

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.139>

Modelos computacionales para la reducción de la sobrecarga cognitiva en estudiantes de administración

Karold Roxana Cáceres Gómez*
<https://orcid.org/0009-0005-5773-0666>
kcaceresg@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Stephanie Cris Cheneaux Márquez
<https://orcid.org/0000-0001-9163-6001>
stephanie.cheneaux@estudiante.ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Erick Percy Berrios Fernández
<https://orcid.org/0009-0009-8311-7282>
eberrios@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Antonio Escobar Juárez
<https://orcid.org/0000-0001-5991-0410>
aescobar@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Christian Herbert Cueva Allison
<https://orcid.org/0009-0008-4339-4798>
ccuevaa@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

*Autor de correspondencia: kcaceresg@unsa.edu.pe

Recibido: (12/02/2026), Aceptado: (10/05/2026)

Resumen. La investigación desarrolló un modelo computacional predictivo para identificar y reducir la sobrecarga cognitiva en estudiantes universitarios de administración en entornos digitales. Se aplicó un enfoque cuantitativo utilizando variables académicas, cognitivas y tecnológicas relacionadas con fatiga digital, estrés académico y uso de plataformas virtuales. Se implementaron algoritmos de aprendizaje automático como regresión logística, SVM y *Random Forest*, complementados con simulación computacional. Los resultados mostraron que *Random Forest* obtuvo el mejor desempeño predictivo y permitió detectar escenarios críticos de saturación cognitiva. Se concluye que los modelos computacionales pueden contribuir al diseño de sistemas educativos inteligentes orientados al bienestar académico.

Palabras clave: sobrecarga cognitiva, modelos computacionales, aprendizaje automático, fatiga digital, inteligencia artificial.

Computational Models for Reducing Cognitive Overload in Business Administration Students

Abstract. The study developed a predictive computational model to identify and reduce cognitive overload in undergraduate business administration students in digital environments. A quantitative approach was applied using academic, cognitive, and technological variables related to digital fatigue, academic stress, and the use of virtual platforms. Machine learning algorithms such as logistic regression, SVM, and *Random Forest* were implemented and complemented with computational simulation. The results showed that *Random Forest* achieved the best predictive performance and made it possible to detect critical scenarios of cognitive saturation. It is concluded that computational models can contribute to the design of intelligent educational systems oriented toward academic well-being.

Keywords: cognitive overload, computational models, machine learning, digital fatigue, artificial intelligence.

I. INTRODUCCIÓN

La transformación digital de los entornos universitarios ha incrementado significativamente la exposición de los estudiantes a múltiples estímulos informativos, plataformas virtuales y dinámicas académicas simultáneas, generando nuevos desafíos relacionados con la gestión de la carga mental y el procesamiento cognitivo. En este contexto, la sobrecarga cognitiva se ha convertido en un problema relevante dentro de la educación superior, especialmente en carreras vinculadas a procesos analíticos y toma de decisiones, como administración de empresas. Diversos estudios han demostrado que la acumulación excesiva de información y tareas digitales puede afectar negativamente la concentración, la productividad académica y el bienestar psicológico de los estudiantes [1], [2], [3].

El crecimiento de los sistemas educativos digitales ha impulsado además el interés por el desarrollo de herramientas basadas en inteligencia artificial orientadas a optimizar el aprendizaje y reducir la saturación cognitiva. Investigaciones recientes han señalado que los modelos computacionales y sistemas adaptativos permiten gestionar de manera más eficiente la complejidad de los entornos virtuales de aprendizaje, facilitando procesos de personalización educativa y regulación dinámica de actividades académicas [4], [5], [6]. De manera complementaria, enfoques basados en interacción humano-computador y analítica educativa han evidenciado que la detección temprana de estados de fatiga mental puede contribuir significativamente a mejorar el rendimiento estudiantil y la permanencia académica [7], [8].

Desde una perspectiva teórica, la teoría de la carga cognitiva continúa siendo uno de los principales marcos explicativos para comprender las limitaciones del procesamiento mental frente a escenarios educativos altamente demandantes. No obstante, investigaