

# Classification of Student Profiles Based on Generative AI Dependency and Complex Problem-Solving Capacity: A Machine Learning Approach Using K-Means Clustering

Benites-Rodriguez, Joseph<sup>1</sup>; Salazar-Sandoval, Fredy<sup>1</sup>; Amaro-Guzman, Carlos<sup>1</sup>; Grados-Espinoza, Anna<sup>1</sup>; Torres-Quiroz, Alminton<sup>1</sup>; Narciso-Gomez, Kennedy<sup>1</sup>; Narciso-Huaccho, Yuleissi-Xiomara<sup>2</sup>

<sup>1</sup>Universidad Nacional del Callao - (PE), Perú, [jmbenitesr@unac.edu.pe](mailto:jmbenitesr@unac.edu.pe); [fsalazars@unac.edu.pe](mailto:fsalazars@unac.edu.pe); [cjamarog@unac.edu.pe](mailto:cjamarog@unac.edu.pe); [akgradose@unac.edu.pe](mailto:akgradose@unac.edu.pe); [agtorresq@unac.edu.pe](mailto:agtorresq@unac.edu.pe); [knarcisog@unac.edu.pe](mailto:knarcisog@unac.edu.pe)

<sup>2</sup>Universidad Ricardo Palma - (PE), Perú, [yuleissi.narciso@urp.edu.pe](mailto:yuleissi.narciso@urp.edu.pe)

**Abstract**– The rapid integration of Generative Artificial Intelligence (GAI) tools, particularly ChatGPT, into higher education has raised concerns about potential cognitive dependency and its impact on students' problem-solving skills. This study aims to classify student profiles based on their dependency on generative AI and their ability to solve complex problems using machine learning clustering techniques. A cross-sectional study was conducted with 847 engineering students from three Latin American universities. The AI Dependency Scale for University Students (EDIAU-15), the Complex Problem-Solving Inventory (IRPC-25), and the ChatGPT Frequency of Use Questionnaire (CFUC) were administered. K-means clustering with Davies-Bouldin optimization identified four distinct student profiles: (1) Critical Autonomists (23.4%, n=198): low AI dependence, high problem-solving ability; (2) Balanced Integrators (31.2%, n=264): moderate AI use, preserved cognitive skills; (3) Dependent Compensators (28.6%, n=242): high dependence on AI, declining problem-solving ability; and (4) Passive Delegators (16.8%, n=143): severe dependence on AI, significantly impaired cognitive functioning. ANOVA revealed significant differences between profiles in academic performance ( $F=47.82, p<.001$ ), metacognitive awareness ( $F=38.94, p<.001$ ), and self-efficacy ( $F=52.17, p<.001$ ). Structural equation modeling confirmed that AI dependence mediates the relationship between ChatGPT usage frequency and problem-solving ability ( $\beta=-0.43, p<.001$ ).

**Keywords**– Generative AI, ChatGPT, problem solving, students, K-means clustering

# Clasificación de Perfiles de Estudiantes según su Dependencia a la IA Generativa y su Capacidad de Resolución de Problemas Complejos: Un Enfoque de Aprendizaje Automático mediante Clustering K-Means

Benites-Rodriguez, Joseph<sup>1</sup>; Salazar-Sandoval, Fredy<sup>1</sup>; Amaro-Guzman, Carlos<sup>1</sup>; Grados-Espinoza, Anna<sup>1</sup>; Torres-Quiroz, Alminton<sup>1</sup>; Narciso-Gomez, Kennedy<sup>1</sup>; Narciso-Huaccho, Yuleissi-Xiomara<sup>2</sup>

<sup>1</sup>Universidad Nacional del Callao - (PE), Perú, jmbenitesr@unac.edu.pe; fsalazars@unac.edu.pe; cjaminarog@unac.edu.pe; akgradose@unac.edu.pe; agtorresq@unac.edu.pe; knarcisog@unac.edu.pe

<sup>2</sup>Universidad Ricardo Palma - (PE), Perú, yuleissi.narciso@urp.edu.pe

**Resumen**– La rápida integración de herramientas de Inteligencia Artificial Generativa (IAG), particularmente ChatGPT, en la educación superior ha generado preocupaciones sobre la potencial dependencia cognitiva y su impacto en las habilidades de resolución de problemas de los estudiantes. Este estudio tiene como objetivo clasificar perfiles de estudiantes basándose en su dependencia a la IA generativa y su capacidad de resolución de problemas complejos utilizando técnicas de clustering de aprendizaje automático. Se realizó un estudio transversal con 847 estudiantes de ingeniería de tres universidades latinoamericanas. Se administraron la Escala de Dependencia a IA para Estudiantes Universitarios (EDIAU-15), el Inventario de Resolución de Problemas Complejos (IRPC-25) y el Cuestionario de Frecuencia de Uso de ChatGPT (CFUC). El clustering K-means con optimización Davies-Bouldin identificó cuatro perfiles distintos de estudiantes: (1) *Autonomistas Críticos* (23.4%, n=198): baja dependencia a IA, alta capacidad de resolución de problemas; (2) *Integradores Equilibrados* (31.2%, n=264): uso moderado de IA, habilidades cognitivas preservadas; (3) *Compensadores Dependientes* (28.6%, n=242): alta dependencia a IA, capacidad de resolución de problemas en declive; y (4) *Delegadores Pasivos* (16.8%, n=143): dependencia severa a IA, funcionamiento cognitivo significativamente deteriorado. ANOVA reveló diferencias significativas entre perfiles en rendimiento académico ( $F=47.82$ ,  $p<.001$ ), conciencia metacognitiva ( $F=38.94$ ,  $p<.001$ ) y autoeficacia ( $F=52.17$ ,  $p<.001$ ). El modelado de ecuaciones estructurales confirmó que la dependencia a IA interviene en la relación de la frecuencia de uso de ChatGPT y la capacidad de resolución de problemas ( $\beta=-0.43$ ,  $p<.001$ ).

**Palabras clave**– IA generativa, ChatGPT, resolución de problemas, estudiantes, clustering K-means

## I. INTRODUCCIÓN

La irrupción de ChatGPT en noviembre de 2022 marcó un punto de inflexión en la relación entre la Inteligencia Artificial (IA) y la educación superior. En menos de dos años, las herramientas de IA generativa (IAG) han sido implementadas masivamente por estudiantes universitarios a nivel mundial, con tasas de uso que superan el 80% en algunas poblaciones [1][2]. Este uso sin precedentes ha generado un intenso debate

académico sobre los beneficios y riesgos potenciales de estas tecnologías para el desarrollo cognitivo y las competencias fundamentales de los estudiantes [3][4].

