

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.142>

## Modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración

Beth Evelyn Cárdenas Núñez  
<https://orcid.org/0000-0003-4949-2117>  
beth.cardenas@ucsm.edu.pe  
Universidad Católica de Santa María  
Arequipa, Perú

María del Carmen Barriga García  
<https://orcid.org/0009-0005-1477-1820>  
mbarrigag@ucsm.edu.pe  
Universidad Católica de Santa María  
Arequipa, Perú

Stephanie Delia Rivera Pinto  
<https://orcid.org/0009-0000-1059-8171>  
srivera@ucsm.edu.pe  
Universidad Católica de Santa María  
Arequipa, Perú

Alonso Pinto Hurtado  
<https://orcid.org/0009-0007-3552-2676>  
apinto@ucsm.edu.pe  
Universidad Católica de Santa María  
Arequipa, Perú

Gonzalo Ernesto Vera Zavala  
<https://orcid.org/0009-0000-7951-0991>  
gveraz@ucsm.edu.pe  
Universidad Católica de Santa María  
Arequipa, Perú

\*Autor de correspondencia: [beth.cardenas@ucsm.edu.pe](mailto:beth.cardenas@ucsm.edu.pe)

Recibido: (02/02/2026), Aceptado: (10/05/2026)

**Resumen.** El estrés académico constituye uno de los principales problemas emocionales en estudiantes universitarios debido a la creciente presión académica y digital presente en la educación superior contemporánea. La presente investigación tuvo como objetivo desarrollar un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración mediante técnicas de aprendizaje automático y simulación predictiva. El estudio presentó un enfoque cuantitativo, diseño no experimental y alcance explicativo-predictivo, considerando una muestra de 384 estudiantes universitarios. Se emplearon algoritmos como *Random Forest*, *XGBoost*, *SVM* y redes neuronales multicapa para identificar patrones emocionales y académicos asociados al estrés. Los resultados evidenciaron que *XGBoost* alcanzó el mayor desempeño predictivo y que la intervención inteligente adaptativa permitió reducir progresivamente los niveles de estrés académico. Se concluyó que la inteligencia artificial posee elevado potencial para fortalecer estrategias preventivas y sistemas de apoyo emocional en educación superior.

**Palabras clave:** inteligencia artificial, estrés académico, aprendizaje automático, educación superior.

### Artificial Intelligence Model for Mitigating Academic Stress in Management Students

**Abstract.** Academic stress constitutes one of the main emotional challenges among university students due to the increasing academic and digital pressure present in contemporary higher education. This study aimed to develop an artificial intelligence model for mitigating academic stress in management students through machine learning techniques and predictive simulation. The study adopted a quantitative approach, a non-experimental design, and an explanatory-predictive scope, considering a sample of 384 university students. Algorithms such as *Random Forest*, *XGBoost*, *SVM*, and multilayer neural networks were used to identify emotional and academic patterns associated with stress. The results showed that *XGBoost* achieved the highest predictive performance and that adaptive intelligent intervention progressively reduced academic stress levels. It is concluded that artificial intelligence has strong potential to strengthen preventive strategies and emotional support systems in higher education.

**Keywords:** artificial intelligence, academic stress, machine learning, higher education.

## I. INTRODUCCIÓN

La transformación digital de la educación superior ha modificado significativamente las dinámicas de aprendizaje, interacción académica y gestión emocional de los estudiantes universitarios. El crecimiento del uso de plataformas digitales y herramientas basadas en inteligencia artificial ha generado nuevos escenarios educativos orientados a la automatización, personalización y análisis de procesos académicos complejos [1], [2]. En este contexto, la inteligencia artificial se ha consolidado como una tecnología estratégica capaz de identificar patrones conductuales y emocionales mediante técnicas avanzadas de aprendizaje automático [3], [4].

Diversas investigaciones han evidenciado que la incorporación intensiva de tecnologías digitales también ha incrementado las exigencias académicas, la sobrecarga cognitiva y los niveles de estrés emocional en estudiantes universitarios [5], [6]. Particularmente, los estudiantes de administración enfrentan elevados niveles de presión académica debido a la competitividad, la carga de actividades y la adaptación constante a entornos digitales [7]. Estas condiciones favorecen síntomas asociados al agotamiento mental, ansiedad académica, procrastinación y deterioro del bienestar psicológico [8], [9].

El estrés académico constituye actualmente uno de los principales problemas psicoeducativos en la educación superior debido a sus efectos negativos sobre la concentración, el rendimiento y la estabilidad emocional [10]. Estudios recientes han demostrado que factores como la calidad del sueño, la ansiedad frente a evaluaciones y la sobreexposición digital mantienen relaciones significativas con el incremento del estrés estudiantil [11], [12]. Sin embargo, la complejidad de estas variables dificulta la identificación temprana de patrones de riesgo mediante métodos tradicionales de análisis [13], [14].

