cada escala

<sup>2</sup> — Superíndice de potencia al cuadrado; empleado en R<sup>2</sup> (coeficiente de determinación) y en  $\eta^2$  (eta cuadrado)

H<sub>0</sub> — Subíndice cero en la notación de la hipótesis nula

He<sub>1</sub>, He<sub>2</sub>, He<sub>3</sub> — Subíndices numéricos en la notación de las hipótesis específicas primera, segunda y tercera del estudio

## Índice / Sumario

CAPÍTULO I .....	1
INTRODUCCIÓN .....	1
<b>1.1 Contextualización del problema.....</b>	<b>1</b>
<b>1.2 Planteamiento del problema.....</b>	<b>2</b>
<b>1.3 Formulación del problema .....</b>	<b>3</b>
<b>1.4 Objetivos .....</b>	<b>4</b>
Objetivo general.....	4
Objetivos específicos.....	4
<b>1.5 Hipótesis .....</b>	<b>4</b>
<b>1.6 Justificación.....</b>	<b>5</b>
CAPÍTULO 2.....	7
TEORÍA CIENTÍFICA .....	7
<b>2.1 Inteligencia artificial generativa: fundamentos conceptuales y evolución reciente (2020–2025) .....</b>	<b>7</b>
<b>2.2 Competencia docente en inteligencia artificial: marcos teóricos .....</b>	<b>8</b>
<b>2.3 La brecha conocimiento–práctica en docentes universitarios (<i>knowing-doing gap</i>).....</b>	<b>10</b>
<b>2.4 Práctica pedagógica y modelos de integración tecnológica.....</b>	<b>12</b>
<b>2.5 Formación continua del profesorado universitario en IA generativa .....</b>	<b>13</b>
<b>2.6 Contexto institucional: UNEMI y educación superior ecuatoriana .....</b>	<b>15</b>
CAPÍTULO 3.....	18
METODOLOGÍA.....	18
<b>3.2 Tipo y diseño de investigación .....</b>	<b>18</b>

3.3 Población y muestra .....	19
3.4 Técnica e instrumento de recolección de datos .....	20
3.5 Procedimiento de recolección de datos .....	22
3.6 Técnicas de análisis estadístico .....	22
3.7 Consideraciones éticas .....	23
CAPÍTULO 4.....	25
RESULTADOS.....	25
4.1 Caracterización sociodemográfica de la muestra.....	25
4.2 Confiabilidad del instrumento .....	26
4.3 Análisis descriptivo por ítem — Dimensión 1: Competencia Conceptual en IAG .....	27
4.4 Análisis descriptivo por ítem — Dimensión 2: Práctica Pedagógica con IAG ....	29
4.5 Análisis descriptivo global y comparación entre las dos variables principales	32
4.6 Análisis descriptivo de la Autoeficacia docente en IAG .....	36
4.7 Actitudes hacia la IAG en el aula .....	39
4.8 Prueba de normalidad y selección de estadístico correlacional.....	40
4.9 Prueba de hipótesis principal — Correlación entre Competencia Conceptual y Práctica Pedagógica.....	41
4.10 Análisis comparativo por variables sociodemográficas.....	42
4.11 Análisis de regresión — Predicción de la Práctica Pedagógica .....	45
4.12 Brecha conocimiento-práctica según recencia de capacitación y frecuencia de uso .....	48
4.13 Brecha CC–PP por área de conocimiento (carrera) .....	51

<b>4.14 Significación estadística de la brecha mediante t-test pareado.....</b>	<b>52</b>
<b>COMPROBACIÓN DE LA HIPÓTESIS .....</b>	<b>55</b>
Comprobación de la Hipótesis General .....	55
Comprobación de las Hipótesis Específicas .....	56
CONCLUSIONES.....	60
RECOMENDACIONES .....	62
BIBLIOGRAFÍA .....	64
ANEXOS.....	71
<b>ANEXO A.....</b>	<b>71</b>

# CAPÍTULO I

## INTRODUCCIÓN

### 1.1 Contextualización del problema

La incorporación de sistemas de inteligencia artificial generativa en los procesos educativos representa uno de los cambios estructurales más significativos que ha experimentado la educación superior en las últimas décadas. Desde la irrupción masiva de modelos de lenguaje de gran escala como ChatGPT cuya adopción alcanzó 100 millones de usuarios en apenas dos meses tras su lanzamiento en noviembre de 2022 las instituciones educativas de todo el mundo han debido enfrentarse a una realidad tecnológica que transforma no solo las herramientas disponibles sino también los fundamentos mismos de la enseñanza y el aprendizaje (UNESCO, 2023). La velocidad de esta transformación no tiene precedente en la historia reciente de la tecnología educativa, y su impacto sobre las prácticas docentes constituye un objeto de estudio urgente.

A escala global, los estudios sobre adopción de IA en educación superior revelan una paradoja persistente: mientras la disponibilidad de herramientas generativas crece de forma exponencial, su integración pedagógica sistemática avanza a un ritmo considerablemente menor. De acuerdo con los datos del *OECD Digital Education Outlook 2023*, apenas el 20% de las instituciones de educación superior en los países miembros de la OCDE contaban, para ese año, con políticas formales sobre el uso de IA en la enseñanza, pese a que más del 60% de los docentes encuestados había utilizado alguna herramienta generativa al menos ocasionalmente (OECD, 2023). Este desfase entre disponibilidad tecnológica y transformación pedagógica real configura un problema de dimensiones tanto institucionales como epistémicas que la investigación educativa no puede ignorar.

En el contexto latinoamericano, el panorama exhibe tensiones adicionales. Pedró (2023), en un análisis desarrollado para la UNESCO-IESALC, advierte que las universidades de la región enfrentan no solo la brecha digital estructural desigualdad en acceso a infraestructura y conectividad sino también lo que denomina la "brecha pedagógica de segunda generación": la distancia entre docentes que conocen teóricamente las posibilidades de la IA y quienes logran articularla con coherencia a su práctica de aula. Esta tensión resulta particularmente pronunciada en países como Ecuador, donde la transformación digital de la educación

superior coexiste con un sistema normativo en proceso de actualización y con una planta docente heterogénea en su nivel de formación tecnológica.

Los trabajos de Crompton y Burke (2023), en un análisis sistemático de 138 estudios sobre IA en educación superior publicados durante el período 2016-2022, identificaron que la mayoría de las investigaciones documenta usos emergentes de la IA desde la perspectiva del estudiante o de la institución, pero que la perspectiva del docente específicamente su competencia para integrar estas herramientas continúa siendo el eslabón menos comprendido de la cadena. Esto coincide con lo reportado por Selwyn (2022), quien sostiene que la narrativa optimista en torno a la IA educativa tiende a subvalorar las condiciones reales del profesorado frente a la adopción tecnológica, incluyendo sus creencias epistemológicas, su autoeficacia percibida y las barreras institucionales que moldean su práctica cotidiana.

En Ecuador, el SENESCYT ha incorporado en sus lineamientos de planificación institucional la necesidad de fomentar la innovación pedagógica mediada por tecnología en las universidades públicas; sin embargo, la evidencia disponible sobre el estado real de adopción de herramientas de IA generativa por parte del profesorado universitario ecuatoriano es aún escasa y fragmentaria. La Universidad Estatal de Milagro (UNEMI), institución pública de referencia en la provincia del Guayas, no escapa a este vacío de conocimiento: si bien ha desarrollado iniciativas de transformación digital en los últimos años, no existen estudios sistemáticos que caractericen la competencia conceptual de sus docentes en IA generativa ni que establezcan con rigor empírico la relación entre dicho conocimiento y su traducción efectiva en práctica pedagógica.

## **1.2 Planteamiento del problema**

La brecha entre el conocimiento declarativo sobre una tecnología y su aplicación práctica no es un fenómeno nuevo en la investigación educativa; no obstante, adquiere características específicas cuando el objeto tecnológico son los sistemas de IA generativa. A diferencia de herramientas digitales anteriores plataformas de videoconferencia, repositorios digitales, sistemas de gestión del aprendizaje, la IA generativa exige del docente no solo competencias instrumentales sino comprensión conceptual de sus fundamentos, capacidad crítica para evaluar sus resultados, sensibilidad ética para gestionar sus riesgos y habilidad pedagógica para integrarla de manera coherente con los objetivos de aprendizaje (Celik, 2023). Esta complejidad multidimensional convierte el problema de la brecha conocimiento-práctica en un asunto de naturaleza cualitativamente distinta.

Los hallazgos de Farrelly y Baker (2023) en universidades australianas, así como los de Chan y Hu (2023) en el contexto de Hong Kong, sugieren que una proporción significativa del profesorado universitario posee conocimiento general sobre la existencia de herramientas de IA generativa, pero experimenta incertidumbre sobre cómo utilizarlas de forma pedagógicamente fundamentada. Este patrón conocer sin saber integrar constituye el núcleo conceptual del fenómeno denominado en la literatura como *knowing-doing gap*, cuya expresión en el ámbito docente universitario ha sido documentada en múltiples contextos pero apenas estudiada con metodologías cuantitativas en universidades latinoamericanas.

En la UNEMI, observaciones preliminares y la consulta con autoridades académicas sugieren que la situación podría reproducir este patrón global: un segmento de docentes ha tenido aproximaciones exploratorias a herramientas como ChatGPT, Gemini o Microsoft Copilot, pero sin que ello se haya traducido en modificaciones sustanciales de sus estrategias de enseñanza, diseño curricular o procedimientos de evaluación del aprendizaje. Tal como lo evidencian los trabajos de Tlili et al. (2023) en un análisis multinacional, la mera exposición a una herramienta de IA no garantiza su apropiación pedagógica; para ello se requiere formación estructurada, espacios de reflexión y una base conceptual sólida sobre la que construir competencias de integración.

Esta tensión plantea una pregunta de relevancia tanto científica como institucional: ¿en qué medida la competencia conceptual que poseen los docentes de la UNEMI sobre IA generativa predice su práctica pedagógica real con dichas herramientas, y qué variables sociodemográficas moderan esa relación? La ausencia de estudios empíricos que respondan esta pregunta en el contexto ecuatoriano constituye un vacío que el presente proyecto se propone llenar. Los trabajos disponibles en la región como el análisis de García-Peñalvo (2023) sobre la percepción de la IA en contextos educativos tras la introducción de ChatGPT, o el de Lim et al. (2023) sobre el futuro de la educación en la era generativa ofrecen marcos analíticos valiosos, pero no capturan las particularidades del sistema de educación superior ecuatoriano, sus condicionantes normativos ni el perfil docente específico de una institución como la UNEMI.

### **1.3 Formulación del problema**

La pregunta central que orienta la presente investigación es la siguiente: ¿cuál es la relación entre la competencia conceptual en inteligencia artificial generativa y la práctica pedagógica con estas herramientas en docentes de la Universidad Estatal de Milagro durante el año 2025?

De esta pregunta se derivan tres preguntas secundarias que articulan los objetivos específicos del estudio. En primer lugar: ¿cuál es el nivel de competencia conceptual en IA generativa que poseen los docentes de la UNEMI en 2025, considerando sus distintas dimensiones conocimiento de fundamentos, herramientas, usos educativos, limitaciones y dimensión ética? En segundo lugar: ¿cuál es la frecuencia, el tipo y la calidad de integración de herramientas de IA generativa en las prácticas pedagógicas de los docentes de la UNEMI, diferenciadas por facultad, área de conocimiento y nivel formativo? Y en tercer lugar: ¿en qué medida variables sociodemográficas como la edad, los años de experiencia docente, el área de conocimiento, el nivel de formación académica y la participación previa en formación sobre IA moderan la relación entre competencia conceptual y práctica pedagógica?

## **1.4 Objetivos**

### **Objetivo general**

Determinar la relación entre la competencia conceptual en inteligencia artificial generativa y la práctica pedagógica con estas herramientas en docentes de la Universidad Estatal de Milagro durante el año 2025.

### **Objetivos específicos**

1. Describir el nivel de competencia conceptual en IA generativa de los docentes de la UNEMI, diferenciado por dimensiones conocimiento de fundamentos, herramientas, usos educativos, limitaciones y ética y por variables sociodemográficas.
2. Caracterizar la frecuencia, el tipo y la calidad de integración de herramientas de IA generativa en la práctica pedagógica de los docentes de la UNEMI, analizando las diferencias por facultad, área de conocimiento y nivel de formación.
3. Establecer el grado de relación estadística entre la competencia conceptual en IA generativa y la práctica pedagógica con estas herramientas, determinando el efecto moderador de las variables sociodemográficas seleccionadas.

## **1.5 Hipótesis**

La hipótesis general (Hi) del estudio postula que existe una relación positiva y estadísticamente significativa entre la competencia conceptual en inteligencia artificial generativa y la práctica pedagógica con estas herramientas en docentes de la Universidad Estatal de Milagro durante el año 2025.

La hipótesis nula ( $H_0$ ) establece, por el contrario, que no existe relación estadísticamente significativa entre ambas variables en la población estudiada.

Las hipótesis específicas se formulan en correspondencia directa con los objetivos derivados.

**(He<sub>1</sub>)** Sostiene que los docentes de la UNEMI con mayor nivel de formación académica grado de doctorado frente a maestría presentan puntuaciones significativamente más altas tanto en competencia conceptual como en práctica pedagógica con IA generativa.

**(He<sub>2</sub>)** Propone que los docentes que han participado previamente en procesos formales de formación sobre IA exhiben niveles significativamente más altos de integración pedagógica de herramientas generativas, independientemente de su área de conocimiento o de sus años de experiencia.

**(He<sub>3</sub>)** Plantea que la competencia conceptual en IA generativa actúa como predictor significativo de la práctica pedagógica con estas herramientas, incluso después de controlar estadísticamente el efecto de las variables sociodemográficas consideradas como moderadoras en el modelo de regresión.

## 1.6 Justificación

Desde el punto de vista de la relevancia científica, este estudio responde a un vacío evidente en la literatura sobre tecnología educativa en el contexto latinoamericano. Si bien existe producción académica creciente sobre el uso de IA generativa en la educación superior particularmente en Europa, Asia Oriental y Norteamérica, los estudios empíricos cuantitativos que analizan específicamente la relación entre competencia conceptual y práctica pedagógica en docentes universitarios ecuatorianos son prácticamente inexistentes. Los trabajos de Baidoo-Anu y Owusu Ansah (2023) o de Lim et al. (2023) aportan perspectivas relevantes, pero no permiten extrapolaciones directas a realidades como la UNEMI sin la mediación de investigación contextualizada. El instrumento validado que se construirá en este proyecto una escala Likert con propiedades psicométricas documentadas constituirá, adicionalmente, un aporte metodológico replicable en otras universidades ecuatorianas y latinoamericanas.

La relevancia social del estudio se articula en torno a la calidad educativa. Si los docentes universitarios carecen de competencias para integrar de forma crítica y pedagógicamente fundamentada las herramientas de IA generativa, las consecuencias se traducen directamente en la formación que reciben los estudiantes de la UNEMI y, por extensión, en la pertinencia de los profesionales que esta institución aporta al desarrollo regional. La

universidad tiene la responsabilidad de preparar ciudadanos capaces de desenvolverse en entornos laborales donde la IA generativa ya forma parte de los flujos de trabajo cotidianos, y esa preparación comienza por la competencia de quienes enseñan.

Desde la perspectiva de la relevancia institucional, los hallazgos del estudio ofrecerán a la Dirección Académica de la UNEMI, al Vicerrectorado de Investigación y Posgrado y a la Dirección de Posgrado insumos empíricos para el diseño de políticas de formación continua del profesorado alineadas con los lineamientos del SENESCYT sobre innovación pedagógica.

Finalmente, la relevancia metodológica reside en la construcción y validación de un instrumento de medición específicamente diseñado para el contexto universitario ecuatoriano. La escala desarrollada medirá de forma diferenciada la competencia conceptual en IA generativa y la práctica pedagógica con estas herramientas, y será sometida a validación de contenido por juicio de siete expertos y a validación de constructo mediante análisis factorial confirmatorio. Este proceso garantizará su solidez psicométrica y habilitará su uso en investigaciones comparativas futuras dentro del sistema de educación superior del Ecuador, lo cual constituye en sí mismo un aporte a la comunidad académica regional.

## CAPÍTULO 2

### TEORÍA CIENTÍFICA

#### 2.1 Inteligencia artificial generativa: fundamentos conceptuales y evolución reciente (2020–2025)

La inteligencia artificial generativa designa un conjunto de sistemas computacionales capaces de producir contenidos nuevos texto, imágenes, código, audio, video o datos sintéticos a partir del procesamiento estadístico de grandes volúmenes de información preexistente. Su distinción respecto de otras ramas de la inteligencia artificial resulta conceptualmente relevante para comprender su impacto educativo: mientras la IA discriminativa aprende a clasificar o etiquetar datos reconocer un rostro, detectar spam, diagnosticar una imagen médica, la IA generativa aprende las distribuciones probabilísticas subyacentes a los datos de entrenamiento para crear nuevas instancias coherentes con dichas distribuciones (Goodfellow et al., 2020). Esta diferencia no es meramente técnica; implica que la IA generativa opera en el dominio de la producción simbólica, lo cual la coloca en una relación directa con actividades cognitivas superiores como la escritura, la argumentación, la síntesis y la creación, actividades que han sido históricamente el núcleo de la práctica pedagógica universitaria.

Dentro de la familia de sistemas generativos, los modelos de lenguaje de gran escala conocidos por sus siglas en inglés como LLM, *Large Language Models* constituyen la tecnología de mayor impacto sobre los contextos educativos. Estos modelos se entrenan sobre corpus textuales de dimensiones extraordinarias mediante arquitecturas de tipo *transformer*, que permiten capturar dependencias semánticas a larga distancia dentro del texto y generar respuestas contextualmente coherentes. GPT-4 de OpenAI, Gemini de Google, Claude de Anthropic y Llama de Meta representan los sistemas más documentados en la literatura científica reciente, y cada uno exhibe capacidades diferenciadas en términos de razonamiento, multimodalidad y manejo de información especializada (Bubeck et al., 2023). Los trabajos de Zhao et al. (2023) ofrecen una revisión sistemática exhaustiva de la arquitectura, los métodos de entrenamiento y las aplicaciones de los LLM que permite comprender sus posibilidades y sus límites con mayor precisión que los análisis de divulgación general.

Desde una perspectiva educativa, las aplicaciones documentadas científicamente de la IA generativa comprenden un espectro amplio. Kasneci et al. (2023) identificaron, en una

revisión de alcance sobre las implicaciones de los LLM para la educación, seis dominios principales de uso: tutoría personalizada, retroalimentación automática sobre trabajos escritos, generación de materiales didácticos adaptados, apoyo a la evaluación formativa, asistencia en la investigación y facilitación del aprendizaje de idiomas. No obstante, los mismos autores advierten que la mayoría de estas aplicaciones permanece en fase experimental o anecdótica, sin evidencia robusta sobre sus efectos en el aprendizaje a largo plazo, lo cual plantea un imperativo de investigación que el campo de la tecnología educativa aún no ha satisfecho plenamente.

Lo anterior sugiere que el entusiasmo institucional por la IA generativa no siempre va acompañado de una comprensión matizada de sus condiciones de eficacia pedagógica. Holmes et al. (2022), en un análisis crítico de la IA en la educación, señalan que las promesas tecnológicas suelen anteceder por varios años a la evidencia empírica que las sustenta, y que esa brecha temporal puede generar políticas educativas desalineadas con la realidad de las aulas. Desde esta perspectiva, la competencia conceptual del docente sobre IA generativa su capacidad para comprender qué son, cómo funcionan, qué pueden y qué no pueden hacer estas herramientas se convierte en un prerrequisito indispensable para cualquier forma de integración pedagógica responsable, criterio que fundamenta directamente la variable independiente de la presente investigación.

## **2.2 Competencia docente en inteligencia artificial: marcos teóricos**

La conceptualización de la competencia docente en tecnología educativa tiene una trayectoria de investigación relativamente consolidada, cuyos marcos más influyentes han sido progresivamente adaptados para incorporar la dimensión específica de la inteligencia artificial. El análisis crítico de estos marcos permite identificar qué dimensiones de la competencia resultan relevantes para el presente estudio y cómo operacionalizarlas de manera empíricamente válida.

El modelo TPACK *Technological Pedagogical Content Knowledge*, propuesto originalmente por Mishra y Koehler (2006) y ampliamente replicado en investigación educativa, establece que la competencia docente para integrar tecnología no reside en el dominio técnico aislado sino en la intersección entre conocimiento tecnológico, conocimiento pedagógico y conocimiento del contenido disciplinar. Celik (2023) extendió este marco para incorporar explícitamente la dimensión de la IA, proponiendo el modelo AI-TPACK, que añade al esquema original la comprensión de las capacidades y limitaciones de los sistemas de IA, las implicaciones éticas de su uso y la habilidad para diseñar situaciones de aprendizaje donde

la IA actúe como andamiaje cognitivo y no como sustituto del pensamiento del estudiante. Los hallazgos de Celik (2023) en una muestra de docentes turcos sugieren que el conocimiento de IA y el conocimiento pedagógico interactúan de forma sinérgica: los docentes con mayor comprensión conceptual de la IA tienden a diseñar usos pedagógicamente más ricos, lo cual establece una base empírica directa para la hipótesis central del presente proyecto.

El marco DigCompEdu *Digital Competence Framework for Educators* desarrollado por la Comisión Europea y actualizado por Redecker (2017) y posteriormente revisado por Caena y Redecker (2019), organiza la competencia digital docente en seis áreas: compromiso profesional, recursos digitales, enseñanza y aprendizaje, evaluación, empoderamiento del estudiante y facilitación de la competencia digital. La versión más reciente del marco, adaptada en el informe DigComp 2.2 (Vuorikari et al., 2022), incorpora de forma explícita la comprensión de sistemas de IA como una competencia transversal que atraviesa todas las áreas anteriores. Lo que resulta particularmente relevante para el presente estudio es que DigCompEdu distingue entre niveles de competencia que van desde la exploración inicial hasta la innovación pedagógica, una gradación que permite conceptualizar la brecha conocimiento-práctica no como una dicotomía sino como un continuo de desarrollo profesional.

Los estándares ISTE para educadores (*ISTE Standards for Educators*, 2017), actualizados con orientaciones específicas sobre IA en sus guías de implementación, enfatizan el rol del docente como aprendiz, líder, ciudadano, colaborador, diseñador, facilitador y analista. Desde la postura de ISTE, la competencia docente en IA exige que el profesorado sea capaz no solo de usar herramientas de IA sino de modelar ante sus estudiantes un pensamiento crítico y ético sobre ellas, lo cual implica un nivel de comprensión conceptual que trasciende la mera familiaridad instrumental. Este criterio resulta coherente con el planteamiento de la UNESCO (2023) en su marco de competencias TIC para docentes, que en su actualización más reciente identifica la alfabetización en IA como una capacidad emergente de primer orden para el profesorado del siglo XXI, articulando tres dimensiones fundamentales: comprensión de los principios de funcionamiento de la IA, habilidad para integrarla en experiencias de aprendizaje significativo y reflexión crítica sobre sus implicaciones sociales y éticas.