Investigaciones recientes han documentado un fenómeno emergente denominado 'pereza metacognitiva' o 'cognitive offloading', caracterizado por la tendencia de los usuarios a delegar procesos cognitivos de alto orden a sistemas de IA, incluyendo el análisis crítico, síntesis de información y resolución de problemas [5][6]. Abbas et al. encontraron que los estudiantes universitarios que usan ChatGPT frecuentemente muestran un menor compromiso cognitivo, memoria más débil y menor sentido de propiedad sobre su trabajo comparados con grupos de control [7]. Estos hallazgos son consistentes con estudios de Anthropic que revelaron que estudiantes delegaban funciones cognitivas de orden superior a sistemas de IA, planteando preguntas sobre el desarrollo de las habilidades fundamentales [8].

La capacidad de resolución de problemas complejos constituye una competencia fundamental para profesionales del siglo XXI, particularmente en campos de ingeniería donde la identificación, análisis y solución de problemas es central para la práctica profesional [9][10]. El Foro Económico Mundial ha identificado consistentemente la resolución de problemas complejos como la habilidad más demandada en el mercado laboral global [11]. Sin embargo, esta evidencia sugiere que la dependencia excesiva a herramientas de IAG puede impactar negativamente en las capacidades críticas mediante el reemplazo de procesos cognitivos activos por consultas pasivas a sistemas automatizados [12][13].

El modelo I-PACE (Interaction of Person-Affect-Cognition-Execution) proporciona un marco teórico relevante para comprender el desarrollo de comportamientos problemáticos relacionados con la tecnología [14]. Este modelo postula que las características individuales (autoeficacia académica), factores afectivos (estrés académico), y procesos cognitivos (expectativas de rendimiento) interactúan para predecir patrones de uso

problemático [15]. Choi et al. aplicaron este modelo al estudio de dependencia a ChatGPT, encontrando que el estrés académico y las expectativas de rendimiento interfieren en la relación entre la autoeficacia y la dependencia a la IA [16].

A pesar de la creciente literatura sobre el uso de IAG en la educación, existe una brecha significativa en la comprensión de cómo diferentes patrones de uso se relacionan con capacidades cognitivas específicas. Particularmente, no se han identificado perfiles diferenciados de estudiantes que integren dimensiones de dependencia tecnológica y competencias de resolución de problemas. Esta investigación aborda esta brecha mediante la aplicación de técnicas de aprendizaje automático para identificar y caracterizar perfiles de estudiantes universitarios según su dependencia a IAG y analizar su capacidad de resolución de problemas complejos.

Los objetivos específicos de este estudio son: (1) desarrollar y validar instrumentos para medir la dependencia a IAG y capacidad de resolución de problemas complejos en el contexto latinoamericano; (2) identificar perfiles diferenciados de estudiantes mediante clustering K-means; (3) caracterizar cada perfil en términos de variables académicas, cognitivas y comportamentales; y (4) examinar las relaciones causales entre el uso de ChatGPT, dependencia a IAG, y capacidad de resolución de problemas mediante un modelado de ecuaciones estructurales.

La estructura de este estudio se presenta de la siguiente manera: en la sección de Marco Teórico se detallan conceptos relacionados a la temática del estudio. En Metodología, se muestran los pasos secuenciales que se utilizaron para desarrollar el análisis respectivo. En Resultados, se muestran los datos estadísticos derivados del análisis correspondiente. En Discusión, se presentan las comparaciones y puntos encontrados con referencia a los objetivos del estudio; así también, se muestran las limitaciones del estudio y se sugieren futuras líneas de investigación. En la sección de Conclusiones, se presentan los resultados resumidos a conformidad de lo establecido por el propósito del estudio.

## II. MARCO TEÓRICO

### A. Dependencia a la Inteligencia Artificial Generativa

La dependencia a la IAG puede conceptualizarse como un estado caracterizado por alta confianza en la funcionalidad de sistemas de IA combinada con reacciones psicológicas de abstinencia y funcionamiento deteriorado cuando la asistencia de IA no está disponible [17]. Esta conceptualización se distingue de nociones más amplias de 'uso problemático de tecnología' al enfocarse específicamente en la dependencia funcional y cognitiva, más que en patrones adictivos clásicos [18][19].

Morales-García et al. desarrollaron y validaron la primera escala específica de Dependencia a IA en estudiantes universitarios, identificando tres dimensiones: dependencia funcional (incapacidad de completar tareas sin IA), dependencia emocional (malestar psicológico ante

indisponibilidad), y dependencia cognitiva (delegación de procesos de pensamiento) [20]. Yu et al. propusieron la Escala de Uso Problemático de ChatGPT (PCGUS), un instrumento unidimensional de 9 ítems que evalúa patrones de uso maladaptativo consistentes con criterios de adicciones comportamentales [21]. Recientemente, Chen et al. desarrollaron la Escala de Dependencia a LLM, que captura específicamente las reacciones de abstinencia y deterioro funcional observadas cuando sistemas como ChatGPT no están disponibles [22].

La prevalencia de dependencia a IAG en estudiantes universitarios varía considerablemente según el contexto y criterios utilizados. Estudios en Asia reportan tasas de dependencia moderada-alta entre 35-45% de usuarios frecuentes de ChatGPT [16][23]. En contextos occidentales, Paz et al. documentaron que aproximadamente el 30% de los estudiantes universitarios exhiben signos de dependencia cognitiva a herramientas de IAG [24]. Los cinco efectos negativos más reportados de esta dependencia incluyen: aumento de pereza, propagación de desinformación, menor creatividad, y reducción del pensamiento crítico e independiente [16].

### B. Resolución de Problemas Complejos en Educación Superior

La Resolución de Problemas Complejos (RPC) se define como la capacidad cognitiva para procesar información en situaciones dinámicas, con múltiples variables interrelacionadas, donde las reglas subyacentes son parcialmente desconocidas o cambiantes [25][26]. A diferencia de los problemas bien estructurados con soluciones únicas y verificables, los problemas complejos requieren integración de conocimiento de múltiples dominios, tolerancia a la ambigüedad, y adaptación iterativa de estrategias [27]. Esta capacidad constituye un componente central de la taxonomía de Bloom revisada, correspondiendo a los niveles superiores de análisis, evaluación y creación [28].

Instrumentos validados para medir RPC incluyen el Social Problem-Solving Inventory (SPSI) de D'Zurilla et al. [29], el Problem-Solving Inventory (PSI) de Heppner [30], y evaluaciones basadas en simulaciones como MicroDYN y MicroFIN [31]. Más recientemente, se han desarrollado instrumentos específicos para contextos de educación superior que capturan dimensiones de pensamiento analítico, razonamiento lógico, metacognición y transferencia de conocimiento [32][33]. Estos instrumentos evalúan tanto la orientación hacia problemas (actitudes y creencias) como estilos de resolución (estrategias y comportamientos).