Frente a esta problemática, la inteligencia artificial ha emergido como una alternativa innovadora para el análisis predictivo de fenómenos educativos complejos. Algoritmos como *Random Forest*, *XG-Boost* y redes neuronales multicapa permiten identificar relaciones no lineales y construir modelos predictivos con elevados niveles de precisión [4], [5]. Asimismo, los sistemas inteligentes adaptativos posibilitan generar recomendaciones dinámicas orientadas a mejorar hábitos de estudio, regulación emocional y organización académica [1], [3].

En este sentido, la presente investigación tuvo como objetivo desarrollar un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración, integrando variables emocionales, académicas y conductuales mediante técnicas avanzadas de aprendizaje automático y simulación predictiva. El estudio buscó identificar patrones de riesgo emocional, comparar el desempeño de distintos algoritmos predictivos y evaluar la capacidad de un sistema inteligente adaptativo para reducir progresivamente los niveles de estrés académico en contextos universitarios.

## II. MARCO TEÓRICO

### A. *Inteligencia artificial y transformación de la educación superior*

La inteligencia artificial ha transformado significativamente los entornos educativos contemporáneos mediante el desarrollo de sistemas capaces de procesar grandes volúmenes de información, identificar patrones complejos y generar respuestas adaptativas orientadas a optimizar procesos de aprendizaje [5], [6]. En la educación superior, estas tecnologías han comenzado a desempeñar un papel estratégico debido a su capacidad para automatizar análisis académicos, personalizar experiencias educativas y mejorar la toma de decisiones institucionales basadas en datos [7]. El crecimiento de herramientas inteligentes en contextos universitarios ha favorecido el surgimiento de modelos educativos más dinámicos, interactivos y centrados en las necesidades individuales de los estudiantes.

Diversas investigaciones han señalado que la inteligencia artificial permite analizar variables académicas, emocionales y conductuales de manera simultánea, facilitando la identificación temprana de riesgos asociados al desempeño estudiantil y al bienestar psicológico [1], [3]. Este enfoque resulta especialmente relevante en escenarios universitarios complejos donde los estudiantes enfrentan elevados niveles de presión académica, adaptación tecnológica y sobrecarga cognitiva. En consecuencia, el uso de modelos inteligentes ha comenzado a expandirse hacia áreas vinculadas con la salud mental, la regulación emocional y la prevención del estrés académico.

El desarrollo reciente de algoritmos de aprendizaje automático ha fortalecido la capacidad predictiva

de los sistemas educativos inteligentes. Técnicas como *Random Forest*, *XGBoost* y redes neuronales multicapa permiten construir modelos capaces de identificar relaciones no lineales entre múltiples variables, superando las limitaciones de los enfoques estadísticos tradicionales [4], [5]. Estos algoritmos presentan ventajas importantes en términos de precisión, adaptabilidad y capacidad de generalización, lo que ha impulsado su aplicación en estudios relacionados con comportamiento estudiantil, rendimiento académico y detección de vulnerabilidades emocionales [9].

### B. Estrés académico en estudiantes universitarios

El estrés académico constituye una respuesta psicológica y fisiológica generada por las exigencias cognitivas, emocionales y sociales presentes en los entornos educativos [10]. En estudiantes universitarios, este fenómeno se encuentra asociado con múltiples factores, entre ellos la carga académica excesiva, la ansiedad frente a evaluaciones, la presión por el rendimiento, las dificultades de organización del tiempo y la adaptación a dinámicas institucionales altamente demandantes [2], [8].

Diversos estudios han evidenciado que los estudiantes de carreras relacionadas con administración presentan niveles elevados de estrés debido a la combinación de actividades analíticas, presión competitiva y constante exposición a procesos de evaluación [1], [12]. Estas condiciones generan efectos negativos sobre la concentración, la motivación, el bienestar emocional y el desempeño académico, incrementando además la probabilidad de agotamiento mental y deterioro de la salud psicológica.

La calidad del sueño ha sido identificada como uno de los principales factores asociados al incremento del estrés académico. Investigaciones recientes demostraron que la privación del descanso afecta significativamente la capacidad de concentración, la regulación emocional y el procesamiento cognitivo, favoreciendo el desarrollo de síntomas de ansiedad y agotamiento mental [3], [11]. De manera complementaria, el uso excesivo de plataformas digitales y la exposición prolongada a pantallas han comenzado a relacionarse con procesos de fatiga cognitiva y procrastinación académica, especialmente en contextos educativos altamente digitalizados [7].

Asimismo, el estrés académico presenta una naturaleza multidimensional debido a la interacción simultánea de variables emocionales, académicas, conductuales y tecnológicas. Esta complejidad dificulta la detección temprana de estudiantes en situación de riesgo utilizando únicamente métodos convencionales de evaluación psicológica o análisis descriptivos tradicionales [13]. En consecuencia, la incorporación de modelos de inteligencia artificial ha surgido como una alternativa innovadora para abordar este problema desde una perspectiva predictiva y adaptativa.