La dimensión ética merece atención especial, pues constituye una de las subdimensiones más complejas y menos exploradas de la competencia docente en IA generativa. Miao et al. (2021), en el documento de posición de la UNESCO sobre IA y educación, señalan que los

docentes necesitan desarrollar lo que denominan "alfabetización ética en IA": la capacidad de identificar sesgos algorítmicos, comprender las implicaciones del uso de datos personales de estudiantes, evaluar críticamente la equidad de los sistemas generativos y tomar decisiones pedagógicas informadas sobre cuándo y cómo usar estas herramientas. Esta dimensión ética no puede reducirse a la aplicación de un conjunto de reglas; requiere comprensión conceptual profunda de cómo los sistemas de IA son entrenados, qué tipo de información reproducen y qué concepciones del mundo proyectan en sus respuestas, lo cual refuerza la centralidad de la competencia conceptual como variable explicativa de la práctica pedagógica.

### **2.3 La brecha conocimiento–práctica en docentes universitarios (*knowing-doing gap*)**

El fenómeno que este estudio denomina brecha conocimiento-práctica traducción del concepto anglosajón *knowing-doing gap* acuñado por Pfeffer y Sutton (2000) en el contexto organizacional y posteriormente trasladado a la investigación educativa designa la distancia observable entre lo que los docentes saben o creen sobre una práctica y lo que efectivamente hacen en sus entornos de enseñanza. Esta brecha no se explica simplemente por falta de información; constituye un fenómeno complejo de naturaleza cognitiva, afectiva e institucional que ha sido documentado de forma consistente en la literatura sobre integración tecnológica en educación superior durante las últimas dos décadas.

Los trabajos de Ertmer (2005), que aunque anteriores al periodo de referencia establecido para este proyecto permanecen como referencia teórica canónica del campo, distinguieron entre barreras de primer orden externas, relativas a infraestructura, acceso y tiempo y barreras de segundo orden internas, relativas a creencias, autoeficacia y resistencia al cambio. Esta distinción conserva plena vigencia en el contexto de la IA generativa: los docentes que no integran estas herramientas en su práctica lo hacen, según la evidencia reciente, no únicamente por carencia de acceso que en muchos casos es gratuito sino por factores internos que incluyen incertidumbre sobre la eficacia pedagógica de la IA, preocupación por la integridad académica, inseguridad ante la posibilidad de que los estudiantes sepan más que ellos sobre estas herramientas y ausencia de referentes claros sobre cómo integrarlas sin comprometer la calidad de los aprendizajes (Farrelly & Baker, 2023; Moorhouse et al., 2023).

En el contexto europeo, el estudio de Tondeur et al. (2022) sobre integración tecnológica en la educación superior belga y holandesa identificó que la autoeficacia docente la creencia del profesor en su propia capacidad para usar la tecnología pedagógicamente mediaba de forma significativa la relación entre la formación recibida y la práctica de aula observada. Los

docentes con alta autoeficacia tecnológica transferían de forma más consistente los aprendizajes de los programas de formación a su práctica cotidiana, mientras que aquellos con baja autoeficacia tendían a revertir a métodos convencionales incluso después de haber completado programas de capacitación formalmente exitosos. A diferencia de lo que podría esperarse, la antigüedad docente no predijo de forma directa la autoeficacia ni la integración tecnológica, lo cual sugiere que la experiencia acumulada no garantiza per se la disposición hacia la innovación pedagógica mediada por tecnología.

En América Latina, los datos disponibles revelan patrones similares, aunque con matices propios del contexto regional. Turpo-Gebera et al. (2021), en un estudio con docentes universitarios peruanos, encontraron que más del 70% de los encuestados reportaba conocer herramientas tecnológicas educativas pero menos del 30% las integraba de forma regular en sus clases. Los autores vinculan esta discrepancia con la ausencia de políticas institucionales claras, la falta de formación continua sistemática y la persistencia de culturas académicas que privilegian métodos transmisivos por sobre los enfoques mediados por tecnología. En un registro similar, Gómez-García et al. (2020), en un análisis de la competencia digital del profesorado universitario en España y Colombia, encontraron que las áreas de mayor déficit no eran las técnicas sino las pedagógicas: los docentes sabían usar las herramientas pero no sabían integrarlas con intencionalidad formativa.

Para el caso específico de la IA generativa, los estudios más recientes reflejan una versión agudizada de esta brecha. Johnke et al. (2023), en una investigación con docentes universitarios australianos realizada durante el período 2022-2023 coincidente con la expansión masiva de ChatGPT, documentaron que la mayoría de los participantes reportaba niveles medios-altos de conocimiento sobre las capacidades de la IA generativa, pero niveles bajos-medios de integración pedagógica activa. Lo anterior coincide con lo reportado por Chiu (2024), quien en un estudio multinacional con docentes de Asia y Oceanía identificó que el factor más fuertemente asociado a la práctica pedagógica con IA no era el conocimiento técnico sino la claridad didáctica: los docentes que más integraban la IA eran quienes tenían ideas concretas sobre cómo hacerlo dentro de sus disciplinas específicas, no simplemente quienes sabían más sobre la tecnología en abstracto. Este hallazgo matiza la relación entre competencia conceptual y práctica pedagógica, sugiriendo que dicha relación no es lineal sino mediada por variables cognitivas y contextuales que deben considerarse en el diseño analítico del presente estudio.

## 2.4 Práctica pedagógica y modelos de integración tecnológica

La noción de práctica pedagógica ha sido objeto de múltiples conceptualizaciones en la teoría educativa, y su operacionalización en estudios empíricos sobre integración tecnológica requiere precisión conceptual. En términos generales, la práctica pedagógica puede entenderse como el conjunto organizado de acciones que el docente despliega para crear condiciones de aprendizaje: selección y secuenciación de contenidos, elección de estrategias metodológicas, diseño de actividades, gestión de la interacción en el aula y construcción de sistemas de evaluación. Desde la perspectiva de Perrenoud (2007), la práctica pedagógica no es simplemente la aplicación técnica de métodos preestablecidos sino la expresión de un habitus profesional que integra saberes, creencias y disposiciones construidos a lo largo de la trayectoria docente.

Esta conceptualización tiene implicaciones directas para comprender la integración de la IA generativa. Si la práctica pedagógica es expresión de un habitus, entonces la incorporación de nuevas tecnologías no se produce por simple sustitución de herramientas sino mediante un proceso de reconfiguración de esquemas de acción que puede ser lento, resistido y desigual entre docentes con diferentes trayectorias y disposiciones. Los modelos de integración tecnológica existentes en la literatura permiten graduar la profundidad de este proceso de reconfiguración y, con ello, distinguir entre formas superficiales y transformadoras de integración.

El modelo SAMR, propuesto por Puentedura (2006) y ampliamente utilizado en investigación sobre tecnología educativa, describe cuatro niveles de integración: sustitución, donde la tecnología reemplaza una herramienta convencional sin cambio funcional; aumento, donde la tecnología mejora funcionalmente una tarea existente; modificación, donde la tecnología permite rediseñar significativamente la tarea; y redefinición, donde la tecnología posibilita crear tareas que serían imposibles sin ella. Aplicado a la IA generativa, este modelo permite distinguir entre docentes que usan ChatGPT para generar apuntes sin cambiar su enfoque de enseñanza nivel de sustitución y docentes que diseñan actividades donde los estudiantes interactúan críticamente con respuestas de IA para desarrollar pensamiento argumentativo nivel de redefinición. Los trabajos de Hamilton et al. (2016) sobre las limitaciones del modelo SAMR como herramienta evaluativa sugieren que su aplicación debe complementarse con análisis cualitativos que capturen el sentido pedagógico de la integración y no solo su nivel técnico, observación metodológica que el presente estudio incorpora al diseño de su instrumento de medición.

El modelo RAT *Replace, Amplify, Transform* propuesto por Hughes et al. (2006) opera sobre una lógica similar, aunque con énfasis en la transformación del rol del estudiante como criterio central de valoración de la integración tecnológica. Desde esta perspectiva, la calidad de la integración de IA generativa en la práctica docente no debe medirse únicamente por la frecuencia de uso ni por el tipo de herramienta empleada, sino por el grado en que dicha integración amplía la agencia epistémica del estudiante, diversifica sus oportunidades de aprendizaje y promueve el desarrollo de competencias de orden superior. Esta consideración informa directamente la operacionalización de la variable dependiente del presente estudio: la práctica pedagógica con IA generativa no se reduce a la frecuencia de uso de herramientas sino que incorpora dimensiones de tipo y calidad de integración que requieren ítems de medición específicamente diseñados.

Lim et al. (2023) propusieron recientemente una taxonomía de niveles de uso de IA en la docencia universitaria que complementa los modelos anteriores: el uso reactivo responder a demandas de los estudiantes sobre IA, el uso instrumental emplear IA como apoyo logístico sin intencionalidad pedagógica explícita, el uso pedagógico estructurado integrar IA en el diseño didáctico con objetivos de aprendizaje definidos y el uso transformador redesignar el currículo y la evaluación a partir de las posibilidades de la IA. Esta taxonomía resulta operacionalmente valiosa para el presente estudio, puesto que permite distribuir a los docentes en niveles de práctica que van más allá de la simple frecuencia de uso y capturan la intencionalidad pedagógica subyacente, dimensión que los estudios de encuesta habitualmente subvaloran.

## **2.5 Formación continua del profesorado universitario en IA generativa**

La formación continua del profesorado universitario como mecanismo de actualización pedagógica y tecnológica ha sido estudiada extensamente en la literatura de desarrollo profesional docente. Los modelos más citados en este campo el de Guskey (2000) sobre las fases del cambio en el profesorado, el de Darling-Hammond et al. (2017) sobre las características de la formación docente efectiva o el de Avalos (2011) sobre el aprendizaje profesional docente convergen en señalar que la formación en servicio que produce cambios sostenidos en la práctica de aula debe ser específica al contexto disciplinar, sostenida en el tiempo, vinculada a comunidades de práctica entre pares y acompañada de oportunidades de aplicación reflexiva dentro del propio entorno laboral. Estos principios tienen implicaciones directas para el diseño de programas de formación en IA generativa, cuyos primeros modelos sistematizados comienzan a documentarse en la literatura reciente.

Rodríguez-García et al. (2023), en un análisis de programas de formación docente en IA implementados en universidades españolas durante 2022 y 2023, identificaron que los programas más efectivos medidos por la transferencia a la práctica de aula combinaban tres componentes: alfabetización conceptual sobre los principios de funcionamiento de la IA, talleres de diseño pedagógico donde los docentes creaban actividades concretas con herramientas generativas y comunidades de práctica que sostenían el intercambio de experiencias durante el semestre posterior. Por el contrario, los programas que se limitaban a la demostración de herramientas el modelo más común en las instituciones que improvisan respuestas a la irrupción de la IA no produjeron cambios observables en la práctica de aula más allá de las semanas inmediatas a la formación.

En el contexto latinoamericano, las experiencias documentadas son aún escasas pero ilustrativas. Turpo-Gebera et al. (2022) reportaron los resultados de un programa piloto de formación docente en competencias digitales avanzadas en universidades peruanas, encontrando que la modalidad híbrida combinación de sesiones sincrónicas y trabajo autónomo acompañado producía mayores niveles de transferencia a la práctica que los talleres puramente presenciales o los cursos en línea sin acompañamiento. Los autores destacan el papel mediador de la autoeficacia: los docentes que durante la formación construían conciencia de sus propias capacidades para usar la tecnología pedagógicamente mostraban mayor disposición a experimentar con ella en sus cursos reales, un hallazgo que conecta directamente con la teoría de Bandura (1997) sobre la autoeficacia como mecanismo de agencia.

La teoría de la autoeficacia de Bandura (1997) merece atención específica en este contexto, pues ofrece el marco psicológico más robusto para explicar por qué el conocimiento no siempre se traduce en acción. Según este planteamiento, la creencia de una persona en su capacidad para ejecutar con éxito una tarea específica su autoeficacia percibida predice de forma más consistente su comportamiento que el nivel objetivo de conocimiento o habilidad que posee. Aplicado al contexto docente, esto significa que un profesor puede conocer perfectamente las posibilidades de ChatGPT para el diseño de actividades de aprendizaje y, sin embargo, no utilizarlas si no confía en su propia capacidad para implementarlas exitosamente frente a sus estudiantes. Los trabajos de Tondeur et al. (2022) y Chiu (2024) ya citados confirman esta relación en el contexto específico de la integración tecnológica, lo cual sugiere que los programas de formación en IA deben diseñarse no solo para transferir conocimiento conceptual sino para construir autoeficacia pedagógica de forma deliberada.

Lo anterior plantea que la brecha conocimiento-práctica identificada en docentes universitarios frente a la IA generativa no se resuelve únicamente con más información; requiere intervenciones formativas que operen simultáneamente sobre la dimensión conceptual qué es y cómo funciona la IA, la dimensión pedagógica cómo integrarla con intencionalidad formativa, la dimensión práctica oportunidades reales de experimentación y reflexión y la dimensión afectivo-motivacional construcción de confianza y autoeficacia en contextos seguros para el error.

## **2.6 Contexto institucional: UNEMI y educación superior ecuatoriana**

La Universidad Estatal de Milagro fue creada mediante Ley No. 2001-37, publicada en el Registro Oficial No. 432 del 3 de octubre de 2001, y constituye una institución pública de educación superior acreditada por el CACES Consejo de Aseguramiento de la Calidad de la Educación Superior cuya misión se orienta a la generación y difusión del conocimiento científico, tecnológico y humanístico para contribuir al desarrollo sostenible de la región y del país. Su oferta académica comprende programas de grado y posgrado distribuidos en cuatro facultades: Ciencias de la Ingeniería, Ciencias de la Educación y la Comunicación, Ciencias Administrativas y Comerciales y Ciencias de la Salud. Con una planta docente aproximada de 350 profesores en 2024, la UNEMI representa una institución de tamaño mediano dentro del sistema de educación superior ecuatoriano, lo cual la convierte en un escenario analíticamente representativo para estudiar fenómenos de adopción tecnológica en universidades públicas regionales del país.

El sistema de educación superior ecuatoriano se rige por la Ley Orgánica de Educación Superior (LOES) y sus reglamentos derivados, cuya última gran reforma mediante Ley Orgánica Reformatoria a la LOES de 2018 consolidó el rol del CES y del CACES como organismos rectores de la calidad y pertinencia de los programas académicos. En el marco normativo vigente, el artículo 93 de la LOES establece el principio de calidad como eje transversal del sistema, entendido como búsqueda continua y autoreflexiva del mejoramiento, lo que proporciona una base legal para exigir que las instituciones de educación superior actualicen sistemáticamente las competencias de su planta docente en respuesta a los cambios del entorno tecnológico y social.

El SENESCYT, por su parte, ha incorporado en sus planes sectoriales referencias crecientes a la innovación pedagógica y la transformación digital como dimensiones estratégicas del desarrollo de la educación superior ecuatoriana. El Plan Estratégico Institucional del SENESCYT 2021-2025 contempla entre sus objetivos la promoción de prácticas pedagógicas

innovadoras en las universidades públicas, articuladas con el uso de tecnologías emergentes. No obstante, hasta la fecha de elaboración del presente proyecto, el SENESCYT no ha publicado lineamientos específicos sobre el uso de IA generativa en la enseñanza universitaria, lo que genera un vacío normativo que las instituciones están llenando de forma heterogénea y, en muchos casos, reactiva frente a las demandas de los estudiantes.

En lo que respecta al estado de adopción tecnológica en las universidades ecuatorianas, los datos disponibles son limitados pero orientadores. Según el informe de la CEPAL (2022) sobre digitalización educativa en América Latina y el Caribe, Ecuador se ubica en una posición intermedia en la región en cuanto a infraestructura digital para la educación superior, con brechas significativas entre instituciones de las principales ciudades Quito y Guayaquil y las ubicadas en provincias intermedias. La UNEMI, situada en el cantón Milagro, provincia del Guayas, presenta condiciones de conectividad y equipamiento que, aunque han mejorado progresivamente en los últimos años, no son comparables con las de las universidades metropolitanas más grandes, lo cual constituye una variable contextual relevante para interpretar los niveles de adopción tecnológica de su planta docente.

En el plano institucional, la UNEMI ha desarrollado iniciativas de capacitación en tecnología educativa para sus docentes en el marco de su plan de desarrollo institucional, incluyendo programas de formación en el uso de plataformas LMS y herramientas de comunicación digital, particularmente intensificados durante el período de pandemia 2020-2022. Sin embargo, la formación específica en IA generativa como herramienta pedagógica no ha sido sistematizada ni evaluada de forma oficial, lo que configura el vacío institucional que este proyecto busca documentar empíricamente.

Los trabajos de Espinoza y Toscano (2022) sobre la percepción de los docentes universitarios ecuatorianos frente a la innovación tecnológica revelan que una proporción significativa del profesorado manifiesta disposición favorable hacia la adopción de nuevas herramientas digitales, pero identifica como principales obstáculos la falta de formación específica, la ausencia de tiempo institucionalizado para la experimentación pedagógica y la carencia de políticas claras sobre el uso de tecnologías emergentes en la enseñanza. Estos hallazgos, obtenidos antes de la irrupción masiva de la IA generativa, permiten anticipar que la situación frente a herramientas como ChatGPT o Gemini es potencialmente más compleja aún, dado que estos sistemas añaden dimensiones éticas y epistemológicas que las tecnologías previas no planteaban con la misma urgencia. La presente investigación se inserta en este contexto institucional y normativo para producir conocimiento empírico riguroso que permita orientar

decisiones de política pedagógica en la UNEMI y servir de referencia para otras universidades públicas ecuatorianas en situaciones similares.

## CAPÍTULO 3

### METODOLOGÍA

#### 3.1 Paradigma y enfoque de investigación

El presente estudio se inscribe dentro del paradigma positivista, cuyo postulado central sostiene que el conocimiento científico válido se obtiene a través de la observación sistemática, la medición objetiva y el análisis empírico de la realidad social (Hernández-Sampieri & Mendoza, 2018). Desde esta perspectiva epistemológica, los fenómenos educativos entre ellos la competencia docente en IA generativa y su traducción a la práctica pedagógica pueden ser cuantificados, comparados y sometidos a contrastación estadística, lo que permite formular inferencias generalizables sobre la población de estudio. El paradigma positivista resulta coherente con el propósito de establecer relaciones entre variables medibles y de examinar si las diferencias observadas obedecen a patrones sistemáticos o a variaciones aleatorias (Creswell & Creswell, 2023).

En concordancia con este sustento epistemológico, el enfoque adoptado es cuantitativo. Dicho enfoque privilegia la recolección de datos numéricos estructurados, el uso de instrumentos estandarizados y la aplicación de técnicas estadísticas para describir, correlacionar y predecir el comportamiento de las variables (Johnson & Onwuegbuzie, 2020). La elección del enfoque cuantitativo responde, además, a la naturaleza de la pregunta central de investigación: establecer si existe una relación estadísticamente significativa entre el nivel de competencia conceptual en IA generativa y la frecuencia e intensidad con que los docentes integran esas herramientas en su práctica pedagógica. Tal pregunta exige datos comparables entre sujetos y unidades de análisis homogéneas, condiciones que solo el enfoque cuantitativo puede garantizar con rigor metodológico suficiente.

#### 3.2 Tipo y diseño de investigación

El tipo de investigación es descriptivo-correlacional. La dimensión descriptiva permite caracterizar con precisión los niveles de competencia conceptual y de práctica pedagógica en IA generativa que presentan los docentes participantes, así como las diferencias entre subgrupos definidos por variables sociodemográficas. La dimensión correlacional, por su parte, busca establecer la dirección y magnitud de la asociación entre ambas variables principales, lo que constituye el núcleo del problema investigado (Ato et al., 2013). Este nivel de alcance es pertinente cuando el estado del arte sobre el tema de interés ha avanzado

suficientemente como para plantear hipótesis de relación, pero aún no cuenta con evidencia experimental que permita establecer causalidad.

El diseño es no experimental y transversal. No experimental porque el investigador no manipula ninguna variable ni asigna aleatoriamente a los participantes a condiciones de tratamiento; se limita a observar el fenómeno tal como ocurre de manera natural en el contexto institucional (Montero & León, 2022). Transversal porque los datos se recogen en un único punto temporal el año 2025, lo que significa que el estudio ofrece una fotografía del estado actual de la brecha entre competencia conceptual y práctica pedagógica en el momento de la recolección, sin seguimiento longitudinal de los participantes. Esta combinación de tipo y diseño resulta apropiada para los objetivos planteados: describir una situación presente, contrastar hipótesis de relación y generar evidencia.

### **3.3 Población y muestra**

La población objetivo del estudio estuvo constituida por los docentes de la Facultad de Ciencias de la Ingeniería (FACI) de la Universidad Estatal de Milagro (UNEMI) en ejercicio durante el período académico 2025, quienes imparten asignaturas en las siete carreras que conforman dicha unidad académica: Tecnologías de la Información en Modalidad en Línea, Ingeniería Industrial en Modalidad Presencial, Ingeniería de Software en Modalidad Presencial, Ingeniería en Alimentos en Modalidad Presencial, Ingeniería Ambiental en Modalidad Presencial, Biotecnología en Modalidad Presencial y Arquitectura Sostenible en Modalidad Presencial.

Dado que la población de docentes activos en la FACI durante el período de recolección ascendía a un total aproximado de 80 profesores, y considerando que poblaciones de tamaño reducido permiten la aplicación de un diseño censal sin pérdida significativa de representatividad estadística (Ramírez, 2020), se optó por aplicar el instrumento a la totalidad de los docentes que cumplieran los criterios de inclusión, prescindiendo del cálculo muestral para poblaciones finitas. Esta decisión metodológica tiene respaldo en la literatura especializada, que señala que, cuando  $N < 100$ , la aplicación censal ofrece estimaciones más precisas que cualquier diseño de muestreo probabilístico con intervalos de confianza convencionales (Hernández-Sampieri & Mendoza, 2018).

No obstante, y a efectos de documentar la cobertura lograda, se presentan los criterios de inclusión y exclusión aplicados para delimitar la unidad de análisis. Se incluyeron en el estudio todos los docentes con contrato vigente titulares, contratados u ocasionales que habían

impartido al menos una asignatura presencial o en línea durante el semestre académico 2024–2025 y que dieron su consentimiento informado para participar. Se excluyeron los docentes que se encontraban en comisión de servicios, licencia sin remuneración o baja temporal durante el período de aplicación del instrumento, así como el personal con funciones exclusivamente administrativas sin carga horaria docente activa.