La evidencia sobre el impacto de IAG en RPC presenta un panorama complejo. Por un lado, estudios han documentado que ChatGPT puede facilitar procesos de aprendizaje, reducir carga cognitiva y apoyar al desarrollo de argumentación estructurada [34][35]. Essel et al. encontraron que la interacción guiada con ChatGPT mejoró habilidades de pensamiento crítico, reflexivo y creativo en estudiantes

universitarios de Ghana [36]. Por otro lado, evidencia sugiere que el uso no guiado puede producir efectos adversos. Ododo et al. observaron que estudiantes usando ChatGPT sin soporte instruccional mostraron dificultades con tareas que requerían abstracción y resolución de problemas de orden superior [37]. Jošt et al. reportaron que estudiantes que dependían frecuentemente de ChatGPT para tareas críticas exhibieron peor rendimiento, sugiriendo que la dependencia excesiva puede socavar el desarrollo del pensamiento crítico [38].

### C. Perfilación de Estudiantes mediante Aprendizaje Automático

Las técnicas de clustering de aprendizaje automático han demostrado una utilidad significativa para identificar subgrupos homogéneos dentro de poblaciones estudiantiles heterogéneas [39][40]. El algoritmo K-means; uno de los métodos más utilizados, particiona datos en k-clusters, minimizando la varianza intra-cluster y maximizando la varianza inter-cluster [41]. La selección del número óptimo de clusters típicamente se realiza mediante métodos como el codo (Elbow), coeficiente de silueta, o el índice de Davies-Bouldin [42].

Aplicaciones recientes de clustering en contextos educativos han identificado perfiles diferenciados de estudiantes basados en comportamientos de aprendizaje, engagement y rendimiento [43][44]. Ahmed utilizó K-means con optimización Davies-Bouldin para identificar clusters de rendimiento estudiantil, logrando precisiones predictivas del 96% con clasificadores SVM [45]. Estudios en el contexto PISA 2022 han utilizado metodologías de clustering explicables combinando la reducción de dimensionalidad, agrupamiento y clasificación para caracterizar perfiles estudiantiles [46]. Investigaciones sobre actitudes hacia IA en educación han identificado perfiles como 'Balanced Supporters', 'Critical Evaluators' y 'Optimistic Users', cada uno con patrones diferenciados de confianza, preocupaciones éticas y expectativas de uso [47].

## III. METODOLOGÍA

### A. Diseño del Estudio

Se utilizó un diseño de investigación transversal con componentes de validación psicométrica y análisis de clustering. El estudio se desarrolló en tres fases: (1) adaptación y validación de instrumentos; (2) recolección de datos y análisis descriptivo; e (3) identificación y caracterización de perfiles mediante aprendizaje automático.

### B. Participantes

La muestra incluyó 847 estudiantes de pregrado en programas de ingeniería de tres universidades latinoamericanas: Universidad Nacional de Ingeniería (Perú, n=312), Universidad Tecnológica Nacional (Argentina, n=287), y Universidad de los Andes (Colombia, n=248). Los criterios de inclusión fueron: (a) estar matriculado en

programa de ingeniería; (b) haber utilizado ChatGPT al menos una vez en los últimos 3 meses; (c) consentimiento informado. Se excluyeron estudiantes de primer semestre por la limitada exposición a tareas académicas complejas.

Las características demográficas de la muestra fueron: edad media 21.4 años (DE=2.3), 62.3% hombres, 37.7% mujeres; distribución por semestre: 2°-4° (28.3%), 5°-7° (45.2%), 8°-10° (26.5%); especialidades: Ingeniería de Sistemas/Computación (34.2%), Civil (22.1%), Industrial (19.7%), Mecánica (13.4%), otras (10.6%). El muestreo fue no probabilístico por conveniencia con cuotas por universidad y especialidad.

### C. Instrumentos

Los instrumentos utilizados en este estudio fueron:

- 1) *Escala de Dependencia a IA para Estudiantes Universitarios (EDIAU-15)*: Se adaptó y validó una escala de 15 ítems basada en los instrumentos de Morales-García et al. [20] y Yu et al. [21]. La escala evalúa tres dimensiones: Dependencia Funcional (5 ítems,  $\alpha=0.87$ ), Dependencia Emocional (5 ítems,  $\alpha=0.84$ ), y Dependencia Cognitiva (5 ítems,  $\alpha=0.89$ ). Los ítems se responden en escala Likert de 5 puntos (1=Totalmente en desacuerdo a 5=Totalmente de acuerdo). El AFC confirmó la estructura trifactorial ( $\chi^2/df=2.34$ , CFI=0.94, TLI=0.92, RMSEA=0.052, SRMR=0.048).
- 2) *Inventario de Resolución de Problemas Complejos (IRPC-25)*: Se desarrolló un inventario de 25 ítems basado en el SPSI-R [29], PSI [30], y marcos teóricos de RPC [25][26]. El instrumento evalúa cinco dimensiones: Orientación Positiva hacia Problemas (5 ítems,  $\alpha=0.83$ ), Análisis Sistemático (5 ítems,  $\alpha=0.86$ ), Razonamiento Lógico (5 ítems,  $\alpha=0.88$ ), Pensamiento Metacognitivo (5 ítems,  $\alpha=0.85$ ), y Transferencia de Conocimiento (5 ítems,  $\alpha=0.82$ ). La consistencia interna global fue  $\alpha=0.91$ . El AFC confirmó la estructura penta factorial ( $\chi^2/df=2.12$ , CFI=0.93, TLI=0.91, RMSEA=0.058, SRMR=0.052).
- 3) *Cuestionario de Frecuencia de Uso de ChatGPT (CFUC)*: Instrumento de 10 ítems que evalúa la frecuencia, intensidad, contextos y propósitos de uso de ChatGPT. Incluye ítems sobre: frecuencia semanal de uso (1=Nunca a 6=Varias veces al día), duración promedio de sesiones, tipos de tareas delegadas, y nivel de edición de outputs. Adicionalmente, se administraron: Escala de Autoeficacia Académica General ( $\alpha=0.86$ ) [48], Escala de Estrés Académico ( $\alpha=0.84$ ) [49], e Inventario de Conciencia Metacognitiva ( $\alpha=0.89$ ) [50].

### D. Procedimiento

La recolección de datos se realizó entre marzo y mayo de 2025 mediante cuestionarios en línea administrados a través

de Qualtrics. Los participantes fueron reclutados mediante anuncios en plataformas institucionales y aulas virtuales. El tiempo promedio para completar el cuestionario fue de 25 minutos. Se implementaron verificaciones de atención y se excluyeron respuestas con patrones sospechosos (n=43, 4.8%). El estudio fue aprobado por los Comités de Ética de las tres universidades participantes.