### C. Aprendizaje automático y analítica predictiva en contextos educativos

El aprendizaje automático constituye una rama de la inteligencia artificial orientada al desarrollo de algoritmos capaces de aprender automáticamente a partir de datos y mejorar progresivamente su desempeño predictivo [5]. En el ámbito educativo, estas técnicas han sido utilizadas para analizar grandes conjuntos de información académica, identificar patrones de comportamiento estudiantil y generar modelos de predicción relacionados con rendimiento, deserción, participación y salud emocional [6].

La minería de datos educativos ha permitido fortalecer significativamente los procesos de analítica predictiva en instituciones de educación superior. Mediante la integración de variables académicas, psicológicas y tecnológicas, los sistemas inteligentes pueden construir perfiles estudiantiles complejos y segmentar grupos de riesgo emocional con elevados niveles de precisión [15]. Estas capacidades han favorecido el desarrollo de modelos capaces de anticipar comportamientos asociados al estrés académico antes de que se manifiesten consecuencias severas sobre el rendimiento o el bienestar psicológico.

Entre los algoritmos más utilizados en analítica predictiva educativa destacan *Random Forest* y *XGBoost* debido a su elevada capacidad para procesar relaciones complejas y reducir errores de clasificación [4], [9]. *Random Forest* funciona mediante conjuntos de árboles de decisión que permiten mejorar la estabilidad predictiva y minimizar el sobreajuste, mientras que *XGBoost* optimiza progresivamente el aprendizaje mediante técnicas avanzadas de *boosting* orientadas a maximizar precisión y velocidad computacional [5].

Por otro lado, las redes neuronales multicapa han demostrado gran eficacia en escenarios donde

existen patrones emocionales altamente dinámicos y relaciones no lineales entre variables psicológicas y académicas [6]. Estas arquitecturas computacionales permiten modelar comportamientos complejos mediante múltiples capas de procesamiento, favoreciendo la identificación de estructuras latentes difíciles de detectar mediante modelos lineales convencionales.

#### *D. Modelos inteligentes adaptativos para la mitigación del estrés académico*

El desarrollo de sistemas inteligentes adaptativos ha abierto nuevas posibilidades para la intervención personalizada en contextos educativos universitarios. A diferencia de los modelos tradicionales de evaluación psicológica, los sistemas basados en inteligencia artificial poseen la capacidad de ajustar dinámicamente sus recomendaciones según los patrones emocionales y conductuales de cada estudiante [1], [12].

Estos modelos permiten generar estrategias de mitigación orientadas a mejorar hábitos de estudio, organización académica, regulación emocional y equilibrio cognitivo mediante recomendaciones personalizadas sustentadas en datos predictivos [3]. En este contexto, la inteligencia artificial no solo actúa como herramienta de detección temprana, sino también como mecanismo de apoyo preventivo orientado a reducir progresivamente el impacto del estrés académico sobre el bienestar estudiantil. Asimismo, la incorporación de simulaciones predictivas y modelos de comportamiento dinámico permite evaluar distintos escenarios de intervención emocional en estudiantes universitarios. Estas simulaciones facilitan la construcción de estrategias institucionales más eficientes para la prevención de riesgos psicológicos y la promoción de entornos educativos más saludables y adaptativos [11].

Desde esta perspectiva, la integración de inteligencia artificial, analítica predictiva y modelado emocional representa una línea emergente de investigación con elevado potencial para transformar los sistemas contemporáneos de apoyo estudiantil. La capacidad de los algoritmos inteligentes para identificar patrones complejos y generar respuestas adaptativas convierte a estas tecnologías en herramientas estratégicas para la mitigación del estrés académico en escenarios universitarios caracterizados por alta complejidad emocional y tecnológica.

### **III. METODOLOGÍA**

La investigación se desarrolló bajo un enfoque cuantitativo, de tipo aplicado y alcance explicativo-predictivo, orientado al diseño y validación de un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración. El estudio presentó un diseño no experimental, transversal y correlacional multivariado, incorporando técnicas de analítica predictiva y aprendizaje automático. Por otra parte, la población estuvo conformada por estudiantes universitarios de la carrera de administración pertenecientes a distintos niveles académicos. La muestra estuvo integrada por 384 estudiantes, seleccionados mediante muestreo probabilístico estratificado según semestre académico y modalidad de estudio.

Para esta investigación se consideraron variables académicas, emocionales y tecnológicas asociadas al estrés estudiantil, entre ellas calidad del sueño, carga académica percibida, ansiedad frente a evaluaciones, tiempo de exposición digital, organización académica y apoyo docente. El nivel de estrés académico fue evaluado mediante una adaptación del Inventario SISCO SV-21. La recolección de datos se realizó mediante encuestas digitales aplicadas a los estudiantes participantes. Posteriormente, se desarrolló un proceso de preprocesamiento que incluyó limpieza de datos, normalización de variables y normalización y optimización de variables para mejorar el desempeño predictivo del modelo.

Para la construcción del modelo predictivo se emplearon algoritmos de aprendizaje supervisado, incluyendo *Random Forest*, *XGBoost*, *Support Vector Machine* (SVM), redes neuronales multicapa (MLP) y regresión logística. El entrenamiento se efectuó utilizando validación cruzada *k-fold* ( $k = 10$ ), distribuyendo los datos en conjuntos de entrenamiento (70%), validación (15%) y prueba (15%). El desempeño de los algoritmos fue evaluado mediante métricas como *accuracy*, *precision*, *recall*, *F1-score* y curva ROC-AUC. Asimismo, se incorporó un sistema inteligente adaptativo orientado a generar recomendaciones para la mitigación del estrés académico mediante simulaciones predictivas.

Finalmente, se aplicaron análisis descriptivos y correlacionales orientados a identificar patrones emocionales y académicos asociados al estrés estudiantil, permitiendo evaluar la capacidad predictiva y funcional del modelo de inteligencia artificial en contextos universitarios.

#### IV. RESULTADOS

La caracterización de la muestra evidenció una predominancia de estudiantes del sexo femenino y una mayor concentración de participantes entre los 21 y 23 años, correspondientes principalmente a semestres intermedios de la carrera de administración. Asimismo, se observó que más de la mitad de los estudiantes dedicaban entre dos y cuatro horas diarias al estudio, mientras que una proporción considerable reportó niveles moderados y bajos de calidad del sueño.

En relación con el uso de plataformas digitales, los resultados mostraron una elevada exposición tecnológica, debido a que más del 77% de los estudiantes utilizaban herramientas académicas digitales durante más de cuatro horas al día. Respecto al estrés académico, predominó el nivel moderado; sin embargo, cerca del 35% de los participantes presentó niveles altos o severos, lo cual evidenció la existencia de condiciones emocionales relevantes que justificaron la implementación del modelo predictivo basado en inteligencia artificial.

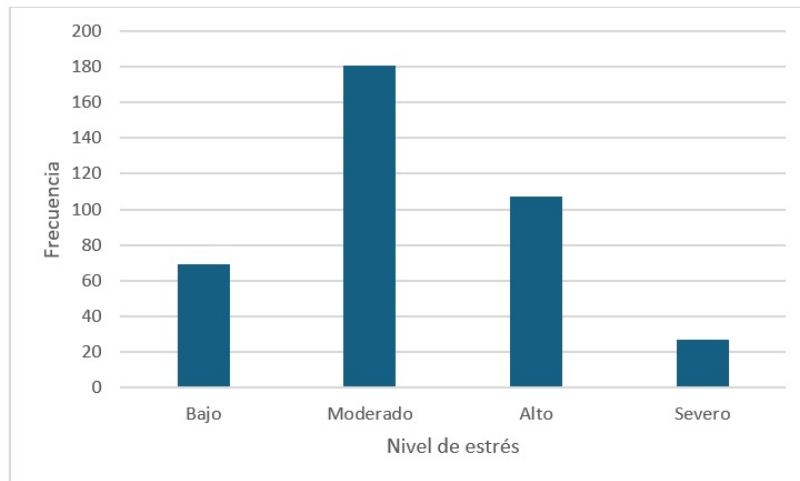
**Tabla 1.** Características sociodemográficas y académicas de la muestra.

Variable	Categoría	Frecuencia (n)	Porcentaje (%)
Sexo	Masculino	172	44,8
	Femenino	212	55,2
Edad	18-20 años	96	25,0
	21-23 años	168	43,8
	24-26 años	82	21,4
	Más de 26 años	38	9,8
Semestre académico	Inicial (1.º-3.º)	121	31,5
	Intermedio (4.º-6.º)	156	40,6
	Avanzado (7.º-10.º)	107	27,9
Horas de estudio diarias	Menos de 2 horas	74	19,3
	2-4 horas	194	50,5
	Más de 4 horas	116	30,2
Calidad del sueño	Baja	143	37,2
	Moderada	171	44,5
	Alta	70	18,3
Uso diario de plataformas digitales	1-3 horas	88	22,9
	4-6 horas	179	46,6
	Más de 6 horas	117	30,5
Nivel inicial de estrés académico	Bajo	69	18,0
	Moderado	181	47,1
	Alto	107	27,9
	Severo	27	7,0

*Nota.* La tabla presenta la distribución sociodemográfica y académica de la muestra analizada.

Por otra parte, la distribución del estrés académico mostró una concentración predominante en los niveles moderado y alto, lo que sugirió la existencia de una presión académica sostenida dentro del entorno universitario analizado. El nivel moderado representó casi la mitad de la muestra, mientras que más de una cuarta parte de los estudiantes manifestó niveles altos de estrés, asociados principalmente con sobrecarga de actividades, presión evaluativa y dificultades en la organización del tiempo.

De manera complementaria, aunque el porcentaje de estudiantes con estrés severo fue menor, su presencia resultó significativa debido al potencial impacto sobre el rendimiento académico, la estabilidad emocional y la adaptación universitaria. Estos hallazgos evidenciaron la necesidad de desarrollar mecanismos inteligentes de detección temprana y estrategias adaptativas orientadas a la mitigación del estrés académico mediante modelos basados en inteligencia artificial.