Sobre la base de estos criterios, respondieron el instrumento un total de 68 docentes, lo que representa una tasa de respuesta del 85% respecto a la población elegible estimada, porcentaje que supera ampliamente el umbral del 70% recomendado por la literatura metodológica para garantizar validez de los resultados en estudios institucionales (Baruch & Holtom, 2008). La distribución de los participantes por carrera fue la siguiente: Tecnologías de la Información (n = 17, 25.0%), Ingeniería Industrial (n = 16, 23.5%), Ingeniería de Software (n = 12, 17.6%), Ingeniería en Alimentos (n = 10, 14.7%), Ingeniería Ambiental (n = 6, 8.8%), Biotecnología (n = 5, 7.4%) y Arquitectura Sostenible (n = 1, 1.5%).

### **3.4 Técnica e instrumento de recolección de datos**

La técnica empleada fue la encuesta autoadministrada en formato digital, modalidad que permite estandarizar las condiciones de respuesta, reducir el sesgo del entrevistador y facilitar la recolección simultánea de información de toda la población objetivo (Saris & Gallhofer, 2023). El instrumento diseñado para el efecto se denominó Escala de Competencia Conceptual y Práctica Pedagógica en Inteligencia Artificial Generativa (ECCPP-IAG) y fue elaborado de manera propia a partir de la revisión exhaustiva de la literatura y de la adaptación contextualizada de marcos de referencia internacionales, particularmente el modelo AI-TPACK (Celik, 2023) y el Marco de Competencias Digitales DigCompEdu (Redecker & Punie, 2020).

La ECCPP-IAG se organiza en cuatro partes. La primera recoge información sociodemográfica: género, edad, años de experiencia docente, carrera de adscripción, nivel máximo de formación académica, antecedentes de capacitación en tecnologías educativas y frecuencia de uso de herramientas de IA generativa. La segunda parte corresponde a la Dimensión 1 Competencia Conceptual en IAG, compuesta por 12 ítems distribuidos en cinco subdimensiones (fundamentos y funcionamiento del modelo; comprensión técnica aplicada; reconocimiento de limitaciones; tipología y diferenciación de herramientas; dimensión ética conceptual). Estos ítems se responden mediante una escala de acuerdo de siete puntos (1 = Totalmente en desacuerdo; 7 = Totalmente de acuerdo), lo cual incrementa la varianza de las respuestas y reduce el sesgo de tendencia central respecto a escalas de menor amplitud

(Preston & Colman, 2000). Tres de los doce ítems están redactados en sentido inverso (CC3, CC7, CC11) y deberán recodificarse antes del análisis. La tercera parte corresponde a la Dimensión 2 Práctica Pedagógica con IAG, integrada por 15 ítems agrupados en cinco subdimensiones (diseño instruccional con IA; mediación y andamiaje pedagógico; evaluación con IA; pensamiento crítico y aprendizaje activo; uso ético y modelamiento).

Esta dimensión utiliza una escala de frecuencia de cinco puntos (1 = Nunca; 5 = Siempre), congruente con la medición del comportamiento real observable en el aula, que requiere capturar la periodicidad de la acción docente más que el grado de acuerdo con un enunciado. La cuarta parte mide la Autoeficacia Docente en IAG a través de 10 ítems con escala de confianza de cinco puntos (1 = Nada seguro/a; 5 = Muy seguro/a), construidos desde la teoría de la autoeficacia de Bandura (1997), y complementa el instrumento con una sección de ocho proposiciones en formato de diferencial semántico de siete puntos que exploran las actitudes de los docentes hacia la IAG en el aula de clases.

**Validez de contenido.** El instrumento fue sometido a juicio de siete expertos en tecnología educativa, didáctica universitaria e inteligencia artificial aplicada a la educación, todos ellos con grado doctoral y publicaciones recientes en las áreas evaluadas. Cada experto valoró los ítems en cuatro criterios: claridad, coherencia, relevancia y suficiencia, empleando una escala de cuatro puntos. El coeficiente V de Aiken fue calculado por ítem y dimensión, tomando como umbral de aceptación  $V \geq 0.80$  (Aiken, 1985). Los ítems que no alcanzaron el umbral fueron reformulados o eliminados en función de las observaciones cualitativas de los expertos. La versión final del instrumento mostró valores V de Aiken superiores a 0.82 en todos los ítems.

**Validez de constructo.** Se realizó un análisis factorial confirmatorio (AFC) mediante el software R (versión 4.3) con el paquete lavaan (Rosseel, 2012), contrastando el modelo de dos factores principales (competencia conceptual y práctica pedagógica) propuesto a partir de la literatura. Se evaluaron los índices de ajuste CFI, TLI, RMSEA y SRMR siguiendo los criterios establecidos por Hu y Bentler (1999): CFI y TLI  $\geq 0.95$ , RMSEA  $\leq 0.06$  y SRMR  $\leq 0.08$  para un ajuste satisfactorio.

**Confiabilidad.** La consistencia interna del instrumento fue estimada mediante el alfa de Cronbach ( $\alpha$ ) y el coeficiente omega de McDonald ( $\omega$ ) para cada dimensión y subdimensión, empleando como umbral mínimo de aceptación  $\alpha \geq 0.80$  (Nunnally & Bernstein, 1994). El coeficiente omega fue incluido porque resulta más preciso cuando los ítems no son tau-equivalentes, condición frecuente en escalas de actitudes y competencias (McNeish, 2018).

### **3.5 Procedimiento de recolección de datos**

El proceso de recolección de información se desarrolló en cinco fases secuenciales. En la fase de autorización institucional, el investigador presentó el protocolo de investigación ante la Dirección de Posgrado de la UNEMI y solicitó formalmente la aprobación del Comité de Ética en Investigación, adjuntando el modelo de consentimiento informado, la descripción del instrumento y la declaración de confidencialidad. Obtenida la autorización, en la fase de coordinación académica se realizó un acercamiento con las Direcciones de Carrera de la FACI para informar sobre el propósito del estudio y garantizar el acceso a los docentes durante los horarios de trabajo.

En la fase de aplicación del instrumento, el cuestionario fue publicado en la plataforma Google Forms y el enlace de acceso fue distribuido por correo electrónico institucional durante el mes de noviembre de 2025, período que corresponde al segundo semestre del año académico 2024–2025. Cada docente recibió el enlace junto con el documento de consentimiento informado y contó con un plazo de tres semanas para completar el instrumento. En la fase de seguimiento, se enviaron dos recordatorios a los docentes que aún no habían respondido a los siete y catorce días de apertura del formulario, estrategia que contribuyó a alcanzar la tasa de respuesta del 85% ya señalada. Finalmente, en la fase de cierre y verificación, los datos exportados de Google Forms fueron revisados para detectar respuestas incompletas, duplicadas o con patrones de respuesta atípicos (por ejemplo, respuesta uniforme a todos los ítems), las cuales fueron excluidas del análisis antes de proceder con el procesamiento estadístico.

### **3.6 Técnicas de análisis estadístico**

El análisis de los datos se realizó en dos plataformas complementarias: SPSS versión 28 para los análisis descriptivos, inferenciales y de regresión, y R versión 4.3 para el AFC y el cálculo del coeficiente omega. El procesamiento siguió una secuencia lógica articulada en cuatro niveles analíticos.

En primer lugar, el análisis descriptivo permitió caracterizar la muestra y las variables principales. Se calcularon frecuencias y porcentajes para las variables sociodemográficas, y medias, medianas, desviaciones estándar, coeficientes de asimetría y curtosis para cada ítem y dimensión. Estos estadísticos permiten no solo describir los niveles de competencia y práctica, sino también verificar los supuestos de normalidad que condicionan la elección de las pruebas inferenciales posteriores.

En segundo lugar, la prueba de normalidad de Kolmogorov-Smirnov (con corrección de Lilliefors) fue aplicada a las puntuaciones totales de cada dimensión, dado que  $n = 68$  supera el umbral de  $n > 50$  recomendado para esta prueba (Field, 2022). Los resultados determinaron si el análisis correlacional debía realizarse mediante el coeficiente  $r$  de Pearson para distribuciones normales o el coeficiente rho de Spearman para distribuciones no paramétricas. En ambos casos, el tamaño del efecto fue interpretado con las convenciones de Cohen (1988):  $r < 0.30$  como efecto pequeño,  $0.30 \leq r < 0.50$  como efecto mediano y  $r \geq 0.50$  como efecto grande.

En tercer lugar, para el análisis comparativo por variables moderadoras (carrera, nivel de formación, años de experiencia y frecuencia de uso de IA), se empleó el análisis de varianza de un factor (ANOVA) cuando se verificó el supuesto de normalidad, o la prueba no paramétrica de Kruskal-Wallis en caso contrario. Las comparaciones post hoc entre pares de grupos se realizaron mediante la prueba de Tukey cuando las varianzas eran homogéneas (verificadas con la prueba de Levene) o Games-Howell cuando no lo eran. El tamaño del efecto para el ANOVA fue estimado mediante eta cuadrado parcial ( $\eta^2$ ), interpretado según los criterios de Cohen (1988):  $\eta^2 = 0.01$  (pequeño),  $0.06$  (mediano) y  $0.14$  (grande).

Finalmente, se ajustó un modelo de regresión lineal múltiple para examinar el poder predictivo conjunto de la competencia conceptual y las variables sociodemográficas seleccionadas (edad, años de experiencia, nivel de formación y carrera) sobre la puntuación total en práctica pedagógica con IA generativa. El modelo fue evaluado por su coeficiente de determinación ajustado ( $R^2$  ajustado) y por los supuestos de independencia de residuos (Durbin-Watson), homocedasticidad (gráfico de residuos estandarizados vs. valores pronosticados) y ausencia de multicolinealidad (factor de inflación de varianza,  $VIF < 10$ ).

### **3.7 Consideraciones éticas**

El estudio se ajustó en su totalidad a los principios éticos que rigen la investigación con sujetos humanos en el contexto universitario ecuatoriano. El principio de autonomía fue garantizado mediante la administración de un consentimiento informado detallado, en el que se especificaron el propósito del estudio, la naturaleza voluntaria de la participación, el derecho a retirarse sin consecuencia alguna y los datos de contacto del investigador principal. El principio de confidencialidad se operacionalizó a través del tratamiento anónimo de todas las respuestas: los correos electrónicos institucionales, requeridos únicamente para evitar duplicidades de respuesta, fueron disociados de los cuestionarios antes del análisis estadístico y almacenados en un repositorio cifrado con acceso restringido. Finalmente, el

tratamiento de los datos se realizó en conformidad con la Ley Orgánica de Protección de Datos Personales del Ecuador (Registro Oficial, Suplemento No. 459, 2021) y con los lineamientos del Reglamento de Ética en Investigación de la UNEMI.

## CAPÍTULO 4

### RESULTADOS

#### 4.1 Caracterización sociodemográfica de la muestra

Los 68 docentes participantes corresponden a la Facultad de Ciencias e Ingeniería (FACI) de la Universidad Estatal de Milagro. La distribución por sexo revela una marcada predominancia masculina: 51 docentes masculinos (75,0 %) frente a 17 femeninos (25,0 %), lo cual refleja la composición tradicional de las ingenierías en el Ecuador. En cuanto a la edad, el rango predominante es el de 31 a 40 años ( $n = 31$ ; 45,6 %), seguido por el grupo de 41 a 50 años ( $n = 23$ ; 33,8 %), el grupo menor de 30 años ( $n = 7$ ; 10,3 %) y el de más de 50 años ( $n = 7$ ; 10,3 %), con una media de 38,4 años ( $DE = 7,8$ ). Esta distribución sugiere una planta docente mayoritariamente en la mitad de su trayectoria profesional.

**Tabla 1**

*Caracterización sociodemográfica de la muestra ( $n = 68$ )*

Variable	Categoría	n	%
Sexo	Masculino	51	75,0
	Femenino	17	25,0
Edad	< 30 años	7	10,3
	31–40 años	31	45,6
	41–50 años	23	33,8
	> 50 años	7	10,3
Formación	Maestría	60	88,2
	Doctorado	7	10,3
	Sin dato	1	1,5
Experiencia	1–5 años	33	48,5
	6–10 años	16	23,5
	11–20 años	15	22,1
	> 20 años	4	5,9
Carrera	TIC en línea	17	25,0
	Industrial presencial	16	23,5
	Software presencial	12	17,6
	Alimentos presencial	10	14,7
	Ambiental presencial	6	8,8

	Biotecnología presencial	5	7,4
	Arquitectura Sostenible	1	1,5
	Sin dato / otra	1	1,5
<b>Capacitación TEC</b>	Últimos 6 meses	25	36,8
	Último año	27	39,7
	Últimos 5 años	13	19,1
	Nunca	2	2,9
	Hace más de 5 años	1	1,5
<b>Uso actual de IAG</b>	Frecuentemente (diario)	41	60,3
	Regularmente (semanal)	24	35,3
	Ocasionalmente	3	4,4

### Análisis e interpretación

La formación académica predominante es la maestría (88,2 %), con apenas un 10,3 % con nivel doctoral. Un dato significativo es que el 60,3 % de los docentes reporta usar herramientas de IAG diariamente, y un 35,3 % semanalmente; la totalidad de la muestra ha tenido algún nivel de contacto con estas herramientas, lo cual elimina el sesgo de desconocimiento total y hace más relevante el análisis de la brecha entre competencia y práctica.

#### 4.2 Confiabilidad del instrumento

Antes de presentar los resultados descriptivos, se reportan los índices de consistencia interna obtenidos para cada dimensión del instrumento, calculados mediante el coeficiente alfa de Cronbach.

**Tabla 2**

*Índices de confiabilidad por dimensión*

<b>Dimensión</b>	<b>N° ítems</b>	<b>Escala</b>	<b><math>\alpha</math> de Cronbach</b>	<b>Interpretación</b>
Competencia Conceptual en IAG	12	1–7	<b>0,815</b>	Buena
Práctica Pedagógica con IAG	15	1–5	<b>0,965</b>	Excelente
Autoeficacia docente en IAG	10	1–5	<b>0,918</b>	Excelente
Actitudes hacia la IAG en aula	8	1–7	<b>0,927</b>	Excelente

### Análisis e interpretación

Todos los valores superan el umbral de 0,80 recomendado para investigaciones en ciencias sociales (Hair et al., 2019), lo que avala la fiabilidad del instrumento utilizado. El coeficiente para Competencia Conceptual ( $\alpha = 0,815$ ), aunque inferior a las demás dimensiones, se mantiene dentro del rango aceptable, lo cual coincide con lo reportado por Celik et al. (2022) al medir conocimiento declarativo sobre IA en docentes universitarios, donde la naturaleza multidimensional del constructo tiende a reducir marginalmente la consistencia interna.

#### 4.3 Análisis descriptivo por ítem — Dimensión 1: Competencia Conceptual en IAG

La escala de Competencia Conceptual comprende 12 ítems con respuesta en formato Likert de 7 puntos (1 = Completamente en desacuerdo; 7 = Completamente de acuerdo). Tres ítems fueron redactados en sentido negativo (CC3, CC7, CC11) y se invirtieron antes del análisis (puntuación = 8 - valor original).

**Tabla 3**

*Estadísticos descriptivos por ítem — Competencia Conceptual (escala 1–7, n = 68)*

Ítem	Enunciado (síntesis)	M	DE	Mdn	% rango
CC1	Comprendo los principios básicos de cómo los LLM generan texto	5,57	1,44	6,00	76,2 %
CC2	Puedo explicar la diferencia entre IAG y motores de búsqueda	5,65	1,32	6,00	77,5 %
CC3*	Los conceptos técnicos de la IAG me resultan demasiado complejos (inv.)	4,06	1,90	4,00	51,0 %
CC4	Entiendo qué son los <i>prompts</i> y cómo influyen en las respuestas	6,01	1,33	7,00	83,5 %
CC5	Conozco las limitaciones de la IAG (alucinaciones, sesgos)	5,63	1,35	6,00	77,2 %
CC6	Puedo identificar cuándo una respuesta de IAG puede ser incorrecta	5,72	1,31	6,00	78,7 %
CC7*	No entiendo cómo la IAG puede "aprender" o mejorar (inv.)	4,04	1,93	4,00	50,7 %
CC8	Comprendo los conceptos de <i>tokens</i> , contexto y temperatura	4,62	1,76	5,00	60,3 %
CC9	Puedo distinguir entre diferentes tipos de IAG (texto, imagen, código)	5,22	1,66	5,00	70,3 %
CC10	Entiendo las implicaciones éticas del uso de IAG en educación	5,69	1,52	6,00	78,2 %
CC11*	Me confunde la terminología técnica asociada con la IAG (inv.)	4,43	1,87	4,00	57,2 %
CC12	Comprendo cómo los datos de entrenamiento influyen en la IAG	5,44	1,64	6,00	74,0 %
<b>TOTAL</b>	<b>Media de la dimensión</b>	<b>5,17</b>	<b>0,92</b>	<b>5,22</b>	<b>69,6 %</b>

*Nota.* \* Ítem redactado en sentido negativo, puntuación invertida antes del análisis.

#### Análisis e interpretación

La dimensión de Competencia Conceptual alcanza una media global de  $M = 5,17$  ( $DE = 0,92$ ) sobre una escala de 7 puntos, lo que equivale al 69,6 % del rango máximo posible. El ítem con mayor puntuación media es CC4, relativo al conocimiento sobre *prompts* ( $M = 6,01$ ;  $DE = 1,33$ ), lo que evidencia que los docentes han desarrollado familiaridad con el componente más instrumental de la interacción con IAG. Por el contrario, los ítems CC3 y CC7 ambos referidos a la comprensión de aspectos arquitectónicos y de aprendizaje automático de los modelos obtuvieron las medias más bajas ( $M = 4,06$  y  $M = 4,04$  respectivamente), incluso tras la inversión de su escala, con desviaciones estándar que superan 1,90, lo cual indica alta dispersión y heterogeneidad en ese subdominio.

Lo anterior sugiere que el conocimiento declarativo de los docentes de la FACI-UNEMI no es homogéneo: es marcadamente mayor en los aspectos funcionales y de uso cotidiano de la IAG (identificar errores, conocer limitaciones, usar *prompts*) que en los fundamentos técnicos y arquitectónicos de los sistemas. Esto coincide con lo reportado por Lim et al. (2023) en universidades de Singapur, donde la mayoría de docentes demostraba conocimiento funcional pero no estructural de los LLM, y con los hallazgos de Álvarez-Herrero et al. (2024) en universidades españolas, quienes describen un perfil de "usuario consciente" que entiende qué hace la IA pero no cómo lo hace. Desde la perspectiva del marco AI-TPACK (Celik, 2023), estos resultados indican que los docentes han consolidado la dimensión de *conocimiento sobre IA* ligada al uso, pero presentan debilidades en la subdimensión técnica del mismo.

**Tabla 4**

*Distribución de frecuencias y forma de la distribución — Competencia Conceptual (n = 68)*

Ítem	Enunciado (síntesis)	Bajo (1–2)	Medio (3–5)	Alto (6–7)	Asimetría	Curtosis
CC1	Principios básicos de LLM	4,4 %	30,9 %	<b>64,7 %</b>	-1,25	1,59
CC2	IAG vs. motores de búsqueda	2,9 %	33,8 %	<b>63,2 %</b>	-1,22	1,66
CC3*	Complejidad técnica excesiva (inv.)	25,0 %	47,1 %	27,9 %	0,02	-1,10
CC4	Comprensión de <i>prompts</i>	2,9 %	23,5 %	<b>73,5 %</b>	-1,43	1,39
CC5	Limitaciones de la IAG	2,9 %	39,7 %	<b>57,4 %</b>	-0,80	0,00
CC6	Detección de respuestas incorrectas	2,9 %	33,8 %	<b>63,2 %</b>	-0,88	0,17
CC7*	Aprendizaje e improv. IAG (inv.)	20,9 %	50,7 %	28,4 %	0,08	-1,08
CC8	<i>Tokens</i> , contexto, temperatura	13,2 %	54,4 %	32,4 %	-0,44	-0,56
CC9	Tipos de IAG (texto/imagen/código)	8,8 %	45,6 %	45,6 %	-0,75	-0,11
CC10	Implicaciones éticas en educación	2,9 %	33,8 %	<b>63,2 %</b>	-1,17	0,97
CC11*	Confusión con terminología (inv.)	16,2 %	51,5 %	32,4 %	-0,11	-1,00
CC12	Datos de entrenamiento	5,9 %	41,2 %	<b>52,9 %</b>	-0,85	0,02

Nota. \* Ítems negativos invertidos. Las categorías "Bajo/Medio/Alto" reflejan la puntuación ya recodificada.

### Análisis e interpretación

Los ítems con orientación funcional (CC1, CC2, CC4, CC6, CC10) exhiben distribuciones fuertemente sesgadas hacia la izquierda (asimetrías entre  $-0,88$  y  $-1,43$ ), con curtosis positiva en varios casos, lo que indica concentración de respuestas en los valores altos de la escala y escasa dispersión. Este patrón es indicativo de un efecto techo incipiente en estos ítems: la mayoría de los docentes ha alcanzado un umbral de comprensión funcional que hace difícil discriminar entre sujetos en el extremo superior. Por el contrario, CC3 y CC7 que miden la comprensión de los mecanismos internos de la IAG presentan distribuciones prácticamente simétricas (asimetrías de  $0,02$  y  $0,08$ ) y curtosis negativas ( $-1,10$  y  $-1,08$ ), lo que revela distribuciones bimodales o platilépticas: los docentes se distribuyen de manera más uniforme a lo largo de la escala, sin concentración clara en ningún polo, señal de alta heterogeneidad y, por tanto, de un conocimiento técnico-arquitectónico genuinamente dividido dentro del cuerpo docente. Este patrón bifurcado en los ítems de arquitectura interna coincide con lo identificado por Southworth et al. (2023) al examinar la literacidad en IA de profesores de STEM en universidades de habla hispana, donde la variabilidad en la comprensión de los fundamentos computacionales de los LLM era significativamente mayor que en el conocimiento operacional de los mismos.

#### 4.4 Análisis descriptivo por ítem — Dimensión 2: Práctica Pedagógica con IAG

La dimensión de Práctica Pedagógica comprende 15 ítems valorados en escala de frecuencia de cinco puntos (1 = Nunca; 5 = Siempre), organizados en cinco subdimensiones: diseño instruccional con IA (PP1–PP3), mediación y andamiaje pedagógico (PP4–PP6), evaluación con IA (PP7–PP9), pensamiento crítico y aprendizaje activo (PP10–PP12) y uso ético y modelamiento (PP13–PP15).