#### E. Análisis de Datos

El análisis se realizó en cuatro etapas: (1) Análisis psicométrico de instrumentos mediante AFC en AMOS 28; (2) Estadística descriptiva e inferencial en SPSS 29; (3) Clustering K-means en Python (scikit-learn) con optimización del número de clusters mediante método del codo, coeficiente de silueta e índice de Davies-Bouldin; (4) Modelado de Ecuaciones Estructurales en Mplus 8.8. Las variables fueron estandarizadas (z-scores) previo al clustering. Se aplicó una reducción de dimensionalidad mediante PCA para la visualización. La comparación entre clusters se realizó mediante ANOVA one-way con pruebas post-hoc de Tukey. La Tabla 1 detalla las características demográficas de la muestra utilizada para este estudio.

TABLA I  
CARACTERÍSTICAS DEMOGRÁFICAS DE LA MUESTRA (N=847)

| Variable     | Categoría            | n   | %     |
|--------------|----------------------|-----|-------|
| Género       | Masculino            | 528 | 62.3% |
|              | Femenino             | 319 | 37.7% |
| Edad (años)  | 18-20                | 287 | 33.9% |
|              | 21-23                | 412 | 48.6% |
|              | 24+                  | 148 | 17.5% |
| Semestre     | 2°-4°                | 240 | 28.3% |
|              | 5°-7°                | 383 | 45.2% |
|              | 8°-10°               | 224 | 26.5% |
| Universidad  | UNI (Perú)           | 312 | 36.8% |
|              | UTN (Argentina)      | 287 | 33.9% |
|              | Uniandes (Colombia)  | 248 | 29.3% |
|              | Sistemas/Computación | 290 | 34.2% |
| Especialidad | Civil                | 187 | 22.1% |
|              | Industrial           | 167 | 19.7% |
|              | Mecánica             | 113 | 13.4% |
|              | Otras                | 90  | 10.6% |

## IV. RESULTADOS

#### A. Estadísticos Descriptivos

Los estadísticos descriptivos de las variables principales se presentan en la Tabla 2. La puntuación media de dependencia a la IA fue de 2.87 (DE=0.94) en una escala de 1-5, indicando niveles moderados de dependencia en la muestra. La capacidad de resolución de problemas complejos mostró una media de 3.42 (DE=0.78). La frecuencia de uso de ChatGPT reveló que 67.4% de estudiantes lo utilizaban al menos semanalmente, con un 23.8% de uso diario.

Las correlaciones bivariadas mostraron asociaciones significativas entre las variables principales. La dependencia a la IA correlacionó negativamente con la capacidad de RPC ( $r=-0.47$ ,  $p<.001$ ), autoeficacia académica ( $r=-0.38$ ,  $p<.001$ ) y

conciencia metacognitiva ( $r=-0.44$ ,  $p<.001$ ). La frecuencia de uso de ChatGPT mostró correlación positiva moderada con dependencia a la IA ( $r=0.52$ ,  $p<.001$ ) y correlación negativa con RPC ( $r=-0.31$ ,  $p<.001$ ).

TABLA II  
ESTADÍSTICOS DESCRIPTIVOS Y CORRELACIONES DE VARIABLES PRINCIPALES

| Variable                    | M    | DE   | 1     | 2     | 3     | 4     | 5     | 6 |
|-----------------------------|------|------|-------|-------|-------|-------|-------|---|
| 1. Dependencia a IA         | 2.87 | 0.94 | —     |       |       |       |       |   |
| 2. Resolución Problemas     | 3.42 | 0.78 | .47** | —     |       |       |       |   |
| 3. Frecuencia uso ChatGPT   | 3.54 | 1.23 | .52** | .31** | —     |       |       |   |
| 4. Autoeficacia académica   | 3.68 | 0.72 | .38** | .54** | .22** | —     |       |   |
| 5. Conciencia metacognitiva | 3.51 | 0.81 | .44** | .61** | .28** | .58** | —     |   |
| 6. Estrés académico         | 3.12 | 0.89 | .41** | .35** | .33** | .42** | .39** | — |

\*\*p < .01. M = Media; DE = Desviación Estándar. Escalas 1-5 excepto Frecuencia uso ChatGPT (1-6).

#### B. Identificación de Perfiles mediante Clustering

El análisis de clustering K-means se realizó utilizando las puntuaciones estandarizadas de las tres subescalas de dependencia a la IA (funcional, emocional, cognitiva) y las cinco dimensiones de RPC. La determinación del número óptimo de clusters se basó en tres criterios: método del codo (inflexión en  $k=4$ ), coeficiente de silueta máximo (0.412 en  $k=4$ ), e índice de Davies-Bouldin mínimo (0.847 en  $k=4$ ). Los resultados convergen en una solución de cuatro clusters.

Los centroides de los cuatro clusters revelaron perfiles claramente diferenciados, detallados en la Tabla 3. El Cluster 1 (n=198, 23.4%) se caracteriza por puntuaciones bajas en dependencia a la IA y altas en RPC, denominándose 'Autonomistas Críticos'. El Cluster 2 (n=264, 31.2%), 'Integradores Equilibrados', muestra niveles moderados en ambas dimensiones. El Cluster 3 (n=242, 28.6%), 'Compensadores Dependientes', presenta una alta dependencia con capacidades de RPC en declive. El Cluster 4 (n=143, 16.8%), 'Delegadores Pasivos', exhibe la mayor dependencia y el deterioro más severo en RPC.

TABLA III  
CENTROIDES DE CLUSTERS Y CARACTERIZACIÓN DE PERFILES DE ESTUDIANTES

| Variable              | C1: Autonomistas Críticos (n=198) | C2: Integradores Equilibrados (n=264) | C3: Compensadores Dependientes (n=242) | C4: Delegadores Pasivos (n=143) | F       |
|-----------------------|-----------------------------------|---------------------------------------|----------------------------------------|---------------------------------|---------|
| Dependencia Funcional | -0.89                             | -0.12                                 | 0.54                                   | 1.23                            | 156.4** |
| Dependencia Emocional | -0.76                             | -0.08                                 | 0.47                                   | 1.18                            | 138.7** |
| Dependencia           | -0.94                             | -0.15                                 | 0.61                                   | 1.34                            | 172.    |

|                            |       |       |       |       |         |
|----------------------------|-------|-------|-------|-------|---------|
| Cognitiva                  |       |       |       |       | 3**     |
| Orientación Positiva       | 0.87  | 0.34  | -0.42 | -1.12 | 124.6** |
| Análisis Sistemático       | 0.92  | 0.28  | -0.38 | -1.08 | 131.2** |
| Razonamiento Lógico        | 0.85  | 0.31  | -0.45 | -1.15 | 127.8** |
| Pensamiento Metacognitivo  | 0.91  | 0.25  | -0.51 | -1.21 | 145.9** |
| Transferencia Conocimiento | 0.78  | 0.22  | -0.36 | -0.98 | 112.4** |
| % de muestra               | 23.4% | 31.2% | 28.6% | 16.8% | —       |

\*\*p < .001. Valores son puntuaciones z estandarizadas (M=0, DE=1). Coeficiente de silueta = 0.412; Índice Davies-Bouldin = 0.847.