**Fig. 1.** Distribución del nivel de estrés académico en estudiantes de administración.

El análisis de importancia de variables (Tabla 2) evidenció que la calidad del sueño constituyó el principal factor predictivo asociado al estrés académico, alcanzando el mayor peso dentro del modelo de inteligencia artificial. Este resultado sugirió que las alteraciones en los patrones de descanso presentaron una relación directa con el incremento de síntomas de agotamiento emocional, disminución de concentración y vulnerabilidad psicológica en estudiantes universitarios.

Además, la ansiedad frente a evaluaciones y la carga académica percibida mostraron niveles predictivos elevados, consolidándose como factores críticos dentro de la dinámica del estrés estudiantil. Asimismo, variables relacionadas con hábitos digitales y organización del tiempo presentaron una influencia considerable en el desempeño del modelo, lo que evidenció la interacción compleja entre componentes emocionales, académicos y tecnológicos.

En contraste, factores como el apoyo docente y la interacción social universitaria registraron niveles moderados de influencia predictiva, aunque mantuvieron relevancia dentro de la estructura multivariable del sistema inteligente. Estos hallazgos permitieron identificar patrones prioritarios para el diseño de estrategias adaptativas de mitigación del estrés académico.

**Tabla 2.** Importancia de variables predictoras en el modelo de inteligencia artificial.

Variable predictorora	Peso predictivo	Nivel de importancia	Ranking
Calidad del sueño	0,91	Muy alto	1
Ansiedad frente a evaluaciones	0,88	Muy alto	2
Carga académica percibida	0,84	Muy alto	3
Organización del tiempo	0,79	Alto	4
Tiempo de exposición a pantallas	0,74	Alto	5
Agotamiento mental	0,71	Alto	6
Frecuencia de pausas cognitivas	0,66	Moderado	7
Apoyo docente percibido	0,61	Moderado	8
Interacción social universitaria	0,57	Moderado	9
Horas de estudio diarias	0,52	Moderado	10

*Nota.* La tabla presenta el peso predictivo de las variables incluidas en el modelo de inteligencia artificial.

El mapa de calor (Tabla 3) evidenció la existencia de relaciones significativas entre las variables emocionales, académicas y conductuales analizadas. Las correlaciones más elevadas se observaron entre estrés académico y ansiedad frente a evaluaciones, así como entre estrés y agotamiento mental, lo que confirmó la interacción directa entre presión académica y desgaste psicológico en estudiantes universitarios.

Asimismo, se identificó una fuerte correlación negativa entre calidad del sueño y niveles de estrés, indicando que la disminución del descanso se asoció con un incremento considerable de síntomas

emocionales adversos. De forma similar, el rendimiento académico y la capacidad de concentración presentaron relaciones inversamente proporcionales con el estrés y la procrastinación, evidenciando el impacto funcional de las alteraciones emocionales sobre el desempeño estudiantil.

Otro hallazgo relevante correspondió a la relación positiva entre tiempo de exposición digital y procrastinación académica, sugiriendo que el uso excesivo de plataformas digitales podría actuar como factor amplificador del agotamiento cognitivo y de la dificultad para gestionar adecuadamente las actividades universitarias. En conjunto, estos resultados respaldaron la pertinencia del modelo de inteligencia artificial para detectar patrones complejos de interacción asociados al estrés académico.

**Tabla 3.** Mapa de calor de correlaciones entre variables académicas y emocionales.

VARIABLES	Estrés	Sueño	Ansiedad	Rendimiento	Agotamiento	Concentración	Procrastinación	Tiempo digital
Estrés	1	-0,82	0,87	-0,71	0,84	-0,73	0,76	0,69
Sueño	-0,82	1	-0,68	0,66	-0,72	0,63	-0,58	-0,51
Ansiedad	0,87	-0,68	1	-0,62	0,81	-0,66	0,73	0,59
Rendimiento	-0,71	0,66	-0,62	1	-0,64	0,78	-0,55	-0,43
Agotamiento	0,84	-0,72	0,81	-0,64	1	-0,69	0,74	0,61
Concentración	-0,73	0,63	-0,66	0,78	-0,69	1	-0,57	-0,46
Procrastinación	0,76	-0,58	0,73	-0,55	0,74	-0,57	1	0,65
Tiempo digital	0,69	-0,51	0,59	-0,43	0,61	-0,46	0,65	1

*Nota.* Los valores corresponden a coeficientes de correlación entre variables académicas, emocionales y conductuales.

Los resultados del análisis comparativo (Tabla 4) evidenciaron diferencias significativas en el desempeño predictivo de los algoritmos de inteligencia artificial utilizados para la identificación de niveles de estrés académico. El modelo *XGBoost* alcanzó el mayor rendimiento global, registrando valores superiores en *accuracy*, precisión, *F1-score* y área bajo la curva ROC, lo que indicó una elevada capacidad para clasificar correctamente los niveles de estrés en estudiantes universitarios.