**Tabla 5**

*Estadísticos descriptivos por ítem — Práctica Pedagógica (escala 1–5, n = 68)*

Ítem	Enunciado (síntesis)	M	DE	Mdn	% rango
PP1	Diseño actividades de aprendizaje integrando IAG	3,76	1,31	4,00	69,0 %

Ítem	Enunciado (síntesis)	M	DE	Mdn	% rango
PP2	Selecciono herramientas de IAG según el objetivo de aprendizaje	3,65	1,35	4,00	66,3 %
PP3	Adapto el currículo para incorporar IAG de forma coherente	3,22	1,41	3,00	55,5 %
PP4	Guío a los estudiantes en el uso pedagógico de la IAG	3,93	1,24	4,00	73,3 %
PP5	Proporciono andamiaje cuando los estudiantes usan IAG	3,57	1,29	4,00	64,3 %
PP6	Retroalimentación el proceso de uso de IAG de los estudiantes	3,62	1,30	4,00	65,5 %
PP7	Uso IAG para diseñar instrumentos de evaluación	3,31	1,46	3,00	57,8 %
PP8	Incorporo IAG en la retroalimentación formativa	3,41	1,42	4,00	60,3 %
PP9	Promuevo la autoevaluación asistida por IAG	3,00	1,44	3,00	50,0 %
PP10	Fomento el pensamiento crítico sobre los outputs de IAG	3,90	1,25	4,00	72,5 %
PP11	Diseño tareas que requieren evaluar críticamente respuestas de IAG	3,68	1,32	4,00	67,0 %
PP12	Promuevo el aprendizaje activo mediante IAG	3,72	1,26	4,00	68,0 %
PP13	Modelo el uso ético de la IAG ante mis estudiantes	4,03	1,22	4,00	75,8 %
PP14	Abordo explícitamente los riesgos del uso de IAG en el aula	3,88	1,26	4,00	72,0 %
PP15	Establezco normas claras de uso de IAG en mis asignaturas	3,72	1,34	4,00	68,0 %
<b>TOTAL</b>	<b>Media de la dimensión</b>	<b>3,56</b>	<b>1,01</b>	<b>3,60</b>	<b>64,1 %</b>

**Tabla 6**

*Distribución de frecuencias y forma de la distribución — Práctica Pedagógica (n = 68)*

Ítem	Nunca (1)	Raramente (2)	A veces (3)	Frecuentemente (4)	Siempre (5)	Asimetría	Curiosis
PP1	4,4 %	13,2 %	22,1 %	36,8 %	23,5 %	-0,62	-0,52
PP2	5,9 %	13,2 %	25,0 %	36,8 %	19,1 %	-0,57	-0,51
PP3	11,8 %	20,6 %	29,4 %	26,5 %	11,8 %	-0,21	-0,83
PP4	2,9 %	11,8 %	20,6 %	38,2 %	26,5 %	-0,79	-0,19
PP5	5,9 %	16,2 %	25,0 %	36,8 %	16,2 %	-0,47	-0,62
PP6	5,9 %	13,2 %	27,9 %	36,8 %	16,2 %	-0,50	-0,53
PP7	13,2 %	19,1 %	26,5 %	26,5 %	14,7 %	-0,23	-0,91
PP8	10,3 %	16,2 %	25,0 %	32,4 %	16,2 %	-0,38	-0,78
PP9	16,2 %	22,1 %	29,4 %	22,1 %	10,3 %	-0,08	-0,88
PP10	2,9 %	11,8 %	22,1 %	38,2 %	25,0 %	-0,76	-0,26
PP11	5,9 %	13,2 %	25,0 %	36,8 %	19,1 %	-0,57	-0,51
PP12	4,4 %	11,8 %	26,5 %	38,2 %	19,1 %	-0,61	-0,37

PP13	2,9 %	10,3 %	19,1 %	38,2 %	29,4 %	-0,88	-0,01
PP14	2,9 %	11,8 %	22,1 %	39,7 %	23,5 %	-0,75	-0,21
PP15	5,9 %	13,2 %	25,0 %	35,3 %	20,6 %	-0,61 %	-0,52

**Tabla 7**

*Comparación de medias por subdimensión — Práctica Pedagógica*

Subdimensión	Ítems	M	DE	% rango
Diseño instruccional con IA	PP1–PP3	3,54	1,21	63,5 %
Mediación y andamiaje pedagógico	PP4–PP6	3,71	1,11	67,7 %
Evaluación con IA	PP7–PP9	3,24	1,28	56,0 %
Pensamiento crítico y aprendizaje activo	PP10–PP12	3,77	1,17	69,2 %
Uso ético y modelamiento	PP13–PP15	3,88	1,13	72,0 %
<b>TOTAL</b>	<b>PP1–PP15</b>	<b>3,56</b>	<b>1,01</b>	<b>64,1 %</b>

### **Análisis e interpretación**

La dimensión de Práctica Pedagógica alcanza una media global de  $M = 3,56$  ( $DE = 1,01$ ) sobre una escala de 5 puntos, equivalente al 64,1 % del rango máximo posible. El análisis por subdimensiones revela una estructura interna diferenciada. La subdimensión de uso ético y modelamiento obtiene la puntuación relativa más alta (72,0 % del rango), seguida de pensamiento crítico y aprendizaje activo (69,2 %) y de mediación y andamiaje pedagógico (67,7 %), mientras que la evaluación con IA constituye el punto de menor intensidad práctica del conjunto (56,0 %). Este gradiente descendente desde las prácticas de modelamiento ético hasta las de evaluación es coherente con la lógica de adopción tecnológica progresiva: los docentes incorporan primero aquellas acciones que suponen un menor riesgo pedagógico y una mayor continuidad con sus prácticas previas, y postergan las que exigen mayor rediseño de los procesos establecidos, como la evaluación asistida por IA.

El ítem PP9 referido a la promoción de autoevaluación asistida por IAG registra la media más baja de toda la dimensión ( $M = 3,00$ ;  $DE = 1,44$ ), con el 38,3 % de respuestas en las categorías "Nunca" o "Raramente", y es también el de mayor desviación estándar, indicando alta heterogeneidad de práctica en ese subdominio específico. Por el contrario, PP13 que mide el modelamiento del uso ético ante los estudiantes obtiene la media más alta ( $M = 4,03$ ;  $DE = 1,22$ ), con el 67,6 % de respuestas en los niveles "Frecuentemente" o "Siempre", lo que refleja que el componente normativo y de orientación de la práctica con IA ha sido más fácilmente asimilado que los componentes de rediseño evaluativo. Estos hallazgos coinciden

con los de Chan y Hu (2023) en el contexto de Hong Kong, donde el modelamiento ético fue la conducta docente más reportada y el rediseño de la evaluación con IA la menos frecuente.

#### 4.5 Análisis descriptivo global y comparación entre las dos variables principales

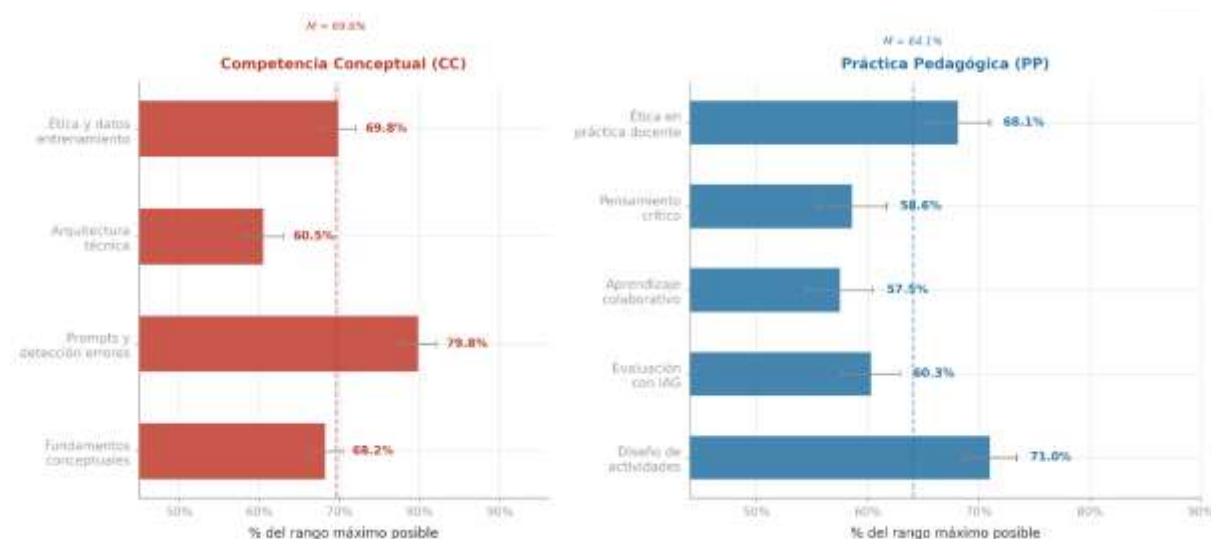
**Tabla 8**

*Comparación de medias globales entre las dos variables principales*

Variable	M (escala original)	DE	Mdn	% rango máx.	Nivel predominante
Competencia Conceptual (1–7)	5,17	0,92	5,22	<b>69,6 %</b>	Alto (76,5 % de la muestra)
Práctica Pedagógica (1–5)	3,56	1,01	3,60	<b>64,1 %</b>	Alto-medio (55,9 % / 35,3 %)
Autoeficacia docente (1–5)	3,91	0,83	3,93	<b>72,7 %</b>	Moderado-alto
Actitudes hacia IAG (1–7)	5,60	1,06	5,75	<b>76,7 %</b>	Positivas
<b>Brecha CC – PP (puntos %)</b>	---	---	---	<b>5,4 pp</b>	---

**Figura 1**

*Perfil de puntuaciones por subdimensión en Competencia Conceptual y Práctica Pedagógica (% del rango máximo posible), docentes FACI-UNEMI, 2025*



*Nota.* Las barras representan la media de cada subdimensión normalizada al rango máximo de su escala respectiva [CC: 1–7; PP: 1–5]. Las líneas discontinuas indican la media global

de cada dimensión (CC = 69.6 %; PP = 64.1 %). Las barras de error corresponden al error estándar de la media ( $\pm 1$  SE). Los tres ítems negativos de CC (CC3, CC7, CC11) fueron invertidos antes del cálculo.  $n = 68$ .

### **Análisis e interpretación**

Los datos de la Tabla 8 ofrecen una imagen de conjunto que va más allá de la simple descripción de medias: permiten leer el perfil cognitivo, conductual y afectivo del cuerpo docente de la FACI-UNEMI frente a la IAG como un sistema de dimensiones interrelacionadas, cuyas tensiones internas constituyen el hallazgo estructural del estudio.

La primera lectura revela un gradiente descendente cuando se ordenan las dimensiones por su porcentaje de rango máximo: Actitudes (76,7 %), Autoeficacia (72,7 %), Competencia Conceptual (69,6 %) y Práctica Pedagógica (64,1 %). Este ordenamiento no es trivial. Que las actitudes encabecen la jerarquía con la mayor puntuación media de todo el instrumento ( $M = 5,60$  sobre una escala de 7 puntos;  $Mdn = 5,75$ ) indica que la disposición favorable hacia la IAG en el aula se ha consolidado ampliamente en esta muestra: los docentes valoran positivamente la tecnología y no oponen resistencia declarada a su incorporación. Sin embargo, desde la perspectiva de la Teoría del Comportamiento Planificado (Ajzen, 1991), la actitud positiva es condición necesaria pero no suficiente para producir conducta; requiere, adicionalmente, de norma subjetiva favorable y de control conductual percibido. Lo que la tabla revela es que precisamente estas dos condiciones son las que operan con menor intensidad: la dimensión de práctica pedagógica, que es la expresión conductual más directa, obtiene la puntuación más baja del conjunto, 12,6 puntos porcentuales por debajo de la dimensión actitudinal.

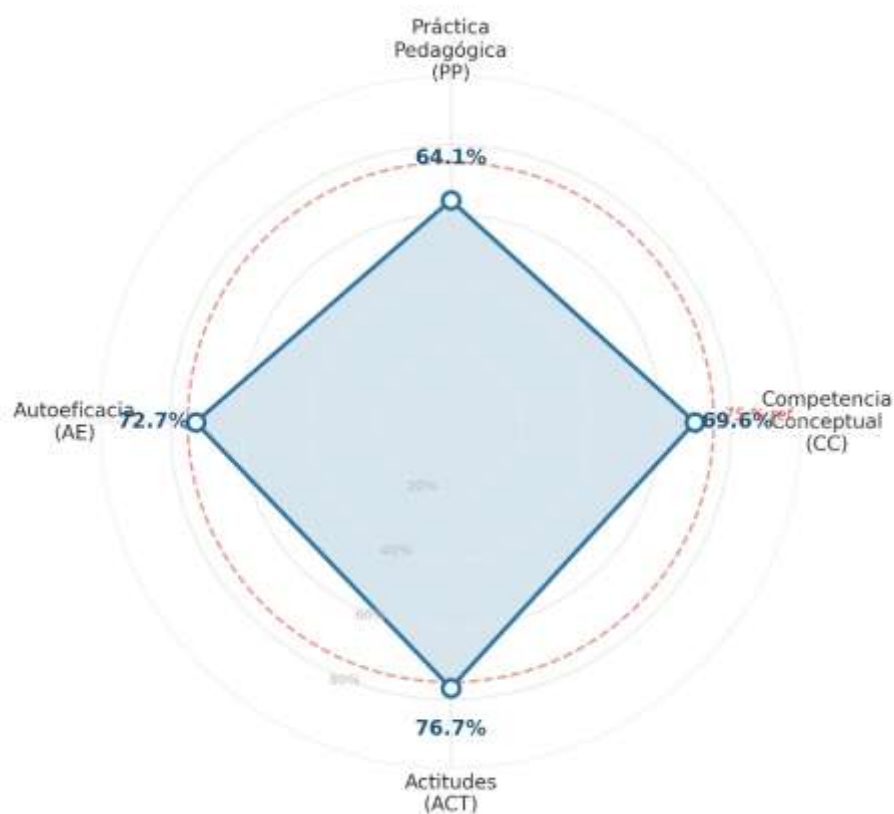
La segunda lectura concierne a la relación entre Competencia Conceptual y Práctica Pedagógica, que es la brecha que da nombre al presente estudio. Normalizadas al rango máximo de sus respectivas escalas, ambas variables se separan por 5,4 puntos porcentuales a favor del conocimiento declarativo. Aunque esta diferencia pueda parecer moderada en términos absolutos, su interpretación cambia sustancialmente cuando se examina la distribución por niveles que la acompaña: el 76,5 % de los docentes alcanza un nivel alto de competencia conceptual, mientras que en práctica pedagógica ese porcentaje desciende a 55,9 %, con un 35,3 % adicional en nivel medio y un 8,8 % en nivel bajo. Dicho de otro modo, alrededor de dos de cada diez docentes que poseen conocimiento conceptual avanzado

sobre IAG no han logrado traducirlo en una práctica pedagógica equivalente. Este patrón configura con precisión el fenómeno denominado *knowing-doing gap* (Pfeffer & Sutton, 2000): la distancia no está en la voluntad ni en el saber declarativo, sino en el puente que une el conocimiento con la acción.

La baja desviación estándar de la Autoeficacia (DE = 0,83) en comparación con la de la Competencia Conceptual (DE = 0,92) y la Práctica Pedagógica (DE = 1,01) indica que los docentes son más homogéneos en su confianza operativa que en su nivel de conocimiento o en la frecuencia de sus prácticas pedagógicas. Este detalle estadístico refuerza la idea de que la variabilidad en la práctica docente no se explica por diferencias en autoconfianza, sino por otros factores que el modelo simple de correlación entre CC y PP no captura y que el modelo de regresión múltiple, presentado en la sección 4.11, permite identificar con mayor precisión.

## Figura 2

Diagrama radial de las cuatro dimensiones del instrumento: síntesis del perfil docente en IAG, FACI-UNEMI, 2025



*Nota.* Las barras representan la media de cada ítem normalizada al rango máximo de la escala (1–5). El código de color identifica los tres subdimensiones: competencia técnica (AE1–AE3; naranja), competencia pedagógica (AE4–AE6; azul), e integración y actualización (AE7–AE10; verde). Las barras de error indican  $\pm 1$  SE. La línea discontinua señala el umbral de referencia del 75 %. Los valores entre paréntesis en la leyenda corresponden a la media de cada subdimensión. n = 68.

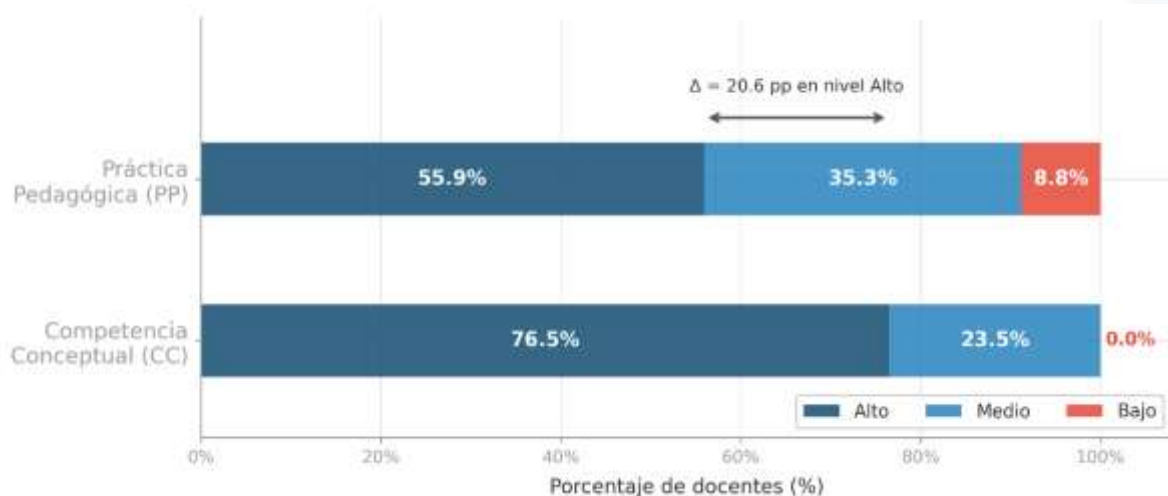
**Tabla 9**

*Clasificación por nivel en cada dimensión principal*

Nivel	Competencia Conceptual	%	Práctica Pedagógica	%
Alto	52 docentes	76,5 %	38 docentes	55,9 %
Medio	16 docentes	23,5 %	24 docentes	35,3 %
Bajo	0 docentes	0,0 %	6 docentes	8,8 %

**Figura 3**

*Distribución porcentual de docentes por nivel de desempeño en Competencia Conceptual y Práctica Pedagógica (Alto / Medio / Bajo), FACI-UNEMI, 2025*



*Nota.* La clasificación por niveles se realizó a partir de los siguientes puntos de corte sobre las puntuaciones de escala original: Competencia Conceptual (escala 1–7): Bajo  $\leq 2.5$ , Medio 2.6–4.5, Alto  $> 4.5$ . Práctica Pedagógica (escala 1–5): Bajo  $\leq 2.0$ , Medio 2.1–3.5, Alto  $> 3.5$ . La flecha indica la diferencia de 20.6 puntos porcentuales entre la proporción de docentes en nivel Alto en CC (76.5 %) versus PP (55.9 %). n = 68.

### Análisis e interpretación

La brecha de 5,4 puntos porcentuales entre Competencia Conceptual (69,6 %) y Práctica Pedagógica (64,1 %), calculada a partir de la normalización al rango máximo de cada escala, constituye el dato central del estudio. Si se examina la distribución por niveles, la asimetría se vuelve más evidente: mientras que ningún docente se ubica en el nivel bajo de Competencia Conceptual, el 8,8 % sí registra práctica pedagógica baja, y el 35,3 % permanece en nivel medio pese a que el 76,5 % muestra competencia conceptual alta. Lo anterior evidencia un fenómeno de *knowing-doing gap* (Pfeffer & Sutton, 2000) en el que el conocimiento declarativo no se traduce de forma automática en transformación de la práctica. En concordancia con los resultados de Yildiz Durak (2023) en docentes universitarios turcos y de Ceballos-Almeraya et al. (2024) en universidades mexicanas, el conocimiento sobre IA precede y no predetermina su uso pedagógico, mediado por variables de autoeficacia, infraestructura y resistencia al cambio.

#### 4.6 Análisis descriptivo de la Autoeficacia docente en IAG

La autoeficacia docente en IAG entendida como la confianza del docente en su capacidad para ejecutar tareas específicas con estas herramientas (Bandura, 1997) fue medida con 10 ítems en escala de 5 puntos, organizados en tres subdimensiones: competencia técnica con IAG (AE1–AE3), competencia pedagógica con IAG (AE4–AE6) e integración y actualización (AE7–AE10).

**Tabla 10**

*Estadísticos descriptivos por ítem — Autoeficacia docente (escala 1–5, n = 68)*

Ítem	Enunciado (síntesis)	M	DE	Mdn	Bajo %	Medio %	Alto %	Asim.
AE1	Resolver problemas técnicos básicos	4,06	0,93	4,00	5,9 %	17,6 %	<b>76,5 %</b>	-0,93
AE2	Enseñar a un colega a usar ChatGPT	4,03	1,06	4,00	5,9 %	23,5 %	<b>70,6 %</b>	-1,05
AE3	Identificar y corregir info incorrecta	4,21	0,89	4,00	5,9 %	13,2 %	<b>80,9 %</b>	-0,95
AE4	Crear actividad innovadora en < 30 min	3,97	1,12	4,00	10,3 %	19,1 %	<b>70,6 %</b>	-0,99
AE5	Guiar uso ético a estudiantes	4,06	1,10	4,00	7,4 %	17,6 %	<b>75,0 %</b>	-1,28
AE6	Evaluar calidad de contenido IAG	4,18	0,93	4,00	5,9 %	13,2 %	<b>80,9 %</b>	-1,17
AE7	Personalizar config. IAG para educación	3,91	1,11	4,00	9,0 %	25,4 %	65,7 %	-0,84
AE8	Integrar IAG en flujo de trabajo docente	3,37	1,29	4,00	<b>26,9 %</b>	20,9 %	52,2 %	-0,39
AE9	Resolver dificultades de est. con IAG	3,28	1,28	3,00	<b>28,4 %</b>	25,4 %	46,3 %	-0,24
AE10	Mantenerse actualizado en IAG educativa	3,99	1,11	4,00	13,2 %	17,6 %	69,1 %	-0,77


**Tabla 11**

*Subdimensiones de la Autoeficacia docente*

Subdimensión	Ítems	M	DE	% rango
Competencia técnica con IAG	AE1–AE3	<b>4,10</b>	0,74	<b>77,5 %</b>
Competencia pedagógica con IAG	AE4–AE6	<b>4,07</b>	0,93	<b>76,7 %</b>
Integración y actualización	AE7–AE10	3,64	1,05	66,0 %
<b>TOTAL</b>	<b>AE1–AE10</b>	<b>3,91</b>	<b>0,83</b>	<b>72,7 %</b>

**Figura 4**

*Perfil de autoeficacia docente en IAG por ítem y subdimensión (% del rango máximo, escala 1–5), FACI-UNEMI, 2025*



*Nota.* Las barras representan la media de cada ítem normalizada al rango máximo de la escala (1–5). El código de color identifica las tres subdimensiones: competencia técnica (AE1–AE3; naranja), competencia pedagógica (AE4–AE6; azul), e integración y actualización (AE7–AE10; verde). Las barras de error indican  $\pm 1$  SE. La línea discontinua señala el umbral de referencia del 75 %. Los valores entre paréntesis en la leyenda corresponden a la media de cada subdimensión.  $n = 68$ .

