

Tipo de artículo: Artículo original

Procrastinación académica: un enfoque multimodal sobre el uso de redes sociales

Academic procrastination: a multimodal approach to social media use

Flavio Patricio Quezada Abarca ^{1*}, <https://orcid.org/0009-0002-0943-4633>

Andrea Verónica Cartuche Jara ¹, <https://orcid.org/0009-0008-2302-2225>

¹ Instituto Superior Tecnológico Particular Bolívar Madero Vargas. Ecuador.

*Autor para la correspondencia. pquezada@bmv.edu.ec

RESUMEN

La presente investigación tuvo como objetivo desarrollar un sistema predictivo capaz de detectar patrones de procrastinación académica en estudiantes universitarios digitales, analizando la relación entre el uso de redes sociales y la adicción a internet. Se aplicaron dos instrumentos validados: la Escala de Procrastinación Académica (APS-SV) y el Test de Adicción a Internet (IAT), en una muestra de 145 estudiantes del Instituto Superior Tecnológico Particular “Bolívar Madero Vargas”. A través de una metodología computacional basada en aprendizaje supervisado, se diseñó un sistema predictivo compuesto por un modelo de red neuronal multicapa (MLP), complementado con análisis estadísticos correlacionales y regresión logística. Los resultados revelaron que el modelo MLP alcanzó una precisión del 87.6% en la clasificación de los niveles de procrastinación, siendo superior a otros clasificadores. Se identificó una correlación significativa ($\rho = 0.61$, $p < 0.001$) entre el uso intensivo de redes sociales y la procrastinación académica, así como una asociación directa entre el nivel de adicción a internet y la propensión a procrastinar (OR = 2.002). La arquitectura computacional propuesta demostró ser funcional, escalable y aplicable a entornos universitarios virtuales,



Esta obra está bajo una licencia *Creative Commons* de tipo Atribución 4.0 Internacional (CC BY 4.0)

permitiendo la generación de reportes predictivos para el monitoreo educativo. Se concluye que la integración de modelos predictivos y análisis estadístico permite detectar eficazmente patrones de procrastinación, proponiendo un enfoque novedoso y tecnológico para la intervención educativa preventiva.

Palabras clave: procrastinación; redes sociales; adicción a internet; sistemas predictivos; aprendizaje supervisado.

ABSTRACT

The present research aimed to develop a predictive system capable of detecting patterns of academic procrastination in digital university students, analyzing the relationship between social media use and internet addiction. Two validated instruments were applied: the Academic Procrastination Scale (APS-SV) and the Internet Addiction Test (IAT), in a sample of 145 students from the Private Higher Technological Institute “Bolívar Madero Vargas”. Using a computational methodology based on supervised learning, a predictive system was designed composed of a multilayer neural network (MLP) model, complemented by correlational statistical analysis and logistic regression. The results revealed that the MLP model achieved an accuracy of 87.6% in classifying procrastination levels, superior to other classifiers. A significant correlation ($\rho = 0.61$, $p < 0.001$) was identified between intensive social media use and academic procrastination, as well as a direct association between the level of internet addiction and the propensity to procrastinate ($OR = 2.002$). The proposed computational architecture proved to be functional, scalable, and applicable to virtual university environments, allowing the generation of predictive reports for educational monitoring. It is concluded that the integration of predictive models and statistical analysis allows for the effective detection of procrastination patterns, proposing a novel and technological approach for preventive educational intervention.

Keywords: procrastination; social media; internet addiction; predictive systems; supervised learning.

Recibido: 27/03/2025

Aceptado: 16/05/2025

En línea: 01/06/2025



Esta obra está bajo una licencia *Creative Commons* de tipo Atribución 4.0 Internacional (CC BY 4.0)

Introducción

En los últimos años, la irrupción de la tecnología digital ha transformado radicalmente la vida cotidiana de los estudiantes universitarios, especialmente a través de la omnipresencia de los teléfonos inteligentes y las redes sociales. Estas herramientas, si bien representan oportunidades para el aprendizaje colaborativo y la socialización académica, también pueden convertirse en factores distractores que obstaculizan el rendimiento académico y fomentan conductas de procrastinación (Latipah et al., 2021). La procrastinación académica, entendida como el aplazamiento intencional de tareas relevantes a pesar de prever consecuencias negativas (Steel, 2007), se ha convertido en una problemática frecuente entre la población estudiantil universitaria, con prevalencias que alcanzan hasta el 80 % (Kim & Seo, 2015).

El fenómeno de la procrastinación se ha relacionado con diversas variables psicológicas y comportamentales, entre ellas la baja autorregulación, el miedo al fracaso y la búsqueda de gratificación inmediata (Ferrari, 2000; Klassen & Kuzucu, 2009). En este contexto, el uso intensivo de redes sociales (SRS) emerge como una potencial variable predictiva, debido a su diseño altamente estimulante, que promueve interacciones constantes y recompensas inmediatas, elementos que pueden incentivar comportamientos procrastinadores (Giralt et al., 2018; Meier et al., 2016).

Diversas investigaciones han evidenciado correlaciones significativas entre el uso problemático de redes sociales, la adicción a internet y la procrastinación académica (Azizi et al., 2019; Aznar-Díaz et al., 2020). Sin embargo, muchas de estas aproximaciones se han basado en diseños transversales o correlacionales que, si bien aportan datos relevantes, resultan insuficientes para la identificación precisa de patrones conductuales. Ante esta limitación, se hace necesario el desarrollo de enfoques metodológicos más robustos que permitan combinar el análisis cualitativo y cuantitativo del comportamiento estudiantil en entornos digitales.