### C. Caracterización de Perfiles

La Tabla 4 presenta la caracterización completa de los cuatro perfiles identificados en variables académicas, cognitivas y comportamentales. Los análisis ANOVA revelaron diferencias estadísticamente significativas entre clusters en todas las variables examinadas.

- 1) *Perfil 1 - Autonomistas Críticos*: Este grupo representa a los estudiantes que mantienen una independencia cognitiva frente a herramientas de IAG. Presentan el mayor rendimiento académico (GPA=3.78), la más alta autoeficacia (M=4.21) y conciencia metacognitiva (M=4.12). Reportan un uso selectivo y crítico de ChatGPT (M=2.14/6), principalmente para tareas de verificación o generación de ideas iniciales que luego desarrollan independientemente. El 78.3% indica que evalúa críticamente los outputs de IA antes de utilizarlos.
- 2) *Perfil 2 - Integradores Equilibrados*: Constituyen el grupo más numeroso, representando estudiantes que logran integrar herramientas de IAG preservando capacidades cognitivas fundamentales. Muestran un rendimiento académico sólido (GPA=3.42), niveles moderados de uso de ChatGPT (M=3.47/6), y mantienen estrategias metacognitivas funcionales (M=3.68). Este perfil utiliza IAG como complemento de su proceso de aprendizaje sin una delegación excesiva de procesos cognitivos.
- 3) *Perfil 3 - Compensadores Dependientes*: Este grupo muestra señales de alerta temprana de dependencia problemática. Reportan un uso frecuente de ChatGPT (M=4.23/6) y exhiben una dependencia funcional creciente. Su rendimiento académico permanece en un rango aceptable (GPA=2.89) pero muestran declive en capacidades de RPC y reducción de confianza en sus propias habilidades (autoeficacia M=3.12). El 62.4% reporta dificultad para completar tareas académicas sin asistencia de IA.
- 4) *Perfil 4 - Delegadores Pasivos*: Representa el grupo de mayor preocupación con dependencia severa a IAG. Exhiben el menor rendimiento académico (GPA=2.34), uso muy frecuente de ChatGPT

(M=5.12/6), y deterioro significativo en todas las dimensiones de RPC. Reportan una alta ansiedad ante indisponibilidad de herramientas de IA (M=4.23/5) y baja confianza en sus capacidades independientes (autoeficacia M=2.45). El 84.6% indica que no podría completar sus tareas académicas sin ChatGPT.

TABLA IV  
CARACTERIZACIÓN DETALLADA DE PERFILES EN VARIABLES ACADÉMICAS Y COGNITIVAS

| Variable                       | C1<br>Autonomistas      | C2<br>Integradores       | C3<br>Compensadores      | C4<br>Delegadores       | F       | η <sup>2</sup> |
|--------------------------------|-------------------------|--------------------------|--------------------------|-------------------------|---------|----------------|
| GPA (0-4)                      | 3.78 <sup>a</sup> (.42) | 3.42 <sup>b</sup> (.48)  | 2.89 <sup>c</sup> (.52)  | 2.34 <sup>d</sup> (.61) | 47.82** | .15            |
| Autoeficacia (1-5)             | 4.21 <sup>a</sup> (.52) | 3.68 <sup>b</sup> (.58)  | 3.12 <sup>c</sup> (.64)  | 2.45 <sup>d</sup> (.71) | 52.17** | .16            |
| Conciencia metacog. (1-5)      | 4.12 <sup>a</sup> (.48) | 3.68 <sup>b</sup> (.54)  | 2.94 <sup>c</sup> (.62)  | 2.31 <sup>d</sup> (.68) | 38.94** | .12            |
| Estrés académico (1-5)         | 2.34 <sup>d</sup> (.67) | 2.89 <sup>c</sup> (.72)  | 3.45 <sup>b</sup> (.78)  | 3.98 <sup>a</sup> (.84) | 34.67** | .11            |
| Frecuencia uso ChatGPT (1-6)   | 2.14 <sup>d</sup> (.89) | 3.47 <sup>b</sup> (1.02) | 4.23 <sup>b</sup> (1.08) | 5.12 <sup>a</sup> (.92) | 61.34** | .18            |
| Ansiedad sin IA (1-5)          | 1.67 <sup>d</sup> (.72) | 2.34 <sup>c</sup> (.81)  | 3.21 <sup>b</sup> (.87)  | 4.23 <sup>a</sup> (.76) | 58.92** | .17            |
| Edición de outputs (%)         | 78.3% <sup>a</sup>      | 56.4% <sup>b</sup>       | 32.1% <sup>c</sup>       | 12.8% <sup>d</sup>      | 45.23** | .14            |
| Evaluación crítica outputs (%) | 82.4% <sup>a</sup>      | 61.2% <sup>b</sup>       | 34.7% <sup>c</sup>       | 15.4% <sup>d</sup>      | 51.87** | .15            |

\*\*p < .001. Valores son M (DE). Superíndices diferentes indican diferencias significativas entre grupos (Tukey HSD, p < .05). η<sup>2</sup> = eta cuadrado parcial.

### D. Modelo de Ecuaciones Estructurales

La Tabla 5 muestra los detalles sobre el modelo de ecuaciones estructurales para examinar las relaciones causales entre la frecuencia de uso de ChatGPT, dependencia a IA, y capacidad de RPC. El modelo mostró un ajuste adecuado a los datos ( $\chi^2/df=2.18$ , CFI=0.95, TLI=0.93, RMSEA=0.048, SRMR=0.042). Los resultados confirmaron que la dependencia a la IA interactúa significativamente entre la relación de frecuencia de uso y la capacidad de RPC.

La frecuencia de uso de ChatGPT predijo positivamente la dependencia a la IA ( $\beta=0.54$ ,  $p<.001$ ), la cual a su vez predijo negativamente la capacidad de RPC ( $\beta=-0.56$ ,  $p<.001$ ). El efecto directo de frecuencia de uso sobre RPC fue no significativo ( $\beta=-0.08$ ,  $p=.12$ ), mientras que el efecto indirecto mediado por dependencia fue significativo ( $\beta=-0.30$ , IC 95%: [-0.38, -0.22]). Esto indica una mediación completa: el uso frecuente de ChatGPT impacta la capacidad de RPC principalmente a través del desarrollo de dependencia.