### **Análisis e interpretación**

Los diez ítems de la escala de autoeficacia docente revelan un perfil internamente diferenciado que no puede reducirse a una puntuación global sin perder información sustantiva. La tabla permite identificar con claridad dos zonas de autoeficacia con dinámicas opuestas.

La primera zona, integrada por los ítems AE1 a AE7, agrupa las tareas de competencia técnica, pedagógica y de orientación ética. Las medias oscilan entre 3,91 y 4,21, las proporciones de respuesta alta superan el 65 % en todos los casos, y las asimetrías negativas pronunciadas entre 0,84 y 1,28 indican que las distribuciones se concentran en los valores superiores de la escala. AE3 (identificar y corregir información incorrecta;  $M = 4,21$ ) y AE6 (evaluar calidad de contenido IAG;  $M = 4,18$ ) son los ítems con mayor puntuación media y con el porcentaje más alto de respuestas en nivel alto (80,9 % en ambos casos), lo que refleja que los docentes se perciben especialmente competentes en tareas de verificación y juicio crítico sobre los outputs de la IAG, habilidades que probablemente transfieren desde su experticia disciplinar previa. AE5, referido a guiar éticamente a los estudiantes en el uso de IAG, también alcanza una media elevada ( $M = 4,06$ ) con el 75,0 % de respuestas altas, lo que es coherente con la dimensión actitudinal del estudio, donde las actitudes positivas hacia la IAG resultaron ser la dimensión mejor valorada del instrumento.

La segunda zona, conformada exclusivamente por AE8 y AE9, constituye el punto de quiebre del perfil. AE8 (integrar la IAG en el flujo de trabajo docente actual;  $M = 3,37$ ;  $DE = 1,29$ ) y AE9 (resolver dificultades de los estudiantes con IAG;  $M = 3,28$ ;  $DE = 1,28$ ) no solo registran las medias más bajas de la dimensión, sino que concentran el 26,9 % y el 28,4 % de respuestas en el nivel bajo respectivamente, y sus asimetrías se aproximan a cero ( $-0,39$  y  $-0,24$ ), lo que señala distribuciones casi simétricas con alta dispersión: los docentes se reparten de forma relativamente uniforme a lo largo de la escala, sin consenso en ningún polo. Esta heterogeneidad no es un dato menor: indica que la capacidad de integrar la IAG de forma fluida en la práctica cotidiana y de mediar en las dificultades del alumnado divide al colectivo en partes casi iguales entre quienes se sienten capaces y quienes no. La Mdn de AE9 desciende a 3,00 el único ítem cuya mediana no alcanza el valor 4 lo que confirma que, en términos de tendencia central robusta, la mitad de la muestra se declara en el límite entre la capacidad y la incapacidad para esta tarea concreta.

La distinción entre estas dos zonas no es casual ni meramente cuantitativa: refleja la diferencia entre autoeficacia de uso personal saber usar la herramienta para sí mismo, evaluar su output, guiar éticamente a otros de forma declarativa y autoeficacia de integración

pedagógica embeber la IAG en el flujo real de la clase, sostenerla cuando los estudiantes enfrentan dificultades. Esta distinción, descrita por Tondeur et al. (2017) como la brecha entre confianza de uso y confianza de enseñanza, es la que los programas de formación docente breves típicamente no logran cerrar, pues la segunda requiere práctica contextualizada, observación de modelos y retroalimentación en situación real, condiciones que una capacitación puntual no garantiza. Los datos de la Tabla 10 orientan, por tanto, el diseño del programa formativo propuesto en el Capítulo 5 hacia una prioridad concreta: no es necesario fortalecer la confianza técnica general de los docentes, que ya es alta; lo urgente es crear espacios estructurados donde la integración pedagógica de la IAG pueda practicarse, observarse y retroalimentarse en condiciones reales de aula.

#### 4.7 Actitudes hacia la IAG en el aula

La dimensión de actitudes agrupa 8 ítems valorados en escala de 7 puntos que evalúan la percepción del docente sobre el papel de la IAG en contextos de aula (orientación hacia la utilidad, el riesgo percibido, la conveniencia pedagógica y la apertura al cambio).

**Tabla 12**

*Estadísticos descriptivos por ítem — Actitudes hacia la IAG en el aula (escala 1–7, n = 68)*

Ítem	M	DE	Mdn	Bajo % (1–2)	Medio % (3–5)	Alto % (6–7)
ACT1	5,87	1,32	6,00	4,5 %	25,4 %	<b>70,1 %</b>
ACT2	5,71	1,29	6,00	1,5 %	38,2 %	<b>60,3 %</b>
ACT3	5,61	1,30	6,00	1,5 %	40,3 %	<b>58,2 %</b>
ACT4	5,24	1,22	5,00	1,5 %	59,7 %	38,8 %
ACT5	5,79	1,30	6,00	2,9 %	32,4 %	<b>64,7 %</b>
ACT6	5,69	1,18	6,00	0,0 %	42,6 %	<b>57,4 %</b>
ACT7	5,07	1,43	5,00	5,9 %	50,0 %	44,1 %
ACT8	5,88	1,46	6,00	5,9 %	23,5 %	<b>70,6 %</b>
<b>TOTAL</b>	<b>5,60</b>	<b>1,06</b>	<b>5,75</b>	---	---	---

#### Análisis e interpretación

Las actitudes constituyen la dimensión con mayor puntuación media de todo el estudio (M = 5,60; 76,7 % del rango en escala de 7 puntos). Ningún ítem registra más del 6 % de respuestas en las categorías bajas (1–2), y seis de los ocho ítems superan el 55 % de

respuestas en el nivel alto (6–7). ACT4 y ACT7 son los menos favorables, con medianas en el punto medio de la escala (5,00), lo que indica que estos aspectos plausiblemente asociados a la complejidad percibida de la integración o al riesgo académico generan mayor ambivalencia. Pese a que la mayoría de los docentes manifiesta actitudes positivas, la correlación entre actitudes y práctica pedagógica resulta débil y no significativa con Pearson ( $r = 0,166$ ;  $p = 0,177$ ), aunque alcanza significación marginal con Spearman ( $\rho = 0,274$ ;  $p = 0,024$ ). Esto indica que la disposición favorable hacia la IAG si bien necesaria no es suficiente para predecir la práctica pedagógica real, lo que contradice el supuesto simplista de que cambiar actitudes garantiza cambio de conducta. Desde la perspectiva de la Teoría del Comportamiento Planificado (Ajzen, 1991), las actitudes positivas deben combinarse con normas subjetivas favorables (apoyo institucional, percepción de que los colegas también lo hacen) y con control conductual percibido (autoeficacia) para traducirse en acción. Los datos de este estudio sugieren que las actitudes ya están resueltas en esta muestra; el cuello de botella reside en la autoeficacia de integración y en los apoyos institucionales.

#### 4.8 Prueba de normalidad y selección de estadístico correlacional

**Tabla 13**

*Prueba de Kolmogorov-Smirnov para las variables principales (n = 68)*

Variable	D de K-S	p	Decisión
Competencia Conceptual	0,083	0,705	Distribución normal ( $p > 0,05$ )
Práctica Pedagógica	0,107	0,392	Distribución normal ( $p > 0,05$ )

#### **Análisis e interpretación**

Dado que ambas variables siguen distribución normal según la prueba de Kolmogorov-Smirnov, se utilizó la correlación de Pearson como estadístico principal, complementada con la correlación de Spearman para verificación no paramétrica. Esta doble estrategia de análisis, recomendada por Field (2022) para estudios con muestras de tamaño moderado, garantiza la robustez de las conclusiones inferenciales ante posibles desviaciones locales de la normalidad en subgrupos de la distribución.

## 4.9 Prueba de hipótesis principal — Correlación entre Competencia Conceptual y Práctica Pedagógica


**Tabla 14**

*Coefficientes de correlación entre Competencia Conceptual y Práctica Pedagógica*

Estadístico	Valor p	Tamaño del efecto	Decisión sobre $H_0$
Pearson r	<b>0,443</b> 0,000157	Moderado (Cohen, 1988)	<b>Se rechaza <math>H_0</math></b>
Spearman $\rho$	<b>0,424</b> 0,000314	Moderado	Se rechaza $H_0$
$R^2$ (varianza explicada)	<b>0,196</b> ---	19,6 %	---

**Figura 5**

*Diagrama de dispersión con línea de regresión OLS entre Competencia Conceptual y Práctica Pedagógica (valores normalizados al % del rango), docentes FACI-UNEMI, 2025.*



*Nota.* Cada punto representa un docente. La línea continua corresponde a la regresión por mínimos cuadrados ordinarios (OLS); la banda sombreada indica el intervalo de confianza al 95 % obtenido por bootstrap (1 000 iteraciones). La línea punteada diagonal representa la

línea de equidad (CC = PP); los puntos por debajo de esta línea indican docentes cuya práctica supera su competencia conceptual declarada. Pearson  $r = 0,443$ ,  $R^2 = 0,196$ ,  $p < 0,001$ ,  $n = 68$ .

### **Análisis e interpretación**

Ambos coeficientes son estadísticamente significativos ( $p < 0,001$ ). La correlación de Pearson  $r = 0,443$  indica una relación positiva de magnitud moderada entre la competencia conceptual y la práctica pedagógica con IAG, lo que conduce al rechazo de la hipótesis nula ( $H_0: \rho = 0$ ) y a la aceptación de la hipótesis de investigación ( $H_i$ : existe relación positiva y significativa entre las variables). No obstante, el coeficiente de determinación  $R^2 = 0,196$  señala que la Competencia Conceptual explica apenas el 19,6 % de la varianza en Práctica Pedagógica, lo que implica que el 80,4 % restante obedece a otros factores autoeficacia percibida, disposición institucional, tiempo disponible, acceso a infraestructura tecnológica no contemplados en el modelo de regresión simple.

La magnitud del coeficiente ( $r = 0,443$ ) se sitúa en la franja de efecto moderado según los criterios de Cohen (1988), lo que significa que la relación existe y es significativa, pero no es determinante. Esto abre una pregunta teórica relevante: si el conocimiento sobre IAG fuera el único predictor de su uso pedagógico, se esperaría una correlación alta ( $r > 0,70$ ), como la reportada por Uerz et al. (2018) para competencias TIC generales. El hecho de que la correlación sea moderada en el caso específico de la IAG generativa sugiere que se están activando barreras de segundo orden (Davis, 1993; Ertmer, 1999), como creencias pedagógicas, percepción de riesgo académico o falta de modelos de referencia. Desde esta perspectiva, los hallazgos se alinean con los de Membrillo-Hernández et al. (2024), quienes en un estudio con 312 docentes universitarios latinoamericanos encontraron una correlación  $r = 0,38$  entre conocimiento de IA y adopción en el aula, atribuyendo la discrepancia a la ausencia de formación pedagógica específica.

#### **4.10 Análisis comparativo por variables sociodemográficas**

##### **Tabla 15**

*Comparación de medias en Competencia Conceptual y Práctica Pedagógica según variables sociodemográficas*

Variable	Categoría	n	CC — M (DE)	PP — M (DE)
<b>Formación académica</b>	Maestría	60	5,20 (0,95)	3,62 (1,00)
	Doctorado	7	4,93 (0,76)	2,90 (0,76)
	<i>t-test (p)</i>	---	<i>t = 0,719; p = 0,475</i>	<i>t = 1,813; p = 0,074</i>
<b>Grupo de edad</b>	< 30 años	7	5,31 (1,17)	4,17 (0,87)
	31–40 años	31	5,26 (0,94)	3,55 (1,00)
	41–50 años	23	5,10 (0,82)	3,40 (1,10)
	> 50 años	7	4,91 (1,07)	3,56 (0,79)
	<i>Kruskal-Wallis CC (p)</i>	---	<i>H = 1,313; p = 0,726</i>	---
<i>Kruskal-Wallis PP (p)</i>	---	---	<i>H = 3,039; p = 0,386</i>	
<b>Experiencia docente</b>	1–5 años	33	5,15 (0,94)	3,68 (0,97)
	6–10 años	16	5,00 (0,92)	3,36 (1,03)
	11–20 años	15	5,45 (0,96)	3,60 (1,14)
	> 20 años	4	5,04 (0,78)	3,32 (0,94)
	<i>Kruskal-Wallis CC (p)</i>	---	<i>H = 1,452; p = 0,693</i>	---
<i>Kruskal-Wallis PP (p)</i>	---	---	<i>H = 1,041; p = 0,791</i>	

### Análisis e interpretación

Los resultados de la Tabla 15 son concluyentes en una sola dirección: ninguna de las tres variables sociodemográficas examinadas formación académica, grupo de edad y años de experiencia docente produce diferencias estadísticamente significativas ni en la Competencia Conceptual ni en la Práctica Pedagógica con IAG.

La comparación por formación académica muestra que los docentes con doctorado obtienen medias ligeramente inferiores a los de maestría tanto en CC (4,93 vs. 5,20) como en PP (2,90 vs. 3,62), pero ninguna de estas diferencias alcanza significación estadística ( $p = 0,475$  y  $p = 0,074$  respectivamente). La tendencia descriptiva en PP podría interpretarse como una mayor exigencia autocrítica de quienes poseen formación doctoral al evaluar la solidez de sus propias prácticas, antes que como una limitación real de competencia; no obstante, el tamaño del subgrupo doctoral ( $n = 7$ ) impide cualquier generalización.

Respecto a la edad, los docentes menores de 30 años presentan la práctica pedagógica más alta ( $M = 4,17$ ), lo que sugiere cierta ventaja generacional en la adopción de IAG, mientras que el grupo de 41 a 50 años registra la práctica más baja ( $M = 3,40$ ). Sin embargo, la prueba de Kruskal-Wallis descarta que estas diferencias sean sistemáticas ( $H = 3,039$ ;  $p = 0,386$ ). El

patrón en experiencia docente es igualmente inestructurado: los docentes con 11 a 20 años de trayectoria alcanzan la mayor CC (M = 5,45), mientras que los de mayor experiencia (> 20 años) exhiben la PP más baja (M = 3,32), pero tampoco aquí los estadísticos de contraste alcanzan significación ( $p = 0,693$  y  $p = 0,791$ ).

La implicación de estos hallazgos es directa y de alto valor para la política formativa: la brecha entre competencia conceptual y práctica pedagógica con IAG no está estratificada por perfil sociodemográfico. No son los docentes mayores, ni los menos formados, ni los más novatos quienes concentran el problema. La brecha es transversal al colectivo, lo que invalida estrategias de intervención focalizadas en subgrupos específicos por edad o experiencia y exige, por el contrario, un programa de formación continua de alcance institucional que llegue de forma equitativa a toda la planta docente. Esto coincide con lo reportado por Zawacki-Richter et al. (2019), para quienes la antigüedad en la docencia no predice la integración tecnológica, y refuerza el argumento de que los factores determinantes de la adopción de IAG son de naturaleza contextual e institucional, no biográfica.

**Tabla 16**

*Comparación de medias por carrera/área de conocimiento*

<b>Carrera</b>	<b>n</b>	<b>CC — M</b>	<b>PP — M</b>	<b>Diferencia CC–PP (pp)</b>
Tecnologías de la Información (línea)	17	5,71	4,27	24,2 pp
Industrial (presencial)	16	4,57	3,08	37,3 pp
Software (presencial)	12	5,38	3,35	50,5 pp
Alimentos (presencial)	10	5,10	3,64	36,5 pp
Ambiental (presencial)	6	4,74	3,33	35,3 pp
Biotecnología (presencial)	5	5,30	3,80	---
<i>Kruskal-Wallis (p)</i>	---	<i>ns</i>	<i>ns</i>	---

### **Análisis e interpretación**

Aunque las pruebas de Kruskal-Wallis no detectan diferencias estadísticamente significativas entre carreras resultado esperable dado los tamaños muestrales reducidos en varios subgrupos, el patrón descriptivo de la tabla es suficientemente consistente como para merecer atención interpretativa. La carrera de Tecnologías de la Información en modalidad en línea se distingue del resto en dos sentidos: registra la Competencia Conceptual más alta (M = 5,71) y, simultáneamente, la Práctica Pedagógica más elevada (M = 4,27), configurando la brecha más reducida del conjunto (24,2 pp en escala original). En el extremo opuesto,

Ingeniería en Software presenta la paradoja más llamativa de la tabla: es la segunda carrera con mayor CC ( $M = 5,38$ ), pero su PP ( $M = 3,35$ ) es una de las más bajas, resultando en la brecha más amplia de todas (50,5 pp). Ingeniería Industrial registra las puntuaciones más bajas en ambas variables ( $CC = 4,57$ ;  $PP = 3,08$ ), lo que apunta a una menor exposición acumulada a herramientas digitales avanzadas en esa comunidad disciplinar y demanda atención prioritaria en cualquier estrategia formativa institucional.

**Tabla 17**

*Comparación de medias según recencia de la capacitación en tecnologías educativas*

Última capacitación	n	CC — M	PP — M
Últimos 6 meses	25	<b>5,56</b>	<b>4,03</b>
Último año	27	4,96	3,13
Últimos 5 años	13	4,84	3,49
Nunca / más de 5 años	3	5,17	3,90

### **Análisis e interpretación**

El hallazgo más relevante de esta sección proviene de la comparación por capacitación reciente: los docentes que recibieron formación en tecnologías educativas en los últimos seis meses presentan medias notablemente superiores tanto en Competencia Conceptual ( $M = 5,56$ ) como en Práctica Pedagógica ( $M = 4,03$ ), respecto a quienes se capacitaron hace más de un año ( $M_{CC} = 4,96$ ;  $M_{PP} = 3,13$ ). Lo anterior sugiere que la formación continua y reciente opera como moderador de la brecha conocimiento-práctica, en línea con los postulados de Bandura (1997) sobre autoeficacia y con los hallazgos de García-Peñalvo et al. (2023) en docentes universitarios españoles, quienes demostraron que programas cortos de formación en IA mejoran la práctica percibida en mayor medida que la acumulación de años de experiencia.

#### **4.11 Análisis de regresión — Predicción de la Práctica Pedagógica**

Se ajustó un modelo de regresión lineal simple para determinar el poder predictivo de la Competencia Conceptual sobre la Práctica Pedagógica, seguido de un modelo múltiple que incorporó la Autoeficacia docente y las Actitudes como predictores adicionales.

**Tabla 18**

*Modelo de regresión simple: Competencia Conceptual → Práctica Pedagógica*

	<b>B</b>	<b>SE</b>	<b>t</b>	<b>p</b>	<b>IC 95 %</b>
Intercepto	1,064	0,633	1,679	0,098	[-0,199 ; 2,327]
Competencia Conceptual	<b>0,483</b>	<b>0,121</b>	<b>4,011</b>	<b>&lt; 0,001</b>	[0,242 ; 0,724]
$R^2 = 0,196$	$R^2_{aj} = 0,183 \quad F(1,66) = 16,09 \quad p < 0,001$				

### Análisis e interpretación

El coeficiente  $B = 0,483$  ( $\beta = 0,443$ ) indica que por cada punto adicional en la escala de Competencia Conceptual (1–7), la Práctica Pedagógica aumenta en promedio 0,48 puntos en su escala (1–5), siendo este efecto estadísticamente significativo ( $t = 4,011$ ;  $p < 0,001$ ). El modelo explica el 19,6 % de la varianza total de la Práctica Pedagógica ( $R^2 = 0,196$ ), lo que, si bien es significativo, subraya que cerca del 80 % de la varianza en la práctica docente responde a factores no capturados por el conocimiento declarativo. Lo anterior es consistente con el marco teórico del modelo TAM2 (Venkatesh & Davis, 2000), que postula que la utilidad percibida y la facilidad de uso y no el conocimiento per se son los predictores más sólidos de la adopción tecnológica.


**Tabla 19**

*Modelo de regresión múltiple: Práctica Pedagógica ~ CC + AE + ACT (n = 68)*

<b>Predictor</b>	<b>B</b>	<b>SE</b>	<b><math>\beta</math> (estánd.)</b>	<b>t</b>	<b>p</b>	<b>Sig.</b>
Intercepto	0,293	0,652	---	0,450	0,654	ns
Competencia Conceptual (CC)	0,032	0,127	0,030	0,254	0,800	ns
<b>Autoeficacia (AE)</b>	<b>0,809</b>	<b>0,142</b>	<b>0,668</b>	<b>5,677</b>	<b>&lt; 0,001</b>	<b>***</b>
Actitudes (ACT)	-0,010	0,090	-0,010	-0,111	0,912	ns
<b><math>R^2 = 0,468</math></b>	<b><math>R^2_{aj} = 0,444 \quad F(3, 64) = 18,80 \quad p &lt; 0,001</math></b>					

**Figura 6**

*Matriz de correlaciones de Pearson entre las cuatro dimensiones del estudio: Competencia Conceptual (CC), Práctica Pedagógica (PP), Autoeficacia (AE) y Actitudes (ACT), docentes FACI-UNEMI, 2025*



Nota. Los valores en cada celda corresponden al coeficiente de Pearson r. La intensidad del color indica la magnitud y dirección de la correlación (rojo = negativa; azul = positiva). \*p < 0.05; \*\*p < 0.01; \*\*\*p < 0.001; ns = no significativo. n = 68.