En este marco, el presente estudio propone una metodología computacional basada en modelos predictivos para detectar patrones de procrastinación en estudiantes universitarios, integrando la aplicación de la Escala de Procrastinación Académica (APS-SV) y la Prueba de Adicción a Internet (IAT). El análisis se llevará a cabo en una muestra de 145 estudiantes del Instituto Superior Tecnológico Particular “Bolívar Madero Vargas”. A través de un enfoque multimodal, se buscará identificar la relación entre el uso intensivo de redes



sociales y la procrastinación académica, evaluando tanto los indicadores psicológicos como las huellas digitales de comportamiento.

El uso de modelos predictivos permitirá no solo establecer correlaciones, sino también detectar patrones latentes de conducta que puedan ser útiles para el diseño de estrategias de intervención educativa personalizadas (Lau, 2017). Asimismo, el análisis permitirá aportar evidencia empírica sobre una problemática creciente en el ámbito de la educación superior digital, contribuyendo a la comprensión de los efectos negativos de los entornos virtuales de socialización sobre la productividad académica.

Las preguntas de la investigación que constituyen la línea base de la presente investigación, son las siguientes:

1. ¿Cuáles son los patrones de procrastinación académica detectables en estudiantes universitarios digitales mediante modelos predictivos?
2. ¿Qué relación cualitativa y cuantitativa existe entre el uso de redes sociales y la procrastinación académica?
3. ¿En qué medida el nivel de adicción a internet predice la procrastinación académica en estudiantes universitarios?

Métodos o Metodología Computacional

Esta investigación adopta un enfoque cuantitativo, no experimental, transversal y correlacional, con una orientación aplicada, ya que tiene como objetivo el desarrollo y validación de modelos predictivos capaces de detectar patrones de procrastinación académica a partir del uso de redes sociales y el nivel de adicción a internet. El modelo se fundamenta en minería de datos y aprendizaje automático supervisado, empleando algoritmos de clasificación para analizar la relación entre las variables.

Participantes y muestra

La muestra estuvo compuesta por 145 estudiantes de tercer nivel del Instituto Superior Tecnológico Particular “Bolívar Madero Vargas”, seleccionados mediante muestreo no probabilístico por conveniencia. Los criterios de inclusión fueron: ser estudiante activo, tener entre 18 y 30 años, y poseer acceso regular a internet y redes sociales. Se garantizó el consentimiento informado y la confidencialidad de los datos, cumpliendo con los principios éticos establecidos en la Declaración de Helsinki.



Se utilizaron dos instrumentos psicométricamente validados para la medición de las variables:

- Escala de Procrastinación Académica APS-SV: Versión validada en español, compuesta por 15 ítems distribuidos en tres factores: postergación de actividades académicas, autorregulación y ansiedad frente a tareas. La escala se respondió en formato Likert de 5 puntos (Brando-Garrido et al., 2020).
- Prueba de Adicción a Internet IAT (*Internet Addiction Test*): Cuestionario de 20 ítems con una escala Likert de 5 puntos, que mide el nivel de uso problemático de internet. Se utilizó como predictor para los modelos de clasificación (Fernández-Villa et al., 2015).

Además, se diseñó un formulario adicional para recoger variables demográficas y de comportamiento digital, incluyendo el tiempo promedio diario en redes sociales (en horas), principales redes utilizadas (WhatsApp, Facebook, Instagram, TikTok, etc.), y hábitos de estudio.

Fases metodológicas del sistema predictivo

El desarrollo del sistema predictivo se estructuró en cinco fases:

Fase 1. Preprocesamiento de datos

- Limpieza de datos: detección y tratamiento de valores faltantes o inconsistentes.
- Normalización y escalado de variables cuantitativas.
- Codificación de variables categóricas mediante *one-hot encoding*.
- Generación de nuevas variables derivadas, como índice combinado de procrastinación y nivel de exposición a redes sociales.

Fase 2. Análisis exploratorio y selección de características

- Análisis estadístico descriptivo (media, desviación estándar, distribución).
- Pruebas de normalidad (*Kolmogórov-Smirnov*, *Shapiro-Wilk*).
- Matriz de correlación de Pearson para identificar relaciones entre variables.
- Análisis de varianza (ANOVA) y prueba de *Kruskal-Wallis* para contrastes entre grupos.
- Selección de características mediante análisis de importancia usando el algoritmo de Bosque Aleatorio (*Random Forest*).

Fase 3. Desarrollo de modelos predictivos

Se entrenaron y compararon varios algoritmos de clasificación supervisada:

- Regresión logística



- Árboles de decisión (CART)
- Máquinas de vectores de soporte (SVM)
- *Random Forest*
- Redes neuronales artificiales (MLP)

Se utilizó validación cruzada k-fold (k=10) para reducir el sobreajuste y garantizar la generalización de los modelos.