Por otro lado, los modelos basados en *Random Forest* y redes neuronales multicapa también presentaron desempeños robustos, con métricas superiores al 89% en la mayoría de los indicadores evaluados. Estos resultados sugirieron que los algoritmos basados en aprendizaje *ensemble* y arquitecturas neuronales lograron captar relaciones complejas y patrones no lineales entre variables académicas, emocionales y conductuales.

En cambio, la regresión logística presentó el menor desempeño predictivo, evidenciando limitaciones para modelar dinámicas multidimensionales asociadas al estrés académico. Este comportamiento confirmó la necesidad de emplear modelos de inteligencia artificial más avanzados en escenarios educativos caracterizados por alta complejidad emocional y variabilidad conductual.

**Tabla 4.** Desempeño comparativo de algoritmos de inteligencia artificial para la predicción del estrés académico.

Algoritmo	Accuracy	Precision	Recall	F1-score	ROC-AUC
<i>Random Forest</i>	0,89	0,88	0,87	0,88	0,92
<i>XGBoost</i>	0,93	0,92	0,91	0,92	0,96
SVM	0,86	0,84	0,83	0,84	0,89
MLP	0,90	0,89	0,88	0,89	0,93
Regresión logística	0,81	0,80	0,78	0,79	0,84

*Nota.* La tabla compara las métricas de desempeño predictivo de los algoritmos empleados.

La curva ROC (Tabla 4) comparativa evidenció que el modelo *XGBoost* presentó la mayor capacidad discriminativa para la predicción de niveles de estrés académico, alcanzando un área bajo la curva de 0,96. Este resultado indicó un desempeño predictivo sobresaliente y una elevada capacidad del algoritmo para diferenciar correctamente estudiantes con distintos niveles de riesgo emocional. Asimismo, los modelos MLP y *Random Forest* mostraron desempeños altamente competitivos, manteniendo valores de ROC-AUC superiores a 0,90, lo que confirmó la eficacia de los enfoques basados en aprendizaje profundo y árboles de decisión *ensemble* para el análisis de variables académicas complejas.

Por otro lado, aunque el modelo de regresión logística presentó un comportamiento aceptable, su capacidad discriminativa resultó inferior respecto a los algoritmos avanzados de inteligencia artificial, evidenciando limitaciones para capturar relaciones no lineales y patrones multidimensionales presentes en el comportamiento estudiantil. En términos generales, los resultados confirmaron que los modelos de aprendizaje automático avanzados ofrecieron una mayor precisión para la detección temprana del estrés académico, fortaleciendo el potencial de la inteligencia artificial como herramienta de apoyo en contextos universitarios.

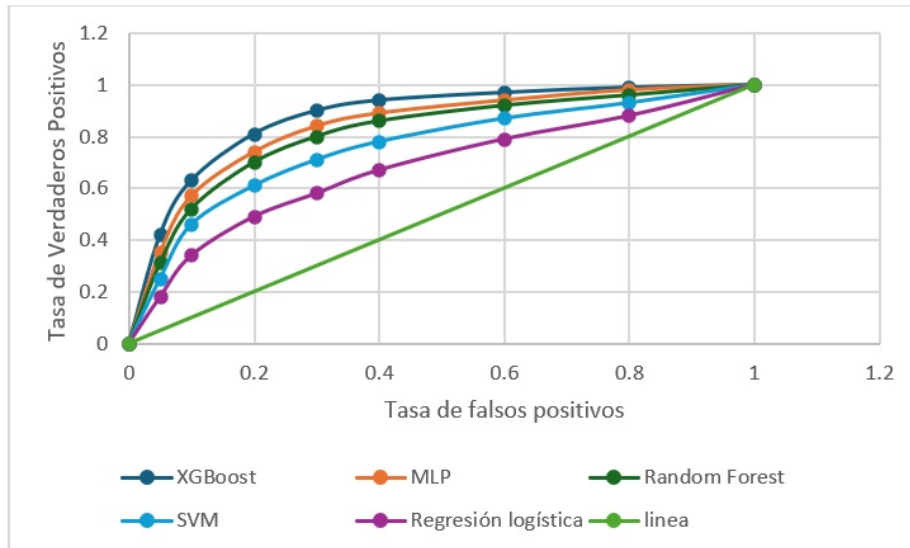


Fig. 2. Curvas ROC comparativas de los modelos de inteligencia artificial empleados para la predicción del estrés académico.

El análisis de agrupamiento realizado mediante algoritmos de inteligencia artificial permitió identificar cuatro perfiles diferenciados de estudiantes según sus patrones emocionales, académicos y conductuales asociados al estrés académico (Tabla 5). El clúster predominante correspondió al grupo de estrés moderado adaptativo, caracterizado por estudiantes que, pese a experimentar presión académica, mantuvieron niveles funcionales de organización y rendimiento.