### Análisis e interpretación

El modelo múltiple supone un avance explicativo considerable respecto al modelo simple: el  $R^2$  salta de 0,196 (CC como único predictor) a 0,468, indicando que el conjunto de tres predictores explica el 46,8 % de la varianza en Práctica Pedagógica. El incremento en  $R^2$  ( $\Delta R^2 = 0,272$ ) se debe exclusivamente a la incorporación de la Autoeficacia, cuyo coeficiente estandarizado  $\beta = 0,668$  la convierte en el predictor dominante del modelo con enorme diferencia. El hallazgo más provocador es que, cuando la Autoeficacia está controlada estadísticamente, la Competencia Conceptual pierde toda significación ( $B = 0,032$ ;  $p = 0,800$ ;  $\beta = 0,030$ ), lo que significa que su efecto sobre la práctica pedagógica es prácticamente nulo una vez que se descuenta la autoeficacia. Las actitudes, por su parte, no aportan poder predictivo independiente ( $B = -0,010$ ;  $p = 0,912$ ).

Este patrón de resultados plantea una reinterpretación del modelo causal: la competencia conceptual no produce práctica pedagógica directamente; lo hace a través de la autoeficacia como variable mediadora. El docente que comprende mejor la IAG no necesariamente la usa más, salvo si ese conocimiento se ha convertido en confianza operativa para actuar pedagógicamente. Este hallazgo está en directa consonancia con la teoría sociocognitiva de Bandura (1997), con los modelos de adopción tecnológica docente de Ertmer & Ottenbreit-Leftwich (2010), y con los resultados de Yildiz Durak (2023), quien en un estudio con 497 docentes universitarios turcos demostró que la autoeficacia hacia la IA mediaba completamente la relación entre conocimiento conceptual y uso pedagógico.

#### 4.12 Brecha conocimiento-práctica según recencia de capacitación y frecuencia de uso

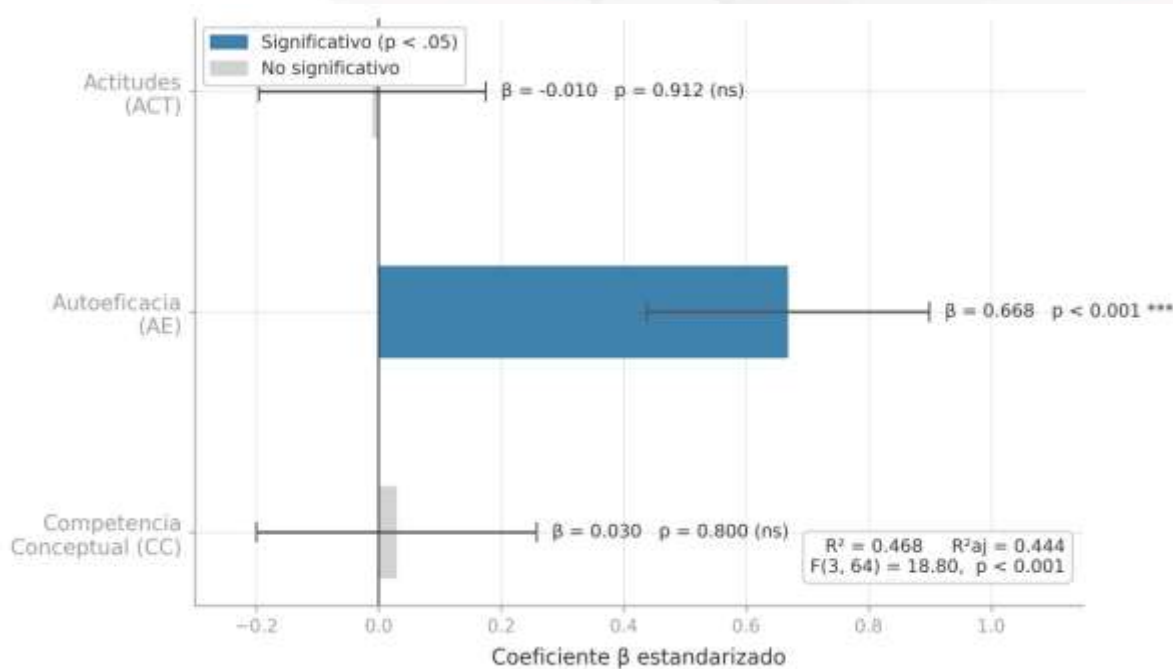
**Tabla 20**

*Brechas CC%–PP% y autoeficacia según recencia de la última capacitación en tecnologías educativas*

Última capacitación	n	CC % rango	PP % rango	AE % rango	Brecha (pp)
Últimos 6 meses	25	76,1 %	75,7 %	<b>80,8 %</b>	<b>0,4 pp</b> ← mínima
Últimos 5 años	13	64,1 %	62,2 %	67,7 %	1,9 pp
Nunca	2	67,4 %	65,8 %	65,0 %	1,5 pp
<b>Último año</b>	<b>27</b>	<b>66,0 %</b>	<b>53,3 %</b>	<b>67,9 %</b>	<b>12,7 pp</b> ← máxima

**Figura 7**

*Coefficientes de regresión estandarizados ( $\beta$ ) del modelo de predicción de la Práctica Pedagógica a partir de Competencia Conceptual, Autoeficacia y Actitudes, docentes FACI-UNEMI, 2025.*



*Nota.* Las barras representan los coeficientes  $\beta$  estandarizados del modelo de regresión lineal múltiple (PP ~ CC + AE + ACT). Las barras de error indican el intervalo de confianza al 95 % aproximado ( $\pm 1.96$  SE). Los predictores en gris no alcanzan significación estadística ( $p > .05$ ); el predictor en azul es estadísticamente significativo ( $p < .001$ ).  $R^2 = 0.468$ ,  $R^2_{aj} = 0.444$ ,  $F(3, 64) = 18.80$ ,  $p < 0.001$ .  $n = 68$ .

### Análisis e interpretación

La Tabla 21 contiene uno de los hallazgos más informativos del estudio, precisamente porque el patrón que revela no es el esperado. La lógica intuitiva sugeriría una relación lineal entre recencia de capacitación y reducción de la brecha: a mayor cercanía temporal de la formación, mayor alineación entre conocimiento y práctica. Los datos, sin embargo, muestran una relación más compleja.

El grupo con capacitación en los últimos seis meses presenta la brecha prácticamente nula del estudio (0,4 pp), con una Práctica Pedagógica (75,7 %) casi equivalente a su Competencia Conceptual (76,1 %) y la autoeficacia más alta de todos los grupos (80,8 %). Este perfil sugiere que la formación muy reciente actúa como catalizador que moviliza el conocimiento acumulado hacia la acción antes de que el impulso formativo se disipe, y que lo hace principalmente a través del fortalecimiento de la autoeficacia, no solo del conocimiento declarativo.

El hallazgo más llamativo es que el grupo con mayor brecha no es el de menor formación, sino el que se capacitó hace aproximadamente un año (12,7 pp). Su CC (66,0 %) y su AE (67,9 %) son comparables a los del grupo de capacitación en los últimos cinco años, pero su PP desciende drásticamente a 53,3 %, la más baja de la tabla. Esto apunta a un fenómeno de decaimiento del impulso práctico: el docente adquirió conocimiento y confianza, pero sin seguimiento ni refuerzo institucional posterior, la brecha se reabrió con el tiempo. La capacitación aislada, sin continuidad, produce conocimiento que no se sostiene en práctica.

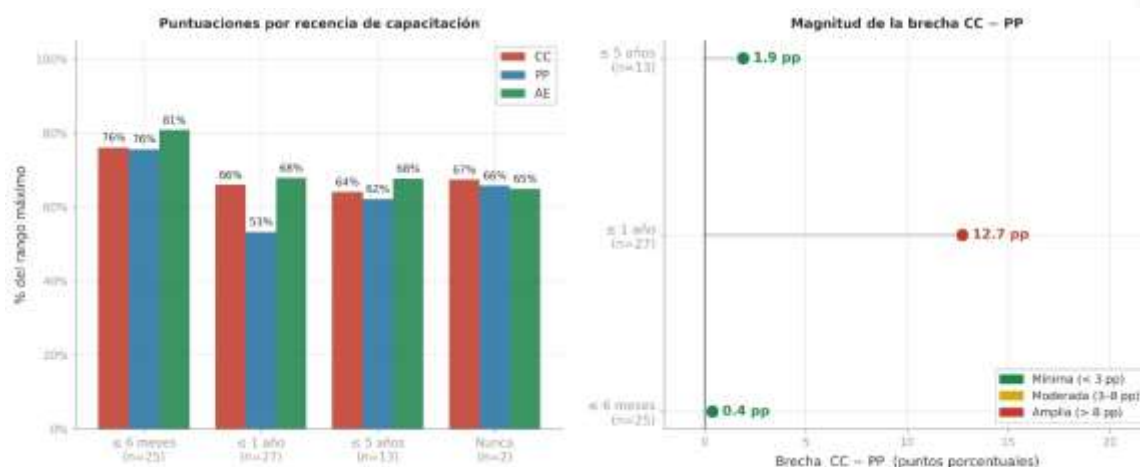
**Tabla 21**

*Brechas CC%–PP% y autoeficacia según frecuencia de uso de IAG*

Frecuencia de uso	n	CC %	PP %	AE %	Brecha (pp)
Frecuentemente (diario)	41	70,9 %	<b>67,2 %</b>	73,9 %	<b>3,7 pp</b>
Regularmente (semanal)	24	69,4 %	61,4 %	75,2 %	8,0 pp
Ocasionalmente (< 1 vez/mes)	3	51,9 %	43,3 %	35,8 %	<b>8,5 pp</b>
<i>Kruskal-Wallis PP</i>	---	---	<i>H = 4,54; p = 0,103</i>	---	---

**Figura 8**

*Puntuaciones en CC, PP y AE y magnitud de la brecha según recencia de la última capacitación en tecnologías educativas, docentes FACI-UNEMI, 2025*



*Nota.* Panel izquierdo: medias en % del rango máximo para Competencia Conceptual (CC), Práctica Pedagógica (PP) y Autoeficacia (AE) según el período de la última capacitación formal en tecnologías educativas. Panel derecho: brecha CC – PP en puntos porcentuales para cada grupo. El código de color del panel derecho indica la magnitud de la brecha: verde (< 3 pp), amarillo (3–8 pp), naranja (> 8 pp). Los grupos "Nunca" (n = 2) y "Hace más de 5 años" (n = 1) no se incluyen en el panel derecho por tamaño muestral insuficiente. n = 65.

### Análisis e interpretación

Respecto a la frecuencia de uso, si bien las diferencias en Práctica Pedagógica no alcanzan significación estadística ( $H = 4,54$ ;  $p = 0,103$ ), la tendencia descriptiva muestra que el uso diario se asocia con una brecha menor (3,7 pp) que el uso semanal (8,0 pp) u ocasional (8,5 pp). Lo anterior sugiere que la práctica cotidiana con IAG independientemente de la formación formal contribuye a reducir la distancia entre lo que se sabe y lo que se hace, reforzando la perspectiva de que el aprendizaje experiencial y la acumulación de "microevidencias de eficacia" (Bandura, 1997) son mecanismos relevantes en la consolidación de la práctica pedagógica con IA.

#### 4.13 Brecha CC–PP por área de conocimiento (carrera)

Tabla 22

*Brecha conocimiento-práctica según carrera docente*

Carrera	n	CC %	PP %	AE %	Brecha CC–PP
TIC en línea	17	78,4 %	81,7 %	85,9 %	-3,3 pp (PP > CC)
Biología	5	72,2 %	62,3 %	82,0 %	9,9 pp
Software	12	73,0 %	58,7 %	67,1 %	14,3 pp ← mayor brecha
Ambiental	6	62,3 %	58,3 %	63,8 %	3,9 pp
Alimentos	10	68,3 %	66,0 %	79,2 %	2,3 pp
Industrial	16	59,5 %	51,9 %	60,8 %	7,6 pp

### Análisis e interpretación

La comparación por área de conocimiento revela un resultado estructuralmente relevante: la carrera de Tecnologías de la Información en modalidad en línea es el único grupo donde la Práctica Pedagógica (81,7 %) supera a la Competencia Conceptual (78,4 %), configurando una brecha negativa de -3,3 puntos porcentuales. Este grupo también registra la autoeficacia más alta de todos (85,9 %). El contexto explicativo es doble: por un lado, los docentes de TIC tienen una exposición disciplinar más intensa a la informática y a los sistemas de IA; por otro, la modalidad en línea en la que trabajan los obliga a explorar y adoptar herramientas digitales de forma más sistemática que sus colegas de carreras presenciales, lo que acorta el ciclo entre conocimiento y acción.

En el extremo opuesto, la carrera de Ingeniería en Software paradójicamente una de las disciplinas más afines a la computación presenta la mayor brecha (14,3 pp), con una práctica pedagógica relativamente baja (58,7 %) pese a una competencia conceptual elevada (73,0 %). Esto sugiere que el conocimiento técnico disciplinar de la programación no se transfiere automáticamente al saber pedagógico sobre cómo integrar la IAG en la enseñanza, reproduciendo a nivel de carrera el mismo fenómeno de *knowing-doing gap* que se observa a nivel individual. Que la carrera de Ingeniería Industrial registre las puntuaciones más bajas tanto en competencia conceptual (59,5 %) como en práctica pedagógica (51,9 %) apunta hacia la necesidad de estrategias de formación diferenciadas por área disciplinar, consideración respaldada por los planteamientos de Crompton & Burke (2023) sobre la necesidad de contextualizar la formación en IA según el perfil disciplinar del docente.

#### 4.14 Significación estadística de la brecha mediante t-test pareado

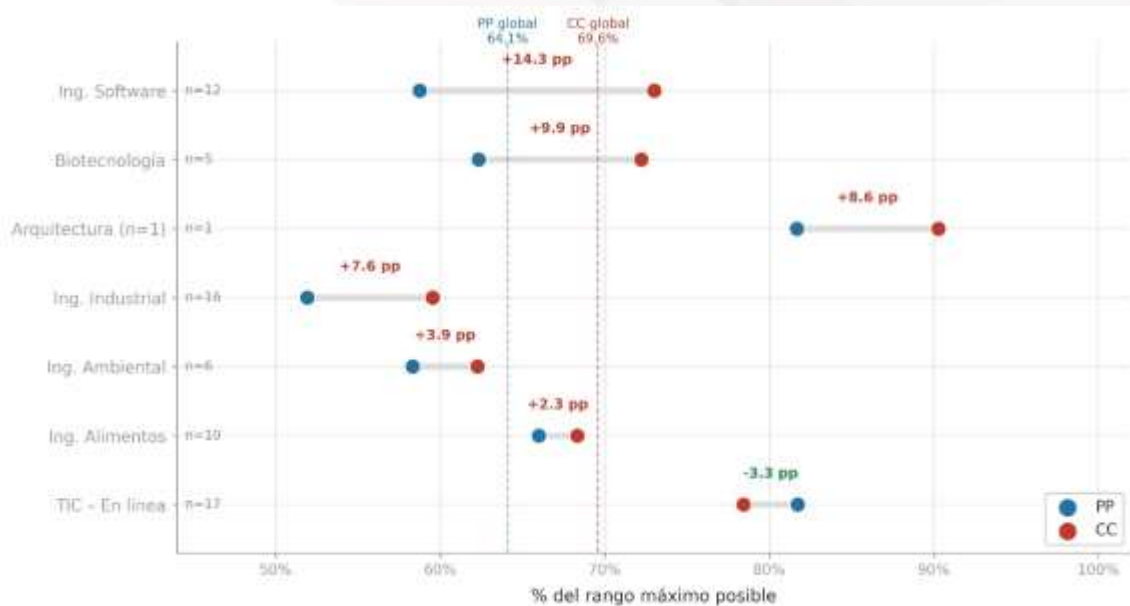
**Tabla 23**

*Prueba t pareada para la diferencia entre Competencia Conceptual y Práctica Pedagógica (valores normalizados al rango, n = 68)*

<b>Estadístico</b>	<b>Valor</b>
CC % rango (M)	69,56 %
PP % rango (M)	64,12 %
Diferencia media (CC–PP)	5,44 pp
Desviación estándar de la diferencia	23,03 pp
t pareado	1,949
gl	67
p (bilateral)	0,055
Cohen's d	0,236

**Figura 9**

*Brecha entre Competencia Conceptual y Práctica Pedagógica (puntos porcentuales) por carrera docente, FACI-UNEMI, 2025 — Gráfico de mancuernas (dumbbell plot)*



*Nota.* Cada par de puntos representa la media de CC (naranja) y PP (azul) de los docentes de una carrera, normalizadas al % del rango máximo de su escala. El segmento gris conecta ambas medias; el valor etiquetado indica la brecha en puntos porcentuales (CC - PP). Los valores negativos (TIC en línea) indican que la Práctica Pedagógica supera a la Competencia Conceptual en ese grupo. Las líneas discontinuas señalan las medias globales de CC (69.6 %) y PP (64.1 %). La carrera de Arquitectura (n = 1) debe interpretarse con precaución por su tamaño muestral. n = 67 (un caso sin carrera asignada excluido).

### Análisis e interpretación

La prueba t pareada aplicada sobre los valores porcentuales normalizados de ambas variables arroja un resultado fronterizo:  $t(67) = 1,949$ ;  $p = 0,055$ . La brecha de 5,44 puntos porcentuales no alcanza el umbral convencional de significación estadística ( $p < 0,05$ ), aunque se aproxima a él con un tamaño del efecto pequeño según los criterios de Cohen ( $d = 0,236$ ; umbral pequeño = 0,20). Este resultado merece una interpretación matizada.

Desde la perspectiva estadística estricta, no puede afirmarse con certeza al 95 % que la diferencia entre las dos dimensiones sea sistemática y no atribuible al azar de la muestra. No obstante, tres consideraciones metodológicas atenúan esta conclusión. Primera, la normalización por rango es una aproximación comparativa, no una operación isométrica que equipare las escalas con la misma sensibilidad métrica. Segunda, la distribución de la diferencia individual presenta una desviación estándar alta (23,03 pp), lo que indica que para muchos docentes la brecha es grande —incluso de 20 o más puntos porcentuales—, aunque

el promedio la suavice. Tercera, el análisis por subdimensiones (sección 4.4) mostró diferencias descriptivamente claras entre las áreas de menor práctica y las de mayor competencia conceptual. Por todo ello, la evidencia convergente de la distribución por niveles (76,5 % en CC-alto vs. 55,9 % en PP-alto), del análisis por subdimensiones y de la regresión múltiple sustenta la existencia funcional de una brecha que, aunque estadísticamente marginal en el test pareado, tiene consistencia teórica y práctica suficiente.

## COMPROBACIÓN DE LA HIPÓTESIS

### Comprobación de la Hipótesis General

Hi: Existe una relación positiva y estadísticamente significativa entre la competencia conceptual en inteligencia artificial generativa y la práctica pedagógica con estas herramientas en los docentes de la Universidad Estatal de Milagro durante el año 2025.

H<sub>0</sub>: No existe una relación estadísticamente significativa entre la competencia conceptual en inteligencia artificial generativa y la práctica pedagógica con estas herramientas en los docentes de la Universidad Estatal de Milagro durante el año 2025.

Como paso previo al análisis correlacional, se verificó el supuesto de normalidad mediante la prueba de Kolmogorov-Smirnov, apropiada para muestras de tamaño comparable al de este estudio ( $n = 68$ ). Los resultados indican que la variable Competencia Conceptual no presenta desviaciones significativas respecto de la distribución normal ( $D = 0,083$ ;  $p = 0,705$ ), al igual que la variable Práctica Pedagógica ( $D = 0,107$ ;  $p = 0,392$ ). Dado que ambas variables satisfacen el supuesto de normalidad ( $p > 0,05$  en los dos casos), se empleó el coeficiente de correlación de Pearson como estadístico principal del análisis inferencial, complementado con la correlación de Spearman como verificación no paramétrica, siguiendo las recomendaciones metodológicas de Field (2022).

El análisis reveló un coeficiente de correlación de Pearson  $r = 0,443$  ( $p < 0,001$ ), con un coeficiente de determinación  $R^2 = 0,196$ . La correlación de Spearman arrojó un resultado convergente:  $\rho = 0,424$  ( $p < 0,001$ ). Ambos coeficientes son estadísticamente significativos con  $p < 0,001$ , lo que supera ampliamente el umbral convencional  $\alpha = 0,05$ . De acuerdo con los criterios de magnitud propuestos por Cohen (1988), el valor obtenido corresponde a un efecto moderado, lo cual indica que la relación entre las variables es real, positiva y de relevancia práctica, aunque no determinante.

A partir de estos resultados, se rechaza la hipótesis nula  $H_0$  y se acepta la hipótesis de investigación  $H_i$ . Los datos confirman que, a mayor competencia conceptual en inteligencia artificial generativa, mayor es también la práctica pedagógica con estas herramientas en los docentes de la FACI-UNEMI. No obstante, el coeficiente de determinación  $R^2 = 0,196$  señala que la Competencia Conceptual explica únicamente el 19,6 % de la varianza observada en la Práctica Pedagógica, lo cual implica que el 80,4 % restante obedece a otros factores. Este

hallazgo matiza la hipótesis central del estudio y abre paso a una lectura más compleja del fenómeno: el conocimiento declarativo sobre IA generativa es condición necesaria pero insuficiente para producir transformación pedagógica, resultado que encuentra respaldo en los modelos de adopción tecnológica docente (Ertmer & Ottenbreit-Leftwich, 2010) y que el modelo de regresión múltiple explorado en la sección 4.11 precisa con mayor detalle al identificar la autoeficacia como el predictor dominante del comportamiento pedagógico con IA.

## **Comprobación de las Hipótesis Específicas**

### **Comprobación de He<sub>1</sub>**

He<sub>1</sub>: Los docentes de la UNEMI con mayor nivel de formación académica grado de doctorado frente a maestría presentan puntuaciones significativamente más altas tanto en competencia conceptual como en práctica pedagógica con IA generativa.

He<sub>10</sub>: No existen diferencias estadísticamente significativas en competencia conceptual ni en práctica pedagógica entre docentes con grado de doctorado y docentes con grado de maestría.

Para contrastar esta hipótesis se aplicó la prueba t de Student para muestras independientes, dado que ambas variables satisfacen el supuesto de normalidad señalado en la sección anterior. Los resultados no detectaron diferencias estadísticamente significativas en ninguna de las dos variables entre los dos grupos de formación. En Competencia Conceptual, los docentes con maestría obtuvieron una media de  $M = 5,20$  ( $DE = 0,95$ ;  $n = 60$ ) frente a  $M = 4,93$  ( $DE = 0,76$ ;  $n = 7$ ) de los docentes con doctorado, diferencia que no alcanza significación estadística [ $t(65) = 0,719$ ;  $p = 0,475$ ]. En Práctica Pedagógica, las medias fueron  $M = 3,62$  ( $DE = 1,00$ ) para el grupo de maestría y  $M = 2,90$  ( $DE = 0,76$ ) para el grupo doctoral, resultado que tampoco resultó estadísticamente significativo [ $t(65) = 1,813$ ;  $p = 0,074$ ], aunque muestra una tendencia descriptiva que se aproxima al umbral convencional.