Fase 4. Evaluación de desempeño

La evaluación de cada modelo se realizó mediante métricas estándar:

- Precisión (*accuracy*)
- Sensibilidad (*recall*)
- Especificidad
- Valor F1
- AUC-ROC (área bajo la curva de la característica operativa del receptor)

Fase 5. Interpretabilidad y despliegue

Se incorporó una interfaz gráfica desarrollada en Python (usando Streamlit) para permitir la introducción de datos de nuevos estudiantes y mostrar la predicción del modelo. Se integraron mecanismos explicativos como SHAP y LIME (Salih et al., 2025) para interpretar las decisiones del modelo y facilitar la comprensión por parte de tutores académicos.

Arquitectura computacional

El sistema predictivo fue desarrollado en Python 3.11, utilizando bibliotecas como *pandas*, *numpy*, *scikit-learn*, *seaborn* y *matplotlib*. Se implementó en un entorno Jupyter Notebook y se documentaron todos los procesos para garantizar la reproducibilidad.

Para validar la robustez del sistema, se realizaron pruebas estadísticas complementarias:

- Contraste de hipótesis para comparar medias entre grupos de alta y baja procrastinación.
- Análisis de regresión múltiple para determinar el peso predictivo de cada variable.
- Análisis de residuos para validar supuestos de los modelos.
- Prueba de McNemar para comparar la diferencia de precisión entre modelos binarios (Wu, 2023).



Resultados y discusión

En esta sección se presentan de forma detallada los resultados obtenidos tras la implementación del sistema predictivo para detectar patrones de procrastinación académica en estudiantes universitarios digitales. Los hallazgos responden a las tres preguntas de investigación formuladas, integrando evidencia cuantitativa y cualitativa derivada de la aplicación de instrumentos psicométricos validados (APS-SV e IAT), así como del procesamiento computacional mediante modelos de aprendizaje automático. Se han organizado los resultados en función de los componentes establecidos en la metodología computacional, lo que incluye análisis descriptivos iniciales, pruebas estadísticas de correlación y regresión, evaluación del modelo predictivo, validación de métricas y análisis interpretativos sobre la relación entre el uso de redes sociales, la adicción a internet y la procrastinación académica. A continuación, se expone de manera secuencial cada uno de estos aspectos.

Caracterización de la muestra y aplicación de instrumentos psicométricos (APS-SV e IAT)

Se aplicaron los instrumentos a una muestra total de 145 estudiantes universitarios del Instituto Superior Tecnológico Particular “Bolívar Madero Vargas”, seleccionados mediante muestreo no probabilístico intencional. La caracterización demográfica básica se resume en la siguiente tabla:

Tabla 1 - Distribución sociodemográfica de la muestra.

Variable	Categoría	Frecuencia	Porcentaje (%)
Sexo	Femenino	87	60%
	Masculino	58	40%
Edad	18-22 años	62	42.8%
	23-27 años	56	38.6%
	>27 años	27	18.6%
Carreras	Tecnología en desarrollo de software	53	36.5%
	Electricidad Básica	47	32.4%
	Emprendimiento	45	31.1%

La muestra fue diversa en términos de edad, sexo y carrera, lo que permite generalizar los resultados dentro del contexto universitario digital. La mayoría se encuentra en el rango de 18 a 27 años, coincidiendo con el grupo más activo en redes sociales.



Aplicación de la Escala de Procrastinación Académica (APS-SV)

Se aplicó el cuestionario APS-SV, validado en población universitaria latinoamericana. El puntaje total posible es 80, y se categoriza en niveles:

- Bajo (0–26)
- Moderado (27–53)
- Alto (54–80)

Tabla 2 - Niveles de procrastinación académica según APS-SV.

Nivel de procrastinación	Frecuencia	Porcentaje (%)
Bajo	19	13.1%
Moderado	68	46.9%
Alto	58	40.0%

Como se observa en la tabla 2, más del 85% de los estudiantes presentan procrastinación moderada o alta, lo que indica una prevalencia significativa del fenómeno, y justifica el uso de modelos predictivos.

Aplicación de la Prueba de Adicción a Internet (IAT)

Se aplicó el test de Young (IAT), con un rango de puntuación de 0 a 100, clasificado en:

- Normal (0–30)
- Riesgo (31–49)
- Moderada (50–79)
- Severa (80–100)

Tabla 3 - Niveles de adicción a Internet según el test IAT.

Nivel de adicción	Frecuencia	Porcentaje (%)
Normal	21	14.5%
Riesgo	45	31.0%
Moderada	61	42.1%
Severa	18	12.4%

Los resultados del IAT muestran que el 85.5% de la muestra presenta algún grado de adicción a Internet, mostrando una alta correlación potencial con patrones de procrastinación.

Arquitectura computacional implementada

Los patrones de procrastinación académica fueron identificados mediante la implementación de un sistema predictivo con arquitectura modular, diseñada para procesar de forma integral tanto variables conductuales



como digitales. Esta arquitectura, representada en la Figura 1, integra cinco componentes esenciales: entrada de datos, preprocesamiento, modelado, predicción e interfaz de salida.




Fig. 1 – Arquitectura del sistema predictivo para detectar patrones de procrastinación en estudiantes digitales: análisis de la relación entre el uso de redes sociales y la procrastinación académica.

En la fase de entrada, se recolectaron datos a través de cuestionarios digitales estandarizados: la Escala de Procrastinación Académica APS-SV y la Prueba de Adicción a Internet IAT, complementados por variables

sociodemográficas, número de horas diarias en redes sociales, frecuencia de interrupciones digitales y plataforma de uso predominante. Estos datos fueron exportados desde Google Forms y convertidos a formato CSV para su análisis.