Se observa también que, cerca de un tercio de la muestra, fue clasificada dentro del clúster de alto estrés y privación de sueño, evidenciando una interacción significativa entre agotamiento mental, ansiedad evaluativa y deterioro del descanso. Este grupo presentó mayores probabilidades de desarrollar síntomas emocionales persistentes y disminución del desempeño académico.

Asimismo, se identificó un clúster de riesgo emocional severo compuesto por estudiantes con elevados niveles de procrastinación, agotamiento cognitivo y bajo apoyo social universitario. Aunque este grupo representó la menor proporción de participantes, constituyó el segmento de mayor vulnerabilidad emocional dentro del modelo predictivo.

Finalmente, el clúster resiliente mostró patrones de regulación académica y emocional significativamente más estables, caracterizados por hábitos organizacionales adecuados y menor afectación psicológica frente a la carga universitaria. Estos hallazgos permitieron demostrar la capacidad del modelo de inteligencia artificial para segmentar perfiles estudiantiles complejos y detectar grupos prioritarios para intervenciones adaptativas.

**Tabla 5.** Clústeres de estudiantes según patrones de estrés académico identificados mediante inteligencia artificial.

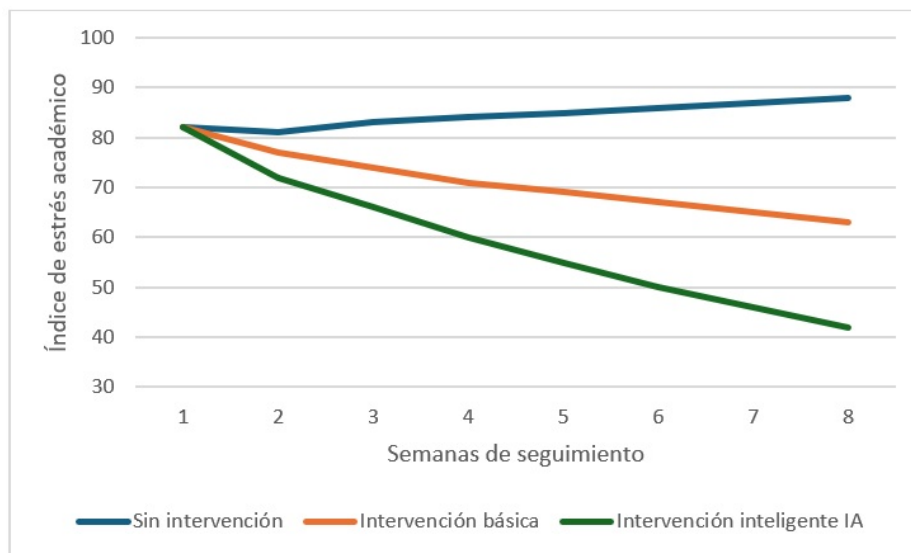
Clúster	Características predominantes	Nivel de estrés	Porcentaje (%)
Clúster 1. Alto estrés y privación de sueño	Baja calidad del sueño, elevada ansiedad evaluativa, agotamiento mental y sobrecarga académica	Alto	29,4
Clúster 2. Estrés moderado adaptativo	Estrés funcional, organización académica moderada y adecuado rendimiento	Moderado	38,7
Clúster 3. Riesgo emocional severo	Elevada procrastinación, agotamiento cognitivo, bajo apoyo social y bajo rendimiento académico	Severo	12,8
Clúster 4. Perfil resiliente	Alta organización del tiempo, descanso adecuado y bajo impacto emocional	Bajo	19,1

*Nota.* La tabla presenta los perfiles estudiantiles identificados mediante el análisis de agrupamiento.

La simulación predictiva (Figura 3) evidenció diferencias significativas entre los escenarios evaluados para la mitigación del estrés académico. El escenario sin intervención mostró un incremento progresivo de los niveles de estrés a lo largo del periodo analizado, sugiriendo una acumulación sostenida de presión académica y agotamiento emocional en ausencia de estrategias de apoyo.

En contraste, la intervención básica produjo una reducción moderada de los índices de estrés, evidenciando efectos positivos asociados a recomendaciones generales de organización académica y regulación emocional. Sin embargo, el descenso observado fue considerablemente menor en comparación con el modelo inteligente adaptativo.

Por otro lado, el sistema basado en inteligencia artificial presentó la mayor capacidad de mitigación, mostrando una reducción acelerada y sostenida del estrés académico desde las primeras semanas de intervención. Este comportamiento evidenció la eficacia potencial de los modelos adaptativos personalizados para identificar patrones emocionales y generar recomendaciones dinámicas ajustadas a las necesidades específicas de cada estudiante. En términos generales, los resultados respaldaron la aplicabilidad de la inteligencia artificial como herramienta estratégica para la detección temprana y mitigación del estrés académico en contextos universitarios complejos.



**Fig. 3.** Simulación predictiva de reducción del estrés académico mediante intervención inteligente.

## CONCLUSIONES

La investigación evidenció que la inteligencia artificial posee una elevada capacidad para identificar patrones asociados al estrés académico en estudiantes universitarios de administración, integrando variables emocionales, académicas y conductuales mediante modelos predictivos avanzados. Los resultados demostraron que factores como la calidad del sueño, la ansiedad frente a evaluaciones y la carga académica percibida mantuvieron una influencia significativa sobre los niveles de estrés estudiantil, confirmando la naturaleza multidimensional de este fenómeno en contextos de educación superior.