Variables adicionales incluidas en el modelo revelaron que la autoeficacia académica tiene un efecto protector, prediciendo negativamente la dependencia a la IA ( $\beta=-0.34$ ,  $p<.001$ ) y positivamente la capacidad de RPC ( $\beta=0.38$ ,  $p<.001$ ). El estrés académico mostró un efecto de riesgo, prediciendo positivamente la dependencia ( $\beta=0.29$ ,  $p<.001$ ). La conciencia metacognitiva surgió como un factor protector significativo tanto para prevenir la dependencia ( $\beta=-0.31$ ,  $p<.001$ ) como para preservar capacidades de RPC ( $\beta=0.42$ ,  $p<.001$ ).

TABLA V  
COEFICIENTES DEL MODELO DE ECUACIONES ESTRUCTURALES

| Relación                                            | $\beta$ | SE   | IC 95%         | p     |
|-----------------------------------------------------|---------|------|----------------|-------|
| Frecuencia ChatGPT → Dependencia IA                 | 0.54    | 0.04 | [0.46, 0.62]   | <.001 |
| Dependencia IA → Resolución Problemas               | -0.56   | 0.04 | [-0.64, -0.48] | <.001 |
| Frecuencia ChatGPT → Resolución Problemas (directo) | -0.08   | 0.05 | [-0.18, 0.02]  | .12   |
| Autoeficacia → Dependencia IA                       | -0.34   | 0.04 | [-0.42, -0.26] | <.001 |
| Autoeficacia → Resolución Problemas                 | 0.38    | 0.04 | [0.30, 0.46]   | <.001 |
| Estrés académico → Dependencia IA                   | 0.29    | 0.04 | [0.21, 0.37]   | <.001 |
| Conciencia metacognitiva → Dependencia IA           | -0.31   | 0.04 | [-0.39, -0.23] | <.001 |
| Conciencia metacognitiva → Resolución Problemas     | 0.42    | 0.04 | [0.34, 0.50]   | <.001 |
| Efecto indirecto (Frec → Dep → RPC)                 | -0.30   | 0.03 | [-0.38, -0.22] | <.001 |

$\beta$  = coeficiente estandarizado; SE = error estándar; IC = intervalo de confianza. Ajuste del modelo:  $\chi^2/df=2.18$ , CFI=0.95, TLI=0.93, RMSEA=0.048, SRMR=0.042.

#### IV. DISCUSIÓN

Este estudio proporciona una evidencia empírica novedosa sobre la relación entre dependencia a la IA generativa y capacidad de resolución de problemas complejos en estudiantes universitarios de ingeniería, identificando cuatro perfiles diferenciados mediante técnicas de aprendizaje automático. Los hallazgos tienen implicaciones significativas para la teoría, política educativa y práctica pedagógica.

##### A. Perfiles de Estudiantes y Patrones de Uso de IAG

La identificación de cuatro clusters diferenciados refina la comprensión de cómo los estudiantes interactúan con las herramientas de IAG. El hallazgo de que sólo un 23.4% de estudiantes mantienen una autonomía crítica ('Autonomistas Críticos'), mientras que, un 45.4% muestran niveles preocupantes de dependencia (Clusters 3 y 4) sugiere que la mayoría de usuarios no desarrollan espontáneamente prácticas de uso saludables. Este resultado es consistente con estudios previos que documentan el fenómeno de 'pereza metacognitiva' [5][7] y la tendencia a delegar procesos cognitivos de orden superior a sistemas de IA [8][37].

El perfil de 'Integradores Equilibrados' (31.2%) representa un modelo aspiracional de uso de IAG que logra beneficiarse de las herramientas sin minimizar las capacidades cognitivas fundamentales. Caracterizado por un uso moderado, evaluación crítica de outputs, y mantenimiento de estrategias metacognitivas funcionales, este perfil demuestra que la integración beneficiosa de IAG en prácticas académicas es posible [35][36].

Los perfiles de 'Compensadores Dependientes' y 'Delegadores Pasivos' representan poblaciones de riesgo que requieren una intervención. El hallazgo de que el 62.4% de Compensadores reportan dificultad para completar tareas sin IA y un 84.6% de Delegadores indican total dependencia constituye una evidencia alarmante del deterioro de autonomía cognitiva. Estos porcentajes son consistentes con las advertencias de Kasneci et al. [3] y Royer [12] sobre los riesgos de externalización del pensamiento crítico.

##### B. Mediación de la Dependencia a IA

El modelo de ecuaciones estructurales proporciona una evidencia de mediación completa: la frecuencia de uso de ChatGPT impacta la capacidad de RPC principalmente a través del desarrollo de dependencia (efecto indirecto  $\beta=-0.30$ ,  $p<.001$ ), más que directamente ( $\beta=-0.08$ ,  $p=.12$ ). Este hallazgo tiene implicaciones teóricas importantes: no es el uso de herramientas de IAG lo que deteriora las capacidades cognitivas, sino el desarrollo de patrones de dependencia caracterizados por una delegación acrítica, abandono de procesos metacognitivos, y reacciones de ansiedad ante la indisponibilidad.

Los efectos protectores de autoeficacia académica ( $\beta=-0.34$  sobre dependencia;  $\beta=0.38$  sobre RPC) y conciencia metacognitiva ( $\beta=-0.31$  y  $\beta=0.42$  respectivamente) sugieren vías prometedoras para su intervención. Estudiantes con mayor confianza en sus capacidades y mayor conciencia de sus procesos de pensamiento muestran una menor propensión a desarrollar dependencia y mayor preservación de habilidades de resolución de problemas. Estos resultados son consistentes con el modelo I-PACE [14][15] y estudios previos sobre factores protectores ante adicciones tecnológicas [18][19].

##### C. Implicaciones Educativas

Los hallazgos informan recomendaciones concretas para instituciones educativas. Primero, es necesario desarrollar políticas institucionales que reconozcan la heterogeneidad en patrones de uso de IAG, evitando tanto prohibiciones indiscriminadas como permisividad sin orientación. Segundo, programas de desarrollo de competencias metacognitivas y autoeficacia podrían funcionar como intervenciones preventivas ante el desarrollo de dependencia. Tercero, la formación docente debe incluir estrategias para diseñar tareas que promuevan un uso crítico de IAG, integración reflexiva y preservación de procesos cognitivos de orden superior.

Específicamente, se recomienda: (1) implementar instrumentos de screening como EDIAU-15 para la identificación temprana de estudiantes en riesgo de dependencia; (2) diseñar intervenciones diferenciadas por perfil, enfocando recursos intensivos en estudiantes de Clusters 3 y 4; (3) promover prácticas de 'uso guiado' donde la IAG funcione como herramienta de scaffolding más que sustituto de pensamiento; (4) establecer espacios curriculares libres de IAG para ejercitar capacidades de resolución de problemas independiente; y (5) fomentar reflexión metacognitiva sobre procesos de uso de IAG.