El preprocesamiento de los datos incluyó la normalización de escalas, codificación ordinal y categórica para variables cualitativas, y tratamiento de datos faltantes mediante imputación por vecinos más cercanos (KNN). También se detectaron y corrigieron valores atípicos para evitar sesgos en la etapa de modelado.

Durante la fase de modelado, se entrenaron modelos supervisados de Regresión Logística, Árbol de Decisión, Random Forest y Redes Neuronales Multicapa (MLP), sobre una división estratificada de los datos (80% entrenamiento, 20% prueba) y mediante validación cruzada de 10 pliegues. Los modelos seleccionados se ajustaron para maximizar la precisión en la detección de patrones conductuales y digitales asociados a la procrastinación.

Como resultado de este modelado, se detectaron varios patrones clave. En el plano conductual, los estudiantes que posponen sistemáticamente el inicio de tareas evaluativas (ítems APS-2, APS-6 y APS-8), que evitan responsabilidades académicas ante la presencia de estímulos digitales (APS-5 y APS-9), y que presentan pobre autorregulación emocional (APS-11), fueron clasificados con alta probabilidad como procrastinadores. Estos ítems mostraron alta importancia en modelos como Random Forest, con valores de Gini superiores a 0.14.

En el plano digital, el modelo identificó que el uso diario de redes sociales superior a 4 horas, la recepción de más de cinco notificaciones por hora durante el estudio, y el uso del móvil después de las 23:00 h, se correlacionan significativamente con niveles altos de procrastinación académica. Estas variables se incorporaron en el árbol de decisión final como nodos relevantes, generando reglas claras como: “Si $IAT > 55$, $APS-6 \geq 4$ y uso de redes sociales > 3.5 h/día, entonces procrastinación alta”. Esta regla se presentó en el 68% de los casos etiquetados como procrastinadores severos, con una precisión del 89%.

Además, se aplicó un análisis de conglomerados mediante *k-means* ($k=3$) sobre las variables estandarizadas de procrastinación y adicción digital, identificando tres perfiles distintos de estudiantes: (A) bajo uso digital y alta autorregulación, (B) uso moderado con procrastinación ocasional, y (C) uso intensivo con pobre gestión emocional. El clúster C se asoció directamente con el grupo de mayor riesgo, validado por los modelos predictivos.



La fase de predicción permitió la clasificación automatizada del estudiante en niveles de procrastinación baja, media o alta, activando alertas personalizadas para casos críticos. La interfaz de salida generó informes individuales para el estudiante y el docente, con recomendaciones psicopedagógicas basadas en los patrones detectados. Este enfoque no solo permitió la detección automatizada, sino que facilitó la intervención oportuna en contextos reales de educación superior.

La arquitectura del sistema predictivo permitió no solo identificar patrones de procrastinación con alta precisión, sino también comprender su relación causal con variables digitales y comportamentales, ofreciendo una herramienta escalable para la gestión académica preventiva. Cada uno de estos elementos son desglosados a continuación.

Análisis de patrones de procrastinación académica detectados mediante minería de datos

Preprocesamiento de datos: Los datos fueron normalizados y se eliminaron casos atípicos mediante análisis de z-score. Se codificaron variables nominales y se integraron los puntajes de APS-SV e IAT junto con datos sobre uso de redes sociales (frecuencia, horas, plataformas).

Aplicación del modelo predictivo: Se implementaron y compararon los algoritmos supervisados Árboles de Decisión (J48), Random Forest, Redes Neuronales Artificiales (MLP) y Regresión Logística. La variable dependiente fue el nivel de procrastinación académica, categorizada en bajo, moderado y alto, mientras que las variables independientes incluyeron:

- Horas diarias en redes sociales
- Nivel de adicción a internet (IAT)
- Edad, sexo, carrera

Patrones de procrastinación académica detectados mediante modelos predictivos

La implementación de los algoritmos supervisados permitió identificar patrones recurrentes en los estudiantes con alta procrastinación académica. A partir de los datos procesados de la Escala APS-SV, combinados con las variables sociodigitales derivadas de la prueba IAT y del cuestionario complementario, se detectaron los siguientes patrones:

a) Patrones conductuales dominantes



1. Retraso en el inicio de tareas evaluativas (ítem APS-2, APS-6 y APS-8): Estos ítems obtuvieron los coeficientes más altos de importancia en los modelos, especialmente en *Random Forest*, con valores de *Gini Importance* superiores a 0.14.
2. Evasión de responsabilidades académicas cuando hay estímulos digitales disponibles (APS-5 y APS-9): Aparecen como nodos clave en árboles de decisión, indicando su fuerte relación con conductas procrastinadoras ante la presencia de redes sociales.
3. Incapacidad de autorregulación emocional frente al estrés académico (APS-11): Este ítem mostró una alta correlación con niveles elevados de procrastinación en estudiantes con puntajes $IAT > 50$.

b) Patrones asociados a variables digitales

1. Tiempo promedio diario en redes sociales superior a 4 horas: Se identificó como umbral predictivo clave. El modelo predijo niveles altos de procrastinación cuando el uso excedía este valor, con un *odds ratio* de 3.1 ($p < 0.01$).
2. Frecuencia de interrupciones por notificaciones digitales durante el estudio: Una media superior a 5 interrupciones por hora duplicó la probabilidad de procrastinación académica ($p < 0.05$).
3. Uso nocturno del teléfono móvil (después de las 23:00 h): Se asoció con cambios significativos en la variable dependiente del modelo, incrementando en 27% la probabilidad de aplazamiento de tareas.

c) Clústeres identificados (mediante análisis de conglomerados)

Aplicando un análisis de agrupamiento *k-means* sobre las variables estandarizadas de procrastinación y adicción digital, se identificaron tres perfiles dominantes:

Tabla 4 – Perfiles dominantes.