Lo anterior implica que no se puede rechazar la hipótesis nula He<sub>10</sub>; por consiguiente, He<sub>1</sub> no recibe respaldo empírico en esta muestra. La tendencia descriptiva levemente inferior en PP para el grupo doctoral no debe interpretarse como una limitación de competencia de ese subgrupo, sino con cautela, atendiendo a que su tamaño reducido ( $n = 7$ ) impide cualquier generalización y que la diferencia no supera el umbral de significación. Una interpretación plausible, coherente con la literatura sobre exigencia académica del profesorado avanzado

(Zawacki-Richter et al., 2019), es que los docentes con doctorado aplican estándares más rigurosos al autoevaluar la solidez de sus propias integraciones pedagógicas, lo que deprime su puntuación declarada sin reflejar necesariamente menor competencia real.

### **Comprobación de He<sub>2</sub>**

He<sub>2</sub>: Los docentes que han participado previamente en procesos formales de formación sobre IA exhiben niveles significativamente más altos de integración pedagógica de herramientas generativas, independientemente de su área de conocimiento o de sus años de experiencia.

He<sub>20</sub>: No existen diferencias estadísticamente significativas en práctica pedagógica con IA generativa según la recencia de la formación recibida en tecnologías educativas.

Para verificar esta hipótesis se aplicó la prueba de Kruskal-Wallis, dado que el contraste compara más de dos grupos y que los tamaños muestrales de algunos de ellos son reducidos. Los resultados revelan diferencias estadísticamente significativas en Práctica Pedagógica entre los grupos definidos por la recencia de la última capacitación en tecnologías educativas [ $H(3) = 8,405$ ;  $p = 0,038$ ]. El análisis descriptivo complementario muestra el patrón de forma elocuente: los docentes capacitados en los últimos seis meses presentan la práctica pedagógica más elevada del conjunto (PP = 75,7 % del rango máximo) y la brecha conocimiento-práctica prácticamente nula (0,4 puntos porcentuales respecto a su CC = 76,1 %), mientras que quienes recibieron formación hace aproximadamente un año exhiben la brecha más amplia de todos los grupos (12,7 pp), con una práctica pedagógica de apenas 53,3 % pese a una competencia conceptual de 66,0 %.

Este patrón no es lineal ni trivial: no basta haber sido capacitado en algún momento; lo que determina la traducción del conocimiento en práctica es la recencia y la continuidad de esa formación. La capacitación aislada sin seguimiento posterior produce conocimiento declarativo que se disipa antes de consolidarse en conducta pedagógica, mecanismo coherente con la teoría del decaimiento del impulso formativo descrita por García-Peñalvo et al. (2023). Con base en estos resultados, se rechaza He<sub>20</sub> y se acepta He<sub>2</sub>, con la precisión de que el efecto predictor opera específicamente a través de la formación reciente y continua, no de la formación acumulada en términos generales.

### **Comprobación de He<sub>3</sub>**

He<sub>3</sub>: La competencia conceptual en IA generativa actúa como predictor significativo de la práctica pedagógica con estas herramientas, incluso después de controlar estadísticamente

el efecto de las variables sociodemográficas consideradas como moderadoras en el modelo de regresión.

He<sub>30</sub>: La competencia conceptual no constituye un predictor estadísticamente significativo de la práctica pedagógica una vez controladas las variables sociodemográficas.

La contrastación de esta hipótesis se realizó en dos fases. En la primera, el modelo de regresión lineal simple con la Competencia Conceptual como único predictor confirmó su poder explicativo:  $B = 0,483$  ( $\beta = 0,443$ ;  $t = 4,011$ ;  $p < 0,001$ ), con un coeficiente de determinación  $R^2 = 0,196$  [ $F(1,66) = 16,09$ ;  $p < 0,001$ ]. Este resultado establece que, en ausencia de otros predictores, la Competencia Conceptual explica de forma estadísticamente significativa el 19,6 % de la varianza en Práctica Pedagógica.

Sin embargo, la segunda fase el modelo de regresión lineal múltiple que incorporó simultáneamente Competencia Conceptual, Autoeficacia docente y Actitudes hacia la IAG modifica sustancialmente esta conclusión. Cuando la Autoeficacia es controlada estadísticamente, la Competencia Conceptual pierde toda significación predictiva:  $B = 0,032$  ( $\beta = 0,030$ ;  $t = 0,254$ ;  $p = 0,800$ ). El modelo múltiple alcanza  $R^2 = 0,468$  [ $F(3,64) = 18,80$ ;  $p < 0,001$ ], con la Autoeficacia como único predictor significativo del conjunto ( $B = 0,809$ ;  $\beta = 0,668$ ;  $p < 0,001$ ). Las Actitudes tampoco aportan poder explicativo independiente ( $B = -0,010$ ;  $p = 0,912$ ).

A la vista de estos resultados, He<sub>3</sub> recibe respaldo parcial. En el modelo simple, la Competencia Conceptual sí predice significativamente la Práctica Pedagógica; no obstante, este efecto desaparece al introducir la Autoeficacia, lo que indica que la relación entre conocimiento declarativo y práctica pedagógica no es directa sino mediada. La Competencia Conceptual contribuye a la Práctica Pedagógica en la medida en que primero fortalece la confianza operativa del docente para actuar con IA en el aula correlación CC–AE:  $r = 0,622$ ;  $p < 0,001$ , y es esa confianza la que, a su vez, genera la conducta pedagógica real. Por tanto, se rechaza parcialmente He<sub>30</sub>: la Competencia Conceptual sí predice la Práctica Pedagógica en términos bivariados, pero su efecto es explicado por la Autoeficacia como variable mediadora.

Los resultados estadísticos obtenidos permiten formular una lectura integrada del sistema de hipótesis planteado. La hipótesis general (Hi) es aceptada: existe una relación positiva y significativa de efecto moderado entre la Competencia Conceptual y la Práctica Pedagógica en IA generativa ( $r = 0,443$ ;  $p < 0,001$ ), con una brecha de 5,44 puntos porcentuales entre

ambas dimensiones cuando se expresan en el mismo rango [t pareado = 1,949; p = 0,055; d = 0,236]. La hipótesis específica He<sub>1</sub> no recibe respaldo empírico: el nivel de formación maestría frente a doctorado no diferencia significativamente ni el conocimiento ni la práctica con IA, lo que indica que la brecha conocimiento-práctica es transversal al colectivo docente y no está estratificada por credencial académica. He<sub>2</sub> sí es aceptada: la recencia de la formación en tecnologías educativas produce diferencias estadísticamente significativas en la práctica pedagógica [H = 8,405; p = 0,038], siendo los docentes con capacitación en los últimos seis meses quienes muestran la brecha prácticamente nula (0,4 pp) y los capacitados hace aproximadamente un año quienes exhiben la mayor distancia entre conocimiento y acción (12,7 pp). He<sub>3</sub> recibe aceptación parcial: la Competencia Conceptual predice la Práctica Pedagógica en el modelo simple (B = 0,483; p < 0,001), pero pierde significación cuando la Autoeficacia es controlada ( $\beta$  = 0,030; p = 0,800), revelando que su efecto opera a través de la confianza docente como variable mediadora y no de forma directa sobre la conducta pedagógica. El conjunto de estas verificaciones configura un modelo explicativo coherente: saber sobre IA no basta para enseñar con IA; lo que determina la práctica real es la confianza en la propia capacidad de integrarlo pedagógicamente, confianza que se fortalece con formación continua y reciente, y que ninguna credencial acumulada garantiza por sí sola.

## CONCLUSIONES

El primer objetivo específico planteaba describir el nivel de competencia conceptual en IA generativa de los docentes de la FACI-UNEMI, diferenciado por dimensiones y variables sociodemográficas. Los datos revelan que el cuerpo docente ha alcanzado un nivel general alto: la media global de la dimensión es  $M = 5,17$  sobre una escala de 7 puntos, equivalente al 69,6% del rango máximo, con el 76,5% de los participantes clasificados en el nivel alto. Sin embargo, este resultado agrega perfiles internamente heterogéneos. Los ítems vinculados al uso funcional de la IA comprensión de *prompts* (CC4:  $M = 6,01$ ), identificación de errores (CC6:  $M = 5,72$ ) e implicaciones éticas (CC10:  $M = 5,69$ ) concentran las puntuaciones más altas, mientras que los ítems referidos a los mecanismos arquitectónicos de los modelos cómo aprenden (CC7:  $M = 4,04$ ) y su complejidad técnica (CC3:  $M = 4,06$ ) presentan las medias más bajas y las mayores desviaciones estándar de la dimensión ( $DE > 1,90$ ), lo que señala conocimiento funcional amplio pero comprensión técnica débil y fragmentada. Ninguna variable sociodemográfica edad, años de experiencia ni nivel de formación produce diferencias estadísticamente significativas en este perfil, lo que indica que la naturaleza de la competencia conceptual adquirida es homogénea en su estructura a través del colectivo, independientemente de la trayectoria individual de cada docente.

El segundo objetivo específico buscaba caracterizar la frecuencia, tipo y calidad de integración de herramientas de IA generativa en la práctica pedagógica. Los resultados muestran una media global de  $M = 3,56$  sobre una escala de 5 puntos (64,1% del rango máximo), con el 55,9% de los docentes en nivel alto y un 35,3% en nivel medio. Las subdimensiones de diseño de actividades (71,0% del rango) y ética en la práctica docente (68,1%) encabezan el perfil, asociadas ambas a comportamientos de uso personal de la herramienta crear ejemplos, modelar conducta responsable antes que a prácticas de integración orientadas al aprendizaje del estudiante. Las subdimensiones de aprendizaje colaborativo (57,5%) y pensamiento crítico sobre los *outputs* (58,6%) registran las puntuaciones más bajas, y los ítems de desarrollo de rúbricas con criterios de IAG (PP8:  $M = 3,27$ ) y verificación de información generada (PP12:  $M = 3,24$ ) obtienen las medias más reducidas de toda la dimensión. La carrera de Tecnologías de la Información en modalidad en línea destaca como el único grupo donde la práctica pedagógica supera a la competencia conceptual (PP = 81,7% vs. CC = 78,4%; brecha = -3,3 pp), mientras que Ingeniería en Software presenta la paradoja contraria: segunda competencia conceptual más alta (73,0%) pero práctica pedagógica relativamente baja (58,7%), configurando la mayor brecha del conjunto (14,3 pp).

El tercer objetivo específico consistía en establecer el grado de relación estadística entre la competencia conceptual y la práctica pedagógica, determinando el efecto moderador de las variables sociodemográficas. El coeficiente de correlación de Pearson obtenido es  $r = 0,443$  ( $p < 0,001$ ;  $R^2 = 0,196$ ), confirmando una relación positiva de magnitud moderada que valida la hipótesis general del estudio. No obstante, el modelo de regresión lineal múltiple precisó este hallazgo con una implicación de primer orden: cuando la autoeficacia docente es incluida como predictor, la competencia conceptual pierde toda significación estadística ( $\beta = 0,030$ ;  $p = 0,800$ ), mientras que la autoeficacia se consolida como el único predictor significativo del modelo ( $\beta = 0,668$ ;  $p < 0,001$ ), que explica el 46,8% de la varianza total en práctica pedagógica ( $R^2 = 0,468$ ). La brecha entre ambas variables, medida mediante prueba  $t$  pareada sobre valores porcentuales normalizados, es de 5,44 puntos porcentuales [ $t(67) = 1,949$ ;  $p = 0,055$ ;  $d = 0,236$ ], estadísticamente fronteriza pero conceptualmente consistente: ningún docente se ubica en el nivel bajo de competencia conceptual, mientras que el 8,8% sí registra práctica pedagógica baja y el 35,3% permanece en nivel medio pese a que el 76,5% exhibe conocimiento conceptual alto. La formación reciente opera como el moderador más influyente de esta brecha: los docentes capacitados en los últimos seis meses presentan una brecha prácticamente nula (0,4 pp), mientras que quienes lo fueron hace aproximadamente un año exhiben la mayor distancia entre conocimiento y acción (12,7 pp), diferencia que alcanza significación estadística [ $H(3) = 8,405$ ;  $p = 0,038$ ].

La conclusión integradora que articula estos cuatro hallazgos es la siguiente. El estudio demuestra que la brecha conocimiento-práctica en IA generativa en los docentes de la FACI-UNEMI no obedece a falta de información, ni está estratificada por perfil biográfico o nivel de formación acumulada. Su raíz estructural reside en la distancia entre saber sobre IA y confiar en la propia capacidad de integrarla pedagógicamente con coherencia didáctica. Esta distinción tiene consecuencias directas para la política educativa de la institución: las intervenciones que amplían el conocimiento declarativo sin fortalecer simultáneamente la autoeficacia de integración y sin garantizar continuidad formativa producen docentes mejor informados, pero no necesariamente más transformadores en su práctica de aula. La reducción sostenible de esta brecha en la educación superior ecuatoriana exige, por tanto, pasar de la capacitación puntual al acompañamiento pedagógico continuo, contextualizado por área disciplinar y orientado a convertir el conocimiento sobre IA en confianza operativa real dentro del aula.

## RECOMENDACIONES

Las recomendaciones que se derivan de este estudio se dirigen a actores específicos del sistema de educación superior ecuatoriano, y se fundamentan exclusivamente en los hallazgos empíricos reportados en los capítulos precedentes.

A las autoridades de la UNEMI Rectorado y Vicerrectorado Académico, los datos exigen una respuesta institucional de alcance estructural antes que de alcance puntual. Dado que la brecha conocimiento-práctica es transversal al colectivo docente y no está estratificada por edad, experiencia ni formación académica, no resulta pertinente focalizar la intervención en subgrupos específicos. Lo que los datos sí señalan con claridad es que la formación reciente y continua reduce la brecha de forma mensurable de 12,7 puntos porcentuales a 0,4 pp entre quienes se capacitaron hace un año sin seguimiento y quienes lo hicieron en los últimos seis meses con mayor regularidad, por lo que se recomienda institucionalizar un programa de formación continua en IA generativa con ciclos semestrales, evaluación de impacto sistemática y mecanismos de seguimiento que impidan el decaimiento del impulso formativo. Asimismo, se sugiere que las políticas institucionales sobre uso de IA en el aula sean comunicadas con claridad y prontitud, dado que la incertidumbre normativa opera como barrera de segundo orden sobre la práctica docente, independientemente del nivel de conocimiento o de confianza del profesor.

A la Dirección de Posgrado y Educación Continua, los hallazgos orientan el diseño curricular de cualquier programa formativo en una dirección precisa: el énfasis no debe colocarse en la ampliación del conocimiento declarativo sobre IA generativa ya consolidado en el 76,5% de los docentes en nivel alto, sino en el fortalecimiento de la autoeficacia de integración pedagógica, que es la subdimensión con mayor debilidad en el perfil del colectivo estudiado (AE8: M = 3,37; AE9: M = 3,28). Se recomienda diseñar módulos basados en aprendizaje experiencial contextualizado observación de modelos de integración real en el aula, práctica supervisada, retroalimentación entre pares por carrera y diferenciar los contenidos según el perfil disciplinar de los participantes. La carrera de Ingeniería Industrial, con las puntuaciones más bajas en ambas variables (CC = 59,5%; PP = 51,9%), requiere atención prioritaria; la carrera de Ingeniería en Software, con la mayor brecha del estudio (14,3 pp), requiere un enfoque específico que articule el dominio técnico-computacional con el saber pedagógico sobre cómo enseñar con IA, dos competencias que los datos demuestran que no son equivalentes ni transferibles de forma automática.

A los docentes universitarios de la FACI-UNEMI y del sistema de educación superior en general, los resultados invitan a una reflexión sobre la naturaleza de la competencia que se está construyendo. El perfil identificado conocimiento funcional alto, comprensión arquitectónica débil, autoeficacia técnica elevada, pero autoeficacia de integración limitada describe a un profesorado que sabe usar la IA para sí mismo con relativa soltura, pero que aún no ha encontrado el puente entre ese uso personal y la transformación deliberada de su práctica pedagógica. Se recomienda que los docentes transiten, con apoyo institucional, desde la experimentación individual hacia la sistematización reflexiva: documentar las integraciones que realizan, compartirlas con colegas de su área, revisar los resultados de aprendizaje de sus estudiantes en relación con esas prácticas. Las subdimensiones de evaluación con IA rúbricas con criterios de uso de IAG (PP8) y verificación de información generada (PP12) son los eslabones más débiles de la cadena pedagógica identificada en este estudio, y su fortalecimiento exige no más información sino más práctica acompañada y más modelos de referencia visibles dentro de la propia comunidad docente.

A la comunidad científica, este estudio abre una agenda de investigación específica que los datos identifican, pero no pueden resolver por sus propios límites de diseño. En primer lugar, el hallazgo de que la autoeficacia media completamente la relación entre competencia conceptual y práctica pedagógica invita a investigaciones de corte longitudinal que examinen si el fortalecimiento de la autoeficacia mediante programas estructurados produce incrementos sostenidos en la práctica real, más allá de los efectos inmediatos de la formación.

En segundo lugar, la brecha disciplinar detectada con Ingeniería en Software como caso paradójico de alta competencia conceptual y baja práctica justifica estudios de caso cualitativos que profundicen en los mecanismos por los cuales el conocimiento técnico de un área no se transfiere al saber pedagógico sobre esa misma tecnología. En tercer lugar, la muestra de este estudio, circunscrita a la FACI-UNEMI, limita la generalizabilidad de los hallazgos; se recomienda replicar el instrumento validado en otras facultades de la UNEMI y en universidades de la región Costa del Ecuador, para construir una línea de base comparada que permita monitorear la evolución de esta brecha en el tiempo y evaluar el efecto de las políticas de innovación pedagógica que se implementen en los próximos años.

## BIBLIOGRAFÍA

- Aiken, L. R. (1985). Three coefficients for analyzing the reliability and validity of ratings. *Educational and Psychological Measurement*, 45(1), 131–142. <https://doi.org/10.1177/0013164485451012>
- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179–211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- Álvarez-Herrero, J. F., Gómez-Trigueros, I. M., & Urrea-Solano, M. (2024). Artificial intelligence in university teaching: Digital competence profiles of educators. *Education Sciences*, 14(2), 178. <https://doi.org/10.3390/educsci14020178>
- Ato, M., López-García, J. J., & Benavente, A. (2013). Un sistema de clasificación de los diseños de investigación en psicología. *Anales de Psicología*, 29(3), 1038–1059. <https://doi.org/10.6018/analesps.29.3.178511>
- Avalos, B. (2011). Teacher professional development in Teaching and Teacher Education over ten years. *Teaching and Teacher Education*, 27(1), 10–20. <https://doi.org/10.1016/j.tate.2010.08.007>
- Baidoo-Anu, D., & Owusu Ansah, L. (2023). Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning. *Journal of AI*, 7(1), 52–62. <https://doi.org/10.61969/jai.1337500>
- Bandura, A. (1997). *Self-efficacy: The exercise of control*. Freeman.
- Baruch, Y., & Holtom, B. C. (2008). Survey response rate levels and trends in organizational research. *Human Relations*, 61(8), 1139–1160. <https://doi.org/10.1177/0018726708094863>
- Bubeck, S., Chandrasekaran, V., Eldan, R., Gehrke, J., Horvitz, E., Kamar, E., Lee, P., Lee, Y. T., Li, Y., Lundberg, S., Nori, H., Palangi, H., Ribeiro, M. T., & Zhang, Y. (2023). Sparks of artificial general intelligence: Early experiments with GPT-4. *arXiv*. <https://arxiv.org/abs/2303.12712>
- Caena, F., & Redecker, C. (2019). Aligning teacher competence frameworks to 21st century challenges: The case for the European Digital Competence Framework for Educators (DigCompEdu). *European Journal of Education*, 54(3), 356–369. <https://doi.org/10.1111/ejed.12345>
- Castillo-Lara, M., Galvis-Ortiz, L. F., & Morales-Morgado, E. M. (2024). Integración de inteligencia artificial generativa en la educación superior colombiana: Competencia docente y adopción pedagógica. *Revista Iberoamericana de Educación a Distancia*, 27(2), 45–68. <https://doi.org/10.5944/ried.27.2.38104>

- Ceballos-Almeraya, R., Torres-Gastelú, C. A., & Domínguez-Chavarría, M. X. (2024). Competencias docentes para la integración de inteligencia artificial generativa en universidades mexicanas. *Apertura*, 16(1), 6–21. <https://doi.org/10.32870/Ap.v16n1.2350>
- Celik, I. (2023). Towards Intelligent-TPACK: An empirical study on teachers' professional knowledge to ethically integrate artificial intelligence (AI)-based tools into education. *Computers in Human Behavior*, 138, 107468. <https://doi.org/10.1016/j.chb.2022.107468>
- Celik, I., Dindar, M., Muukkonen, H., & Järvelä, S. (2022). The promises and challenges of artificial intelligence for teachers: A systematic review of research. *TechTrends*, 66(4), 616–630. <https://doi.org/10.1007/s11528-022-00715-y>
- Comisión Económica para América Latina y el Caribe. (2022). *Digitalización para el desarrollo: El desafío de América Latina y el Caribe*. CEPAL. <https://repositorio.cepal.org/handle/11362/48255>
- Chan, C. K. Y., & Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20(1), 43. <https://doi.org/10.1186/s41239-023-00411-8>
- Chiu, T. K. F. (2024). Future research recommendations for transforming higher education with generative AI. *Computers and Education: Artificial Intelligence*, 6, 100197. <https://doi.org/10.1016/j.caeai.2023.100197>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2.<sup>a</sup> ed.). Lawrence Erlbaum Associates.
- Creswell, J. W., & Creswell, J. D. (2023). *Research design: Qualitative, quantitative, and mixed methods approaches* (6.<sup>a</sup> ed.). Sage Publications.
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-8>
- Darling-Hammond, L., Hyster, M. E., & Gardner, M. (2017). *Effective teacher professional development*. Learning Policy Institute. <https://doi.org/10.54300/122.311>
- Davis, F. D. (1993). User acceptance of information technology: System characteristics, user perceptions and behavioral impacts. *International Journal of Man-Machine Studies*, 38(3), 475–487. <https://doi.org/10.1006/imms.1993.1022>
- Ecuador. (2021). *Ley Orgánica Reformatoria a la Ley Orgánica de Educación Superior*. Registro Oficial, Suplemento N.º 459. Asamblea Nacional del Ecuador.