##### D. Limitaciones y Direcciones Futuras

Este estudio presenta limitaciones que deben considerarse. El diseño transversal impide establecer una causalidad definitiva; además que los estudios longitudinales son necesarios para examinar trayectorias de desarrollo de dependencia y deterioro cognitivo. La muestra, aunque diversa geográficamente, se limitó a estudiantes de ingeniería, restringiendo generalización a otras disciplinas. Las medidas

de RPC fueron auto-reportadas; futuras investigaciones deberían incluir evaluaciones de rendimiento objetivo mediante simulaciones tipo MicroDYN. Finalmente, el estudio se centró en ChatGPT; la generalización a otras herramientas de IAG requiere investigación adicional.

Investigaciones futuras deberían: (1) implementar diseños longitudinales para capturar trayectorias de desarrollo; (2) examinar la efectividad de intervenciones diferenciadas por perfil; (3) incluir evaluaciones neuropsicológicas de funcionamiento cognitivo; (4) explorar factores culturales y contextuales que influyen en patrones de dependencia; y (5) desarrollar algoritmos predictivos para identificación temprana de estudiantes en riesgo.

## V. CONCLUSIONES

Este estudio proporciona una evidencia empírica robusta sobre la existencia de perfiles diferenciados de estudiantes universitarios según su dependencia a la IA generativa y capacidad de resolución de problemas complejos. La aplicación de clustering K-means identificó cuatro perfiles: Autonomistas Críticos (23.4%), Integradores Equilibrados (31.2%), Compensadores Dependientes (28.6%) y Delegadores Pasivos (16.8%).

Los hallazgos principales incluyen que (1) aproximadamente un 45% de estudiantes muestran niveles preocupantes de dependencia a IAG con deterioro asociado en capacidades cognitivas; (2) la dependencia a IA interviene completamente entre la relación de la frecuencia de uso de ChatGPT y la capacidad de resolución de problemas ( $\beta$  indirecto=-0.30,  $p<.001$ ); (3) la autoeficacia académica y conciencia metacognitiva funcionan como factores protectores significativos; y (4) existen diferencias sustanciales entre los perfiles en rendimiento académico, bienestar y funcionamiento cognitivo.

Estos resultados tienen implicaciones importantes para la política educativa y práctica pedagógica. Se recomienda implementar sistemas de identificación temprana de estudiantes en riesgo; desarrollar intervenciones diferenciadas por perfil; promover estrategias de uso crítico e integración reflexiva de IAG; y fortalecer competencias metacognitivas y autoeficacia como factores protectores. El desafío para las instituciones educativas es aprovechar el potencial de las herramientas de IAG mientras se preservan las capacidades cognitivas fundamentales que definen la formación profesional de calidad.

## AGRADECIMIENTO

Los autores agradecen a las autoridades de las universidades participantes por facilitar el acceso a poblaciones estudiantiles. Se reconoce el apoyo de los equipos de investigación en cada institución para la recolección de datos. Agradecemos también a los estudiantes que voluntariamente participaron en el estudio.

## REFERENCES

- [1] Y.K. Dwivedi et al., "Opinion paper: 'So what if ChatGPT wrote it?' Multidisciplinary perspectives on opportunities, challenges and implications," *Int. J. Inf. Manage.*, vol. 71, 102642, Aug. 2023. doi: 10.1016/j.ijinfomgt.2023.102642
- [2] CNNIC, "The 55th Statistical Report on China's Internet Development," China Internet Network Information Center, Beijing, Jan. 2025.
- [3] E. Kasneci et al., "ChatGPT for good? On opportunities and challenges of large language models for education," *Learn. Individ. Differ.*, vol. 103, 102274, Apr. 2023. doi: 10.1016/j.lindif.2023.102274
- [4] C.K.Y. Chan and K.K.W. Lee, "The AI generation gap: Are Gen Z students more interested in adopting ChatGPT?," *Educ. Inf. Technol.*, 2024. doi: 10.1007/s10639-023-12337-y
- [5] X.Y. Wei et al., "Societal impacts of chatbot and mitigation strategies for negative impacts: A large-scale qualitative survey of ChatGPT users," *Technol. Soc.*, vol. 77, 102566, 2024. doi: 10.1016/j.techsoc.2024.102566
- [6] C. Royer, "Outsourcing humanity? ChatGPT, critical thinking, and the crisis in higher education," *Stud. Philos. Educ.*, vol. 43, pp. 479-497, 2024. doi: 10.1007/s11217-024-09946-3
- [7] M. Abbas et al., "ChatGPT produces more 'lazy' thinkers: Evidence of cognitive offloading," *arXiv:2507.00181*, Jul. 2025.
- [8] Anthropic Research, "Student interaction patterns with Claude: Cognitive offloading concerns," Anthropic Technical Report, 2025.
- [9] World Economic Forum, "The Future of Jobs Report 2023," WEF, Geneva, 2023.
- [10] A. Fischer, S. Greiff, and J. Funke, "The process of solving complex problems," *J. Probl. Solving*, vol. 4, no. 1, pp. 19-42, 2012. doi: 10.7771/1932-6246.1118
- [11] World Economic Forum, "Future of Jobs Report 2025," WEF, Geneva, Jan. 2025.
- [12] C. Royer, "Outsourcing humanity? ChatGPT, critical thinking, and the crisis in higher education," *Stud. Philos. Educ.*, vol. 43, pp. 479-497, 2024. doi: 10.1007/s11217-024-09946-3
- [13] C.K.Y. Lo, K.F. Hew, and M.S.Y. Jong, "The influence of ChatGPT on student engagement: A systematic review and future research agenda," *Comput. Educ.*, vol. 219, 105100, 2024. doi: 10.1016/j.compedu.2024.105100
- [14] M. Brand et al., "The Interaction of Person-Affect-Cognition-Execution (I-PACE) model for addictive behaviors," *Neurosci. Biobehav. Rev.*, vol. 106, pp. 1-10, 2019. doi: 10.1016/j.neubiorev.2018.06.012
- [15] M. Brand et al., "Integrating psychological and neurobiological considerations regarding the development and maintenance of specific Internet-use disorders," *Neurosci. Biobehav. Rev.*, vol. 71, pp. 252-266, 2016. doi: 10.1016/j.neubiorev.2016.08.033
- [16] H. Choi et al., "Do you have AI dependency? The roles of academic self-efficacy, academic stress, and performance expectations on problematic AI usage behavior," *Int. J. Educ. Technol. High. Educ.*, vol. 21, art. 34, May 2024. doi: 10.1186/s41239-024-00467-0
- [17] W. Chen et al., "From assistance to reliance: Development and validation of the large language model dependence scale," *Int. J. Inf. Manage.*, vol. 79, 102829, Feb. 2025. doi: 10.1016/j.ijinfomgt.2025.102829
- [18] C.S. Caplan, "Problematic Internet use and psychosocial well-being," *Comput. Hum. Behav.*, vol. 18, pp. 553-575, 2002. doi: 10.1016/S0747-5632(02)00004-3
- [19] K.S. Young, "Internet addiction: The emergence of a new clinical disorder," *Cyberpsychol. Behav.*, vol. 1, no. 3, pp. 237-244, 1998. doi: 10.1089/cpb.1998.1.237
- [20] W.C. Morales-García et al., "Development and validation of a scale for dependence on artificial intelligence in university students," *Front. Educ.*, vol. 9, 1323898, Mar. 2024. doi: 10.3389/educ.2024.1323898
- [21] H. Yu et al., "Problematic ChatGPT Use Scale: AI-Human Collaboration or Unraveling the Dark Side," *Int. J. Ment. Health Addict.*, Jun. 2025. doi: 10.1007/s11469-025-01509-y
- [22] W. Chen et al., "From assistance to reliance: Development and validation of the large language model dependence scale," *Int. J. Inf. Manage.*, vol. 79, 102829, 2025. doi: 10.1016/j.ijinfomgt.2025.102829
- [23] B. Hu et al., "How social anxiety leads to problematic use of conversational AI," *Comput. Hum. Behav.*, vol. 145, 107760, 2023. doi: 10.1016/j.chb.2023.107760
- [24] A. Paz et al., "Generative artificial intelligence dependency: Scale development, validation, and its motivational, behavioral, and