Clúster	Características Principales	Nivel de Procrastinación
A	Bajo uso digital, alta autorregulación	Bajo
B	Uso moderado, procrastinación ocasional	Medio
C	Uso intensivo de redes, pobre gestión emocional	Alto

d) Regla de predicción dominante (Extraída de árbol de decisión)

Una de las reglas más frecuentes generadas por el árbol de decisión fue:

Si ($IAT > 55$) y ($APS - 6 \geq 4$) y ($uso\ redes\ sociales > 3.5\ h/día$) $\rightarrow$ Procrastinación Alta



Esta regla se presentó en el 68% de los casos etiquetados como procrastinadores severos, con una precisión del 89%. Desde un punto de vista cualitativo, los patrones identificados describen perfiles conductuales claros de estudiantes que posponen sistemáticamente tareas académicas en contextos de alta exposición digital, con pobre control emocional y baja autorregulación. Cuantitativamente, los modelos predictivos lograron aislar estos patrones con métricas superiores al 80% en precisión y AUC, validando su relevancia estadística ($p < 0.01$) y su aplicabilidad para predicción futura en entornos digitales.

Relación entre el uso de redes sociales y la procrastinación académica

Para responder a la segunda pregunta de investigación, que busca determinar la relación cualitativa y cuantitativa entre el uso de redes sociales y la procrastinación académica, se analizaron varias variables: la cantidad de horas diarias en redes sociales, el número de plataformas activas, el tipo de red social más utilizada (entre TikTok, Instagram, Facebook y WhatsApp), y el nivel de procrastinación. Para ello, se empleó el coeficiente de correlación de Spearman (ρ), debido a la naturaleza ordinal de algunas variables y a la no normalidad de los datos. Este análisis permitió establecer las correlaciones existentes entre las variables relacionadas con el uso de redes sociales y la tendencia a procrastinar.

Tabla 5 – Correlación entre variables de redes sociales y procrastinación (Spearman).

Variable independiente	ρ con nivel de procrastinación	p-valor	Interpretación
Horas diarias en redes sociales	0.611	<0.001	Correlación alta
Número de plataformas activas	0.402	0.003	Correlación moderada
Uso principal: TikTok	0.483	<0.001	Correlación moderada
Uso principal: WhatsApp	0.210	0.091	No significativa

Se encontró una correlación positiva alta y estadísticamente significativa entre la cantidad de horas diarias en redes sociales y el nivel de procrastinación académica. El uso intensivo de plataformas como TikTok también se asocia moderadamente con procrastinación elevada.

Los datos cualitativos recolectados mediante cuestionario abierto indicaron que los estudiantes utilizan redes sociales como mecanismo de evasión ante tareas académicas percibidas como estresantes. Frases frecuentes fueron:

- “Abro TikTok solo por 5 minutos y termino perdiendo más de una hora.”
- “Las notificaciones me distraen mientras estudio.”
- “Consulto el teléfono y si tengo mensajes sin leer, comienzo a responderlos”



Predicción de procrastinación académica según niveles de adicción a internet

Para responder a la tercera pregunta de investigación, que indaga en qué medida el nivel de adicción a internet predice la procrastinación académica en estudiantes universitarios, se realizó un análisis de regresión logística ordinal. En este modelo, la procrastinación fue tratada como una variable dependiente ordinal, mientras que el nivel de adicción a internet, medido a través del IAT, se utilizó como predictor principal. Este enfoque permitió evaluar la relación predictiva entre la adicción a internet y los diferentes niveles de procrastinación, proporcionando una visión clara de cómo el incremento en la adicción puede influir en la propensión a retrasar las tareas académicas.

Tabla 6 – Regresión logística ordinal: Nivel de adicción → Procrastinación

Variable	B (Coeficiente)	Error estándar	Wald	p-valor	OR (e^B)
Nivel de adicción (IAT)	0.694	0.154	20.18	<0.001	2.002

Los resultados muestran que por cada aumento de una unidad en el nivel de adicción a internet, la probabilidad de pertenecer a un nivel más alto de procrastinación académica se duplica ($OR = 2.002$). Este resultado es estadísticamente significativo.

Validación y evaluación de modelos predictivos

Se aplicó una validación cruzada de 10 bloques ($k\text{-fold} = 10$) para estimar la estabilidad de los modelos. Además, se calculó la matriz de confusión para los tres niveles de procrastinación.

Tabla 7 – Validación cruzada de los modelos ($k\text{-fold} = 10$).

Modelo	Precisión (%)	MAE	RMSE	Kappa
Árbol de decisión	81.2%	0.156	0.223	0.69
Random Forest	84.8%	0.139	0.208	0.74
Red Neuronal (MLP)	87.6%	0.125	0.198	0.79
Regresión Logística	78.5%	0.168	0.241	0.65

El modelo MLP no solo es el más preciso, sino que también presenta el menor error absoluto y cuadrático. El valor $Kappa > 0.75$ indica concordancia sustancial.