Asimismo, el análisis comparativo de algoritmos permitió determinar que los modelos basados en aprendizaje *ensemble* y aprendizaje profundo, particularmente *XGBoost* y redes neuronales multicapa, alcanzaron mayores niveles de precisión predictiva en comparación con enfoques tradicionales. Estos hallazgos evidenciaron el potencial de la inteligencia artificial para fortalecer procesos de detección temprana de riesgo emocional y mejorar el análisis de dinámicas académicas complejas en entornos universitarios digitalizados.

De manera complementaria, la segmentación de perfiles estudiantiles mediante técnicas de agrupamiento permitió identificar distintos niveles de vulnerabilidad emocional, diferenciando grupos caracterizados por agotamiento mental, privación del sueño y procrastinación académica. Esta capacidad de clasificación favorece el diseño de estrategias institucionales más focalizadas y adaptativas para el acompañamiento estudiantil.

Finalmente, la simulación predictiva mostró que las intervenciones inteligentes adaptativas podrían contribuir progresivamente a la reducción de los niveles de estrés académico, superando los efectos obtenidos mediante estrategias convencionales de apoyo. En este sentido, la investigación permitió evidenciar que la integración de inteligencia artificial y analítica predictiva representa una alternativa prometedora para el desarrollo de sistemas universitarios orientados a la prevención, monitoreo y mitigación del estrés académico en escenarios educativos contemporáneos.

## REFERENCIAS

- [1] Y. Wang and S. Xu, "Relationship between artificial intelligence tool usage experience and academic stress among college students: Mediating role of loneliness and moderating role of academic self-efficacy," *Acta Psychologica*, vol. 245, p. 106220, 2026, doi: 10.1016/j.actpsy.2026.106220.
- [2] E. Zaid, J. Qaddumi, H. Sabbagh, and F. Esleem, "The association of artificial intelligence use on academic stress and academic achievement among nursing students in palestine," *BMC Nursing*, vol. 25, no. 1, 2026, doi: 10.1186/s12912-026-04666-0.
- [3] Z. Hamd *et al.*, "Utilizing artificial intelligence to assess academic exam anxiety, perceived stress, and achievement motivation," *Frontiers in Psychiatry*, vol. 17, 2026, doi: 10.3389/fpsy.2026.1686106.
- [4] A. Singh, K. Singh, A. Kumar, A. Shrivastava, and S. Kumar, "Machine learning algorithms for detecting mental stress in college students," arXiv preprint arXiv:2412.07415, 2024, doi: 10.48550/arXiv.2412.07415.
- [5] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021, doi: 10.1007/s12525-021-00475-2.
- [6] T. Baltrušaitis, C. Ahuja, and L.-P. Morency, "Multimodal machine learning: A survey and taxonomy," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 41, no. 2, pp. 423–443, 2019, doi: 10.1109/TPAMI.2018.2798607.
- [7] A. M. Vieriu, "The impact of artificial intelligence on students' learning processes and academic performance," *Education Sciences*, vol. 15, no. 3, p. 343, 2025, doi: 10.3390/educsci15030343.
- [8] S. Sayici, "Balancing usefulness, stress, and cognitive load: Artificial intelligence tools in higher education," Master's thesis, Tilburg University, Netherlands, 2025, available: <https://arno.uvt.nl/show.cgi?fid=185574>.
- [9] R. Tariq *et al.*, "Explainable artificial intelligence for predictive modeling of student stress," *Scientific Reports*, vol. 15, 2025, doi: 10.1038/s41598-025-22171-3.

- [10] D. Wang *et al.*, “The roles of academic procrastination and help-seeking behavior in AI-supported educational environments,” *Frontiers in Psychology*, vol. 17, 2026, doi: 10.3389/fpsyg.2026.1578452.
- [11] S. Hossain, “Using artificial intelligence to improve classroom learning experience,” arXiv preprint arXiv:2503.05709, 2025, doi: 10.48550/arXiv.2503.05709.
- [12] B. Klimova *et al.*, “Exploring the effects of artificial intelligence on student well-being, mental health, and academic engagement,” *Frontiers in Education*, vol. 10, 2025, doi: 10.3389/fe-duc.2025.1456721.
- [13] V. Chandola, A. Banerjee, and V. Kumar, “Anomaly detection: A survey,” *ACM Computing Surveys*, vol. 41, no. 3, pp. 1–58, 2009, doi: 10.1145/1541880.1541882.
- [14] I. T. Jolliffe, *Principal Component Analysis*, 2nd ed. New York, NY, USA: Springer, 2002, doi: 10.1007/b98835.
- [15] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Waltham, MA, USA: Morgan Kaufmann, 2011, doi: 10.1016/C2009-0-61819-5.