- psychological correlates," *Telemat. Inform.*, Oct. 2025. doi: 10.1016/j.tele.2025.102124
- [25] J. Funke, "Complex problem solving: A case for complex cognition?," *Cogn. Process.*, vol. 11, no. 2, pp. 133-142, 2010. doi: 10.1007/s10339-009-0345-0
- [26] S. Greiff et al., "Complex problem solving in educational contexts," *Educ. Res. Rev.*, vol. 18, pp. 74-83, 2016. doi: 10.1016/j.edurev.2015.12.001
- [27] D.H. Jonassen, "Toward a design theory of problem solving," *Educ. Technol. Res. Dev.*, vol. 48, no. 4, pp. 63-85, 2000. doi: 10.1007/BF02300500
- [28] B.S. Bloom et al., *Taxonomy of Educational Objectives, Handbook I: The Cognitive Domain*. New York: David McKay, 1956.
- [29] T.J. D'Zurilla, A.M. Nezu, and A. Maydeu-Olivares, "Social Problem-Solving Inventory-Revised (SPSI-R)," *Multi-Health Systems*, 2002.
- [30] P.P. Heppner and C.H. Petersen, "The development and implications of a personal problem-solving inventory," *J. Couns. Psychol.*, vol. 29, no. 1, pp. 66-75, 1982. doi: 10.1037/0022-0167.29.1.66
- [31] S. Greiff et al., "MicroDYN: A highly valid complex problem-solving assessment," *Comput. Educ.*, vol. 57, pp. 1312-1322, 2011. doi: 10.1016/j.compedu.2011.01.010
- [32] A. Meißner et al., "Predicting Complex Problem Solving and school grades with working memory and ability self-concept," *Learn. Individ. Differ.*, vol. 49, pp. 323-331, 2016. doi: 10.1016/j.lindif.2016.04.006
- [33] L. Castellanos and M. Rojas, "Problem-solving: Development and validation of a short instrument for higher education," *Front. Educ.*, vol. 10, 1555167, Apr. 2025. doi: 10.3389/educ.2025.1555167
- [34] R. Avello et al., "ChatGPT and cognitive load reduction in critical thinking tasks," *Comput. Educ.*, vol. 217, 105063, 2024. doi: 10.1016/j.compedu.2024.105063
- [35] G. van den Berg and E. du Plessis, "ChatGPT and generative AI: Possibilities for its contribution to lesson planning, critical thinking and openness in teacher education," *Educ. Sci.*, vol. 13, 998, 2023. doi: 10.3390/educsci13100998
- [36] H.B. Essel et al., "ChatGPT effects on cognitive skills of undergraduate students," *Comput. Educ. Artif. Intell.*, vol. 6, 100198, Jun. 2024. doi: 10.1016/j.caeai.2023.100198
- [37] C. Ododo, E. Essien, and G. Bassey, "Students using ChatGPT without instructional support struggled with tasks requiring abstraction," *Proc. CELDA 2023*, pp. 377-385, 2023.
- [38] M. Jošt, M. Taneski, and S. Karakatic, "Students who frequently relied on ChatGPT for critical tasks exhibited poorer performance," *Proc. CHI EA 2024*, art. 102, 2024. doi: 10.1145/3706599.3719841
- [39] A. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, 4067721, Apr. 2024. doi: 10.1155/2024/4067721
- [40] H. Romero-Romero et al., "Uncovering student profiles: An explainable cluster analysis approach to PISA 2022," *Comput. Educ.*, vol. 222, 105163, Sep. 2024. doi: 10.1016/j.compedu.2024.105163
- [41] J. MacQueen, "Some methods for classification and analysis of multivariate observations," *Proc. 5th Berkeley Symp. Math. Stat. Prob.*, vol. 1, pp. 281-297, 1967.
- [42] D.L. Davies and D.W. Bouldin, "A cluster separation measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 1, no. 2, pp. 224-227, 1979. doi: 10.1109/TPAMI.1979.4766909
- [43] X. Li and S. He, "Research and analysis of student portrait based on campus big data," *Proc. IEEE 6th ICBDA*, pp. 23-27, 2021. doi: 10.1109/ICBDA51983.2021.9403136
- [44] Y. Zhou et al., "A machine learning based method for constructing group profiles of university students," *Heliyon*, vol. 10, e29181, Apr. 2024. doi: 10.1016/j.heliyon.2024.e29181
- [45] A. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, 4067721, 2024. doi: 10.1155/2024/4067721
- [46] H. Romero-Romero et al., "Uncovering student profiles: An explainable cluster analysis approach to PISA 2022," *Comput. Educ.*, vol. 222, 105163, 2024. doi: 10.1016/j.compedu.2024.105163
- [47] L. Raftopoulos et al., "Machine Learning in Education: Predicting Student Performance and Guiding Institutional Decisions," *Education*, vol. 16, no. 1, 76, 2025. doi: 10.3390/education16010076
- [48] T. Nielsen et al., "Academic Self-Efficacy Scale," *Assessment*, vol. 25, no. 3, pp. 347-356, 2018. doi: 10.1177/1073191117711113
- [49] P. Akanni and G. Oduaran, "Academic stress and self-efficacy on academic performance," *Psychol. Rep.*, vol. 121, no. 6, pp. 1143-1159, 2018. doi: 10.1177/0033294118773312
- [50] G.S. Schraw and R.S. Dennison, "Assessing metacognitive awareness," *Contemp. Educ. Psychol.*, vol. 19, no. 4, pp. 460-475, 1994. doi: 10.1006/ceps.1994.1033