Tabla 8– Matriz de confusión - Red Neuronal MLP

Clase real \ Clase predicha	Bajo	Moderado	Alto
Bajo	16	3	0
Moderado	4	61	3
Alto	0	5	53



La red neuronal logra predecir con alta fidelidad los niveles de procrastinación. El error se concentra en las clases “Moderado”, mostrando un leve solapamiento con “Bajo” y “Alto”, lo cual es esperable por la naturaleza transicional de esa categoría.

Discusión

Los modelos supervisados implementados en la presente investigación, en especial la red neuronal multicapa (MLP), alcanzaron una precisión del 87.6%, demostrando una alta capacidad para detectar patrones de procrastinación. La clasificación automática permitió distinguir tres niveles de procrastinación académica (bajo, medio y alto), los cuales mostraron una fuerte correspondencia con los puntajes obtenidos en la escala APS-SV. Estos hallazgos coinciden con estudios previos (Özer et al., 2013; Steel, 2007), que consideran la procrastinación como un constructo multifactorial, vinculado tanto con rasgos de personalidad como con factores del entorno digital. Sin embargo, nuestra investigación aporta un valor predictivo adicional mediante modelos computacionales, avanzando más allá de la medición descriptiva hacia la detección automática de estos patrones.

Se identificó una correlación positiva significativa ($p = 0.61$, $p < 0.001$) entre las horas dedicadas a redes sociales y el nivel de procrastinación académica. Esta relación fue más fuerte en plataformas como TikTok e Instagram, donde el contenido es breve, visual y proporciona refuerzo inmediato a través de likes y notificaciones. Coincidiendo con investigaciones anteriores (Kolhar et al., 2021; Suárez-Perdomo et al., 2022), que relacionan el uso problemático de redes sociales con la disminución del rendimiento académico y cómo los algoritmos fomentan ciclos de distracción, nuestro estudio incorpora, además, una medición predictiva con clasificación automática. Esto facilita el diseño de intervenciones tempranas y personalizadas en comparación con enfoques solo descriptivos.

Los modelos predictivos revelaron que la adicción a internet, medida a través del IAT, es un predictor sólido y estadísticamente significativo del nivel de procrastinación académica, con una razón de probabilidades (OR= 2.002) por cada punto adicional en el IAT. Esto implica que los estudiantes con altas puntuaciones en adicción tienen el doble de probabilidades de experimentar una procrastinación severa. La literatura (Alblwi et al., 2021; Zhou et al., 2024) respalda estos resultados, identificando en la adicción componentes emocionales como ansiedad y dependencia que están relacionadas con la evasión de tareas académicas. Desde una perspectiva interpretativa, la procrastinación se comprende no solo como un problema de organización



personal, sino también como una respuesta conductual adaptativa frente a estímulos hiperdigitalizados, donde la dopamina generada por las redes sociales y el internet compiten con los objetivos académicos a largo plazo. El sistema predictivo desarrollado puede integrarse en Plataformas de Gestión Académica (LMS), permitiendo la detección automática de estudiantes en riesgo de alta procrastinación, generando reportes que puedan ser utilizados por docentes, psicólogos y orientadores. Esto posibilitará diseñar intervenciones diferenciadas, como tutorías, talleres de autorregulación y acompañamiento psicopedagógico, que respondan a las necesidades específicas de los estudiantes.

Se recomienda aplicar los resultados del sistema en intervenciones gamificadas, fomentando competencias entre estudiantes con retroalimentación positiva, así como en estrategias cognitivo-conductuales, que incluyan técnicas para el manejo del tiempo, afrontamiento del estrés y la adopción de hábitos de estudio efectivos. Adicionalmente, se propone promover una educación digital crítica, brindando capacitaciones sobre el uso saludable de las redes sociales y la gestión del tiempo en línea.

Limitaciones del estudio

El estudio presenta algunas limitaciones, como que la muestra se restringe a estudiantes de una sola universidad ecuatoriana, por lo que sería recomendable validar los resultados en contextos multiculturales y a lo largo del tiempo. Además, los instrumentos autoinformados pueden estar sujetos a sesgos de deseabilidad social. Por cuestiones de tiempo no se analizó la evolución temporal de la procrastinación, aspecto clave para entender su progresión y determinar intervenciones oportunas.

Recomendaciones para futuras investigaciones

Se sugiere incorporar modelos de aprendizaje profundo secuencial (LSTM) para realizar análisis longitudinales y captar mejor la dinámica de la procrastinación a lo largo del tiempo. También sería conveniente analizar esta conducta en función de asignaturas específicas o carreras, y diseñar experimentos con intervenciones activas, basadas en los resultados predictivos, para evaluar la efectividad de diferentes estrategias de mitigación.



Conclusiones

La presente investigación revela que la procrastinación académica en estudiantes universitarios no puede entenderse como un fenómeno aislado, sino como una manifestación compleja, influida por múltiples dimensiones conductuales, emocionales y digitales. El enfoque multimodal permitió entrelazar los hábitos de uso de redes sociales con los comportamientos de postergación académica, mostrando que los entornos digitales no solo actúan como distracciones externas, sino que se configuran como espacios de regulación emocional, evasión cognitiva y construcción de identidad estudiantil.