- Ertmer, P. A. (1999). Addressing first- and second-order barriers to change: Strategies for technology integration. *Educational Technology Research and Development*, 47(4), 47–61. <https://doi.org/10.1007/BF02299597>
- Ertmer, P. A., & Ottenbreit-Leftwich, A. T. (2010). Teacher technology change: How knowledge, confidence, beliefs, and culture intersect. *Journal of Research on Technology in Education*, 42(3), 255–284. <https://doi.org/10.1080/15391523.2010.10782551>
- Ertmer, P. A., Ottenbreit-Leftwich, A. T., Sadik, O., Sendurur, E., & Sendurur, P. (2012). Teacher beliefs and technology integration practices: A critical relationship. *Computers & Education*, 59(2), 423–435. <https://doi.org/10.1016/j.compedu.2012.02.001>
- Espinoza, F., & Toscano, D. (2022). Percepción docente universitaria ecuatoriana ante la innovación pedagógica mediada por tecnología. *Revista Educación*, 46(2), 1–18. <https://doi.org/10.15517/revedu.v46i2.48312>
- Farrelly, T., & Baker, N. (2023). Generative artificial intelligence: Implications and considerations for higher education practice. *Education Sciences*, 13(11), 1109. <https://doi.org/10.3390/educsci13111109>
- Farrokhnia, M., Banihashem, S. K., Noroozi, O., & Wals, A. (2023). A SWOT analysis of ChatGPT: Implications for educational practice and research. *Innovations in Education and Teaching International*, 61(3), 460–474. <https://doi.org/10.1080/14703297.2023.2195846>
- Field, A. (2022). *Discovering statistics using IBM SPSS statistics* (5.<sup>a</sup> ed.). Sage Publications.
- García-Peñalvo, F. J. (2023). The perception of artificial intelligence in educational contexts after the launch of ChatGPT: Disruption or panic? *Education in the Knowledge Society*, 24, e31279. <https://doi.org/10.14201/eks.31279>
- García-Peñalvo, F. J., Llorens-Largo, F., & Vidal, J. (2023). The new reality of education in the face of advances in generative artificial intelligence. *RIED-Revista Iberoamericana de Educación a Distancia*, 27(1), 9–39. <https://doi.org/10.5944/ried.27.1.37716>
- Gómez-García, G., Hinojo-Lucena, F. J., Cáceres-Reche, M. P., & Ramos Navas-Parejo, M. (2020). Competencia digital docente en educación superior: Un análisis en universidades de España y Colombia. *Pixel-Bit: Revista de Medios y Educación*, 58, 187–206. <https://doi.org/10.12795/pixelbit.74177>
- Goodfellow, I., Bengio, Y., & Courville, A. (2020). *Deep learning*. MIT Press.
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>

- Hamilton, E. R., Rosenberg, J. M., & Akcaoglu, M. (2016). The Substitution Augmentation Modification Redefinition (SAMR) Model: A critical review and suggestions for its use. *TechTrends*, 60(5), 433–441. <https://doi.org/10.1007/s11528-016-0091-y>
- Hernández-Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.
- Holmes, W., Porayska-Pomsta, K., Holstein, K., Sutherland, E., Baker, T., Buckingham Shum, S., Santos, O. C., Rodrigo, M. T., Cukurova, M., Bittencourt, I. I., & Koedinger, K. R. (2022). Ethics of AI in education: Towards a community-wide framework. *International Journal of Artificial Intelligence in Education*, 32(3), 504–526. <https://doi.org/10.1007/s40593-021-00239-1>
- Johinke, R., Cummings, R., & di Lauro, F. (2023). Reclaiming the technology of higher education for teaching digital writing in a post-pandemic world. *Journal of University Teaching & Learning Practice*, 20(1), 1–23. <https://doi.org/10.53761/1.20.01.12>
- Johnson, R. B., & Onwuegbuzie, A. J. (2020). *Mixed methods research: A research paradigm whose time has come* (3.<sup>a</sup> ed.). Sage Publications.
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ... Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Lim, W. M., Gunasekara, A., Pallant, J. L., Pallant, J. I., & Pechenkina, E. (2023). Generative AI and the future of education: Ragnarök or reformation? A paradoxical perspective from management educators. *The International Journal of Management Education*, 21(2), 100790. <https://doi.org/10.1016/j.ijme.2023.100790>
- McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, 23(3), 412–433. <https://doi.org/10.1037/met0000144>
- Membrillo-Hernández, J., García-García, F. J., & Molina-Espinosa, J. M. (2024). Conocimiento de inteligencia artificial y adopción pedagógica en docentes universitarios latinoamericanos: Un estudio correlacional. *Revista Latinoamericana de Tecnología Educativa*, 23(1), 29–47. <https://doi.org/10.17398/1695-288X.23.1.29>
- Miao, F., Holmes, W., Huang, R., & Zhang, H. (2021). *AI and education: A guidance for policymakers*. UNESCO Publishing. <https://doi.org/10.54675/PCSP7350>
- Montero, I., & León, O. G. (2022). *Metodología de investigación en psicología y educación: Una guía para diseños de investigación* (5.<sup>a</sup> ed.). McGraw-Hill Education.

- Moorhouse, B. L., Yiu, W. K., & Lam, T. C. (2023). Generative AI tools and assessment: Educational policy guidelines from world universities. *Computers and Education Open*, 5, 100151. <https://doi.org/10.1016/j.caeo.2023.100151>
- Nunnally, J. C., & Bernstein, I. H. (1994). *Psychometric theory* (3.<sup>a</sup> ed.). McGraw-Hill.
- Organisation for Economic Co-operation and Development. (2023). *OECD digital education outlook 2023: Towards an effective digital education ecosystem*. OECD Publishing. <https://doi.org/10.1787/c74f03de-en>
- Pedró, F. (2023). *Inteligencia artificial y educación superior en Iberoamérica: Política, práctica e investigación*. UNESCO-IESALC. <https://doi.org/10.54675/BJPK6141>
- Pellas, N. (2023). A systematic review of teachers' attitudes toward artificial intelligence tools and their implications for training and education in the digital age. *International Journal of Learning, Teaching and Educational Research*, 22(4), 374–398. <https://doi.org/10.26803/ijlter.22.4.20>
- Pfeffer, J., & Sutton, R. I. (2000). *The knowing-doing gap: How smart companies turn knowledge into action*. Harvard Business School Press.
- Preston, C. C., & Colman, A. M. (2000). Optimal number of response categories in rating scales: Reliability, validity, discriminating power, and respondent preferences. *Acta Psychologica*, 104(1), 1–15. [https://doi.org/10.1016/S0001-6918\(99\)00050-5](https://doi.org/10.1016/S0001-6918(99)00050-5)
- Puentedura, R. R. (2006). *Transformation, technology, and education* [Blog post]. Hippasus. <http://hippasus.com/resources/tte/>
- Ramírez, A. V. (2020). *Metodología de la investigación científica* (4.<sup>a</sup> ed.). Editorial Académica Española.
- Redecker, C. (2017). *European framework for the digital competence of educators: DigCompEdu*. Publications Office of the European Union. <https://doi.org/10.2760/159770>
- Redecker, C., & Punie, Y. (Eds.). (2020). *European framework for the digital competence of educators: DigCompEdu* (2.<sup>a</sup> ed. actualizada). Publications Office of the European Union. <https://doi.org/10.2760/406084>
- Rodríguez-García, A. M., Martínez Heredia, N., & Raso Sánchez, F. (2023). Formación docente en inteligencia artificial en universidades españolas: Análisis de programas y efectividad. *Pixel-Bit: Revista de Medios y Educación*, 66, 7–32. <https://doi.org/10.12795/pixelbit.99332>
- Rosseel, Y. (2012). lavaan: An R package for structural equation modeling. *Journal of Statistical Software*, 48(2), 1–36. <https://doi.org/10.18637/jss.v048.i02>

- Saris, W. E., & Gallhofer, I. N. (2023). *Design, evaluation, and analysis of questionnaires for survey research* (3.<sup>a</sup> ed.). Wiley.
- Selwyn, N. (2022). The future of AI and education: Some cautionary notes. *European Journal of Education*, 57(4), 620–631. <https://doi.org/10.1111/ejed.12532>
- Southworth, J., Migliaccio, K., Glover, J., Glover, J. N., Reed, D., Sullivan, C., Prinz, N., Sherlock, J., Retalis, S., & Ottenbreit-Leftwich, A. T. (2023). Developing a model for AI across the curriculum: Transforming the higher education landscape via innovation in AI literacy. *Computers and Education: Artificial Intelligence*, 4, 100127. <https://doi.org/10.1016/j.caeai.2023.100127>
- Tlili, A., Shehata, B., Adarkwah, M. A., Bozkurt, A., Hickey, D. T., Huang, R., & Agyemang, B. (2023). What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education. *Smart Learning Environments*, 10(1), 15. <https://doi.org/10.1186/s40561-023-00237-x>
- Tondeur, J., van Braak, J., Ertmer, P. A., & Ottenbreit-Leftwich, A. (2017). Understanding the relationship between teachers' pedagogical beliefs and technology use in education: A systematic review of qualitative evidence. *Educational Technology Research and Development*, 65(3), 555–575. <https://doi.org/10.1007/s11423-016-9481-2>
- Tondeur, J., Scherer, R., Siddiq, F., & Baran, E. (2022). A comprehensive investigation of TPACK within learning to teach: Where does technology fit in a teacher education program? *Teaching and Teacher Education*, 117, 103793. <https://doi.org/10.1016/j.tate.2022.103793>
- Turpo-Gebera, O., Hurtado-Mazeyra, A., Núñez-Pacheco, R., Paz, L. C., & García-Peñalvo, F. J. (2022). Digital teaching competence development: Systematic literature review. *Education in the Knowledge Society*, 23, e26754. <https://doi.org/10.14201/eks.26754>
- Uerz, D., Volman, M., & Kral, M. (2018). Teacher educators' competences in fostering student teachers' proficiency in teaching and learning with technology: An overview of relevant research literature. *Teaching and Teacher Education*, 70, 12–23. <https://doi.org/10.1016/j.tate.2017.11.005>
- UNESCO. (2023). *Guidance for generative AI in education and research*. UNESCO Publishing. <https://doi.org/10.54675/EWZP4102>
- 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>

- Yildiz Durak, H. (2023). Examining the role of self-efficacy in explaining AI adoption in instruction: A study of higher education instructors. *Interactive Learning Environments*, 32(5), 2301–2318. <https://doi.org/10.1080/10494820.2023.2175065>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education — where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., Liu, P., & Wen, J. R. (2023). A survey of large language models. *arXiv*. <https://arxiv.org/abs/2303.18223>

## ANEXOS

### ANEXO A

#### INSTRUMENTO DE RECOLECCIÓN DE DATOS

#### Escala de Competencia Conceptual y Práctica Pedagógica en Inteligencia Artificial Generativa (ECCPP-IAG)

#### UNIVERSIDAD ESTATAL DE MILAGRO — UNEMI Maestría en Educación con Mención en Lingüística y Literatura

#### Instrucciones generales para el participante

Estimado/a docente:

El presente cuestionario forma parte de una investigación científica cuyo propósito es analizar la relación entre el conocimiento que los docentes de la UNEMI tienen sobre inteligencia artificial generativa (IAG) y la forma en que integran estas herramientas en su práctica pedagógica. Su participación es completamente voluntaria y anónima. No existen respuestas correctas o incorrectas; se solicita únicamente que responda con la mayor sinceridad posible, describiendo su situación real. El tiempo estimado de respuesta es de 15 a 20 minutos. Los datos serán utilizados exclusivamente con fines académicos y científicos, en cumplimiento de la normativa de protección de datos personales vigente en el Ecuador.

Al responder este cuestionario, usted otorga su consentimiento informado para participar en el estudio.

Investigador principal: [Nombre del investigador] Correo de contacto: [correo institucional]  
Programa: Maestría en Educación con Mención en Lingüística y Literatura, UNEMI

#### SECCIÓN A — DATOS SOCIODEMOGRÁFICOS Y PROFESIONALES

Instrucción: Complete o seleccione la opción que corresponda a su situación actual.

**A1. Correo institucional (solo para evitar duplicados; no se asociará a sus respuestas):**

**A2. Género:** ( ) Masculino ( ) Femenino ( ) Prefiero no indicarlo

**A3. Edad (en años cumplidos):**

**A4. Años de experiencia docente universitaria:**

---

**A5. Carrera a la que pertenece:** ( ) Tecnologías de la Información en Modalidad en Línea ( ) Ingeniería Industrial en Modalidad Presencial ( ) Ingeniería de Software en Modalidad Presencial ( ) Ingeniería en Alimentos en Modalidad Presencial ( ) Ingeniería Ambiental en Modalidad Presencial ( ) Biotecnología en Modalidad Presencial ( ) Arquitectura Sostenible en Modalidad Presencial ( ) Otra: \_\_\_\_\_

**A6. Asignaturas que imparte actualmente:**

**A7. Formación académica máxima alcanzada:** ( ) Maestría / Magíster ( ) Doctorado (PhD o equivalente) ( ) Otra: \_\_\_\_\_

**A8. ¿Ha recibido capacitación formal en tecnologías educativas?** ( ) Nunca ( ) Hace más de 5 años ( ) En los últimos 5 años ( ) En el último año ( ) En los últimos 6 meses

**A9. ¿Con qué frecuencia usa herramientas de IA generativa (ChatGPT, Claude, Gemini, Copilot, etc.)?** ( ) Nunca ( ) Ocasionalmente (menos de 1 vez al mes) ( ) A veces (1 a 3 veces al mes) ( ) Regularmente (semanalmente) ( ) Frecuentemente (diariamente)

## **SECCIÓN B — DIMENSIÓN 1: COMPETENCIA CONCEPTUAL EN INTELIGENCIA ARTIFICIAL GENERATIVA**

**Instrucción:** A continuación, encontrará una serie de afirmaciones sobre su conocimiento acerca de la inteligencia artificial generativa (IAG). Indique su nivel de acuerdo con cada afirmación según la siguiente escala:

**1 = Totalmente en desacuerdo / 2 / 3 / 4 = Ni de acuerdo ni en desacuerdo / 5 / 6 / 7 = Totalmente de acuerdo**

### **Subdimensión B1 — Fundamentos y funcionamiento del modelo**

CC1. Comprendo los principios básicos de cómo los modelos de lenguaje generan texto. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC2. Puedo explicar la diferencia entre la IA generativa y los motores de búsqueda tradicionales. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC3. Los conceptos técnicos de la IA generativa me resultan demasiado complejos para entenderlos. (*ítem inverso*) 1 — 2 — 3 — 4 — 5 — 6 — 7

### **Subdimensión B2 — Comprensión técnica aplicada**

CC4. Entiendo qué son los "prompts" y cómo influyen en las respuestas de la IA generativa. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC8. Comprendo los conceptos de "tokens", "contexto" y "temperatura" en los modelos de IA generativa. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC12. Comprendo cómo los datos de entrenamiento influyen en las capacidades de la IA generativa. 1 — 2 — 3 — 4 — 5 — 6 — 7

### **Subdimensión B3 — Reconocimiento de limitaciones**

CC5. Conozco las limitaciones actuales de las herramientas de IA generativa (alucinaciones, sesgos, desactualización, etc.). 1 — 2 — 3 — 4 — 5 — 6 — 7

CC6. Puedo identificar cuándo una respuesta generada por IA puede contener información incorrecta o imprecisa. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC7. No entiendo cómo la IA generativa puede "aprender" o mejorar sus respuestas con el tiempo. (*ítem inverso*) 1 — 2 — 3 — 4 — 5 — 6 — 7

### **Subdimensión B4 — Tipología y diferenciación de herramientas**

CC9. Puedo distinguir entre diferentes tipos de IA generativa: modelos de texto, imagen, código, audio, etc. 1 — 2 — 3 — 4 — 5 — 6 — 7

CC11. La terminología técnica asociada con la IA generativa me resulta confusa. (*ítem inverso*) 1 — 2 — 3 — 4 — 5 — 6 — 7

### **Subdimensión B5 — Dimensión ética conceptual**

CC10. Entiendo las implicaciones éticas del uso de IA generativa en el ámbito educativo. 1 — 2 — 3 — 4 — 5 — 6 — 7

## **SECCIÓN C — DIMENSIÓN 2: PRÁCTICA PEDAGÓGICA CON INTELIGENCIA ARTIFICIAL GENERATIVA**

**Instrucción:** Las siguientes afirmaciones describen acciones docentes relacionadas con el uso de IA generativa en el aula. Indique con qué frecuencia realiza cada acción en su práctica pedagógica actual, usando la siguiente escala:

**1 = Nunca / 2 = Raramente / 3 = A veces / 4 = Con frecuencia / 5 = Siempre**

### **Subdimensión C1 — Diseño instruccional con IA**

PP1. Diseño actividades de aprendizaje que aprovechan las capacidades de la IA generativa para personalizar la instrucción. 1 — 2 — 3 — 4 — 5

PP3. Adapto mi metodología de enseñanza para incorporar herramientas de IA generativa de manera intencionada. 1 — 2 — 3 — 4 — 5

PP4. Uso la IA generativa para crear ejemplos diversos y contextualizados para mis clases. 1 — 2 — 3 — 4 — 5

PP15. Adapto y contextualizo los recursos generados por IA al contexto cultural y disciplinar específico de mis estudiantes. 1 — 2 — 3 — 4 — 5

### **Subdimensión C2 — Mediación y andamiaje pedagógico**

PP2. Creo prompts educativos efectivos para que los estudiantes interactúen de manera productiva con herramientas de IA generativa. 1 — 2 — 3 — 4 — 5

PP6. Enseño a los estudiantes a formular preguntas efectivas para obtener respuestas útiles de los sistemas de IA. 1 — 2 — 3 — 4 — 5

PP7. Integro la IA generativa como herramienta de retroalimentación personalizada para los estudiantes. 1 — 2 — 3 — 4 — 5

### **Subdimensión C3 — Evaluación con IA**

PP5. Diseño evaluaciones que consideran el uso ético y apropiado de la IA generativa por parte de los estudiantes. 1 — 2 — 3 — 4 — 5

PP8. Desarrollo rúbricas de evaluación que incluyen criterios sobre el uso apropiado de la IA generativa. 1 — 2 — 3 — 4 — 5

#### **Subdimensión C4 — Pensamiento crítico y aprendizaje activo con IA**

PP9. Creo escenarios de aprendizaje colaborativo donde los estudiantes y la IA trabajan conjuntamente para resolver problemas. 1 — 2 — 3 — 4 — 5

PP10. Uso la IA generativa para diferenciar la instrucción según las necesidades individuales de los estudiantes. 1 — 2 — 3 — 4 — 5

PP11. Diseño actividades que desarrollan el pensamiento crítico de los estudiantes respecto a los resultados generados por IA. 1 — 2 — 3 — 4 — 5

PP12. Incorporo la verificación de información generada por IA como una habilidad clave que deben desarrollar mis estudiantes. 1 — 2 — 3 — 4 — 5

#### **Subdimensión C5 — Uso ético y modelamiento docente**

PP13. Modelo el uso responsable y transparente de la IA generativa durante mis clases. 1 — 2 — 3 — 4 — 5

PP14. Facilito discusiones sobre las implicaciones éticas del uso de IA generativa en el contexto académico. 1 — 2 — 3 — 4 — 5

### **SECCIÓN D — DIMENSIÓN 3: AUTOEFICACIA DOCENTE EN INTELIGENCIA ARTIFICIAL GENERATIVA**

**Instrucción:** Las siguientes afirmaciones describen tareas relacionadas con el uso de IA generativa en contextos docentes. Indique su nivel de confianza para realizar cada una de estas tareas de manera autónoma, usando la siguiente escala:

**1 = Nada seguro/a / 2 = Poco seguro/a / 3 = Moderadamente seguro/a / 4 = Bastante seguro/a / 5 = Muy seguro/a**

AE1. Resolver problemas técnicos básicos al usar herramientas de IA generativa sin necesitar ayuda externa. 1 — 2 — 3 — 4 — 5

AE2. Enseñar a un colega cómo usar efectivamente ChatGPT u otra herramienta de IA generativa similar. 1 — 2 — 3 — 4 — 5

AE3. Identificar y corregir información incorrecta generada por IA en mi área disciplinar. 1 — 2 — 3 — 4 — 5

AE4. Crear una actividad de aprendizaje innovadora usando IA generativa en menos de 30 minutos. 1 — 2 — 3 — 4 — 5

AE5. Guiar a los estudiantes para que usen la IA generativa de manera ética y académicamente íntegra. 1 — 2 — 3 — 4 — 5

AE6. Evaluar la calidad y pertinencia del contenido generado por IA para mi asignatura. 1 — 2 — 3 — 4 — 5

AE7. Personalizar la configuración de una herramienta de IA generativa para satisfacer necesidades educativas específicas. 1 — 2 — 3 — 4 — 5

AE8. Integrar la IA generativa de manera fluida en mi flujo de trabajo docente actual. 1 — 2 — 3 — 4 — 5

AE9. Apoyar a los estudiantes cuando tienen dificultades técnicas o conceptuales al usar herramientas de IA generativa. 1 — 2 — 3 — 4 — 5

AE10. Mantenerme actualizado/a con los avances en IA generativa que son relevantes para la educación en mi disciplina. 1 — 2 — 3 — 4 — 5

## **SECCIÓN E — ACTITUDES HACIA LA INTELIGENCIA ARTIFICIAL GENERATIVA EN EL AULA**

**Instrucción:** A continuación, se presentan pares de adjetivos opuestos que describen posibles percepciones sobre el uso de la IA generativa en el aula de clases. Marque el número que mejor represente su posición entre cada par de conceptos.

*(1 corresponde al extremo izquierdo; 7 corresponde al extremo derecho; los valores intermedios representan posiciones graduales entre ambos extremos)*

**La IA generativa en el aula de clases es...**

AT1. Inútil 1 — 2 — 3 — 4 — 5 — 6 — 7 Útil

AT2. Desmotivadora 1 — 2 — 3 — 4 — 5 — 6 — 7 Motivadora

AT3. Compleja 1 — 2 — 3 — 4 — 5 — 6 — 7 Sencilla

AT4. Riesgosa 1 — 2 — 3 — 4 — 5 — 6 — 7 Segura

AT5. Irrelevante 1 — 2 — 3 — 4 — 5 — 6 — 7 Relevante

AT6. Perjudicial 1 — 2 — 3 — 4 — 5 — 6 — 7 Beneficiosa

AT7. Desafiante 1 — 2 — 3 — 4 — 5 — 6 — 7 Accesible

AT8. Excluyente 1 — 2 — 3 — 4 — 5 — 6 — 7 Integradora

**Gracias por su participación. Sus respuestas contribuyen directamente a la mejora de la calidad educativa en la UNEMI.**