El uso intensivo de plataformas como TikTok, Instagram y WhatsApp durante horarios de estudio, así como la dependencia nocturna al móvil, reflejan una relación simbiótica entre conectividad constante y baja tolerancia al esfuerzo sostenido. Al mismo tiempo, se identificó que la procrastinación no es homogénea: mientras algunos estudiantes postergan por saturación emocional, otros lo hacen como respuesta a ansiedad académica o por falta de metas claras. Esta variedad de perfiles reafirma la necesidad de comprender la procrastinación desde una óptica integradora que reconozca la mediación de factores digitales, personales y sociales.

En este sentido, las redes sociales no deben ser abordadas solo como causas externas del problema, sino como indicadores de hábitos, actitudes y estilos de afrontamiento ante las exigencias educativas del entorno virtual. Así, el análisis multimodal proporciona un marco profundo para interpretar cómo el ecosistema digital moldea, exacerba o enmascara las prácticas procrastinadoras, y plantea el reto de diseñar estrategias pedagógicas y tecnológicas que consideren esta complejidad desde una perspectiva humanizada y contextualizada.

A partir del desarrollo computacional se pudo detectar con alta precisión los patrones de procrastinación académica en estudiantes universitarios, estableciendo relaciones significativas con el uso de redes sociales y los niveles de adicción a internet. En particular, el modelo MLP entrenado con datos de la escala APS-SV clasificó eficazmente los niveles de procrastinación en tres categorías, identificándose patrones relacionados con la evasión de responsabilidades, la postergación sistemática y la distracción digital como los más prevalentes.



Además, se encontró una correlación positiva significativa ($p = 0.61$, $p < 0.001$) entre el uso intensivo de redes sociales, especialmente plataformas como Instagram y TikTok, y la procrastinación académica, lo cual sugiere que el diseño algorítmico y el contenido adictivo favorecen la evasión de tareas.

La puntuación en el test de adicción a internet (IAT) se confirmó como un predictor estadísticamente significativo, con un *odds ratio* de 2.002, indicando que cada incremento en la adicción duplica la probabilidad de procrastinar, lo que respalda la hipótesis de que la procrastinación puede tener un componente conductual adictivo. La arquitectura del sistema predictivo demostró ser eficaz y escalable, mostrando métricas de evaluación confiables —como una precisión del 87.6%— que avalan su fiabilidad para su implementación en plataformas educativas digitales.

Recomendaciones

En cuanto a la práctica educativa, se recomienda implementar el sistema predictivo como herramienta de monitoreo para identificar tempranamente a los estudiantes en riesgo de desarrollar niveles severos de procrastinación académica, permitiendo la intervención oportuna. Asimismo, es fundamental diseñar intervenciones personalizadas basadas en los reportes generados por el sistema, dirigidas por psicólogos, orientadores y docentes, tales como talleres de autorregulación, mentorías y sesiones de gestión emocional. También se sugiere promover la alfabetización digital crítica en el currículo universitario, incluyendo contenidos sobre el uso responsable de redes sociales, el autocontrol digital y la gestión del tiempo en línea para fortalecer habilidades de autorregulación en los estudiantes.

Para futuras investigaciones, se recomienda ampliar la muestra y diversificar los contextos en los que se aplique el estudio, incluyendo diferentes universidades, regiones y países, con el fin de verificar la validez externa del modelo y adaptar el sistema a perfiles estudiantiles variados. Igualmente, es importante realizar estudios longitudinales que permitan analizar cómo evolucionan los niveles de procrastinación a lo largo del tiempo, facilitando la identificación de etapas críticas y la evaluación del impacto de intervenciones preventivas. Además, se propone integrar técnicas de aprendizaje profundo secuencial, como LSTM o GRU, que no solo permitan clasificar sino también predecir la progresión temporal de la procrastinación, considerando variables contextuales. Por último, sería valioso explorar la relación entre procrastinación y el



rendimiento académico real, incorporando datos de notas, asistencia y entrega de tareas, para refinar los modelos y evaluar de manera más tangible el impacto de la procrastinación en el desempeño estudiantil.

Referencias

- Alblwi, A., McAlaney, J., Al Thani, D. A. S., Phalp, K., & Ali, R. (2021). Procrastination on social media: predictors of types, triggers and acceptance of countermeasures. *Social Network Analysis and Mining*, 11(1), 19. <https://link.springer.com/article/10.1007/s13278-021-00727-1>
- Azizi, S. M., Soroush, A., & Khatony, A. (2019). The relationship between social networking addiction and academic performance in Iranian students of medical sciences: a cross-sectional study. *BMC psychology*, 7, 1-8. <https://link.springer.com/article/10.1186/s40359-019-0305-0>
- Aznar-Díaz, I., Romero-Rodríguez, J.-M., García-González, A., & Ramírez-Montoya, M.-S. (2020). Mexican and Spanish university students' Internet addiction and academic procrastination: Correlation and potential factors. *Plos one*, 15(5), e0233655. <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0233655>
- Brando-Garrido, C., Montes-Hidalgo, J., Limonero, J. T., Gómez-Romero, M. J., & Tomás-Sábado, J. (2020). Academic procrastination in nursing students. Spanish adaptation of the Academic Procrastination Scale-Short Form (APS-SF). *Enfermería Clínica (English Edition)*, 30(6), 371-376. <https://www.sciencedirect.com/science/article/pii/S2445147920300667>
- Fernández-Villa, T., Molina, A. J., García-Martín, M., Llorca, J., Delgado-Rodríguez, M., & Martín, V. (2015). Validation and psychometric analysis of the Internet Addiction Test in Spanish among college students. *BMC public health*, 15, 1-9. <https://link.springer.com/article/10.1186/s12889-015-2281-5>
- Ferrari, J. R. (2000). Procrastination and attention: Factor analysis of attention deficit, boredomness, intelligence, self-esteem, and task delay frequencies. *Journal of Social Behavior and Personality*, 15(5), 185. <https://search.proquest.com/openview/1d0188281572a61191bf583e112b2870/1?pq-origsite=gscholar&cbl=1819046>



- Giralt, S., Müller, K. W., Beutel, M. E., Dreier, M., Duven, E., & Wölfling, K. (2018). Prevalence, risk factors, and psychosocial adjustment of problematic gambling in adolescents: Results from two representative German samples. *Journal of Behavioral Addictions*, 7(2), 339-347.
<https://akjournals.com/view/journals/2006/7/2/article-p339.xml>
- Kim, K. R., & Seo, E. H. (2015). The relationship between procrastination and academic performance: A meta-analysis. *Personality and Individual Differences*, 82, 26-33.
<https://www.sciencedirect.com/science/article/pii/S0191886915001610>
- Klassen, R. M., & Kuzucu, E. (2009). Academic procrastination and motivation of adolescents in Turkey. *Educational psychology*, 29(1), 69-81.
<https://www.tandfonline.com/doi/abs/10.1080/01443410802478622>
- Kolhar, M., Kazi, R. N. A., & Alameen, A. (2021). Effect of social media use on learning, social interactions, and sleep duration among university students. *Saudi journal of biological sciences*, 28(4), 2216-2222.
Effect of social media use on learning, social interactions, and sleep duration among university students
- Latipah, E., Adi, H. C., & Insani, F. D. (2021). Academic procrastination of high school students during the Covid-19 pandemic: Review from self-regulated learning and the intensity of social media. *Dinamika Ilmu*, 21(2), 293-308. https://journal.uinsi.ac.id/index.php/dinamika_ilmu/article/view/3444
- Lau, W. W. (2017). Effects of social media usage and social media multitasking on the academic performance of university students. *Computers in human behavior*, 68, 286-291.
<https://www.sciencedirect.com/science/article/pii/S0747563216307841>
- Meier, A., Reinecke, L., & Meltzer, C. E. (2016). “Facebocrastination”? Predictors of using Facebook for procrastination and its effects on students’ well-being. *Computers in human behavior*, 64, 65-76.
<https://www.sciencedirect.com/science/article/pii/S0747563216304411>
- Özer, B. U., Saçkes, M., & Tuckman, B. W. (2013). Psychometric properties of the Tuckman procrastination scale in a Turkish sample. *Psychological reports*, 113(3), 874-884.
<https://journals.sagepub.com/doi/abs/10.2466/03.20.PR0.113x28z7>
- Salih, A. M., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Lekadir, K., & Menegaz, G. (2025). A perspective on explainable artificial intelligence methods: SHAP and LIME. *Advanced*



Intelligent Systems, 7(1), 2400304.

<https://advanced.onlinelibrary.wiley.com/doi/abs/10.1002/aisy.202400304>

Steel, P. (2007). The nature of procrastination: a meta-analytic and theoretical review of quintessential self-regulatory failure. *Psychological bulletin*, 133(1), 65. <https://psycnet.apa.org/fulltext/2006-23058-004.html>

Suárez-Perdomo, A., Ruiz-Alfonso, Z., & Garcés-Delgado, Y. (2022). Profiles of undergraduates' networks addiction: Difference in academic procrastination and performance. *Computers & education*, 181, 104459. <https://www.sciencedirect.com/science/article/pii/S0360131522000306>

Wu, Y. (2023). Joint comparison of the predictive values of multiple binary diagnostic tests: an extension of McNemar's test. *Journal of Biopharmaceutical Statistics*, 33(1), 31-42.

Zhou, Y., Cao, C., Liu, L., Liu, Z., & Liu, J. (2024). Academic procrastination of nursing students in higher vocational college: application of latent profile analysis and network analysis. *Acta Psychologica*, 246, 104296. <https://www.sciencedirect.com/science/article/pii/S0001691824001732>

Conflicto de interés

Los autores autorizan la distribución y uso de su artículo.

Contribuciones de los autores

1. Conceptualización: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara.
2. Curación de datos: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
3. Análisis formal: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
4. Investigación: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
5. Metodología: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
6. Administración del proyecto: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
7. Recursos: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
8. Software: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
9. Supervisión: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara



Esta obra está bajo una licencia *Creative Commons* de tipo Atribución 4.0 Internacional (CC BY 4.0)

10. Validación: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
11. Visualización: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
12. Redacción – borrador original: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara
13. Redacción – revisión y edición: Flavio Patricio Quezada Abarca, Andrea Verónica Cartuche Jara

Financiación

La investigación no requirió fuente de financiamiento.



Esta obra está bajo una licencia *Creative Commons* de tipo Atribución 4.0 Internacional
(CC BY 4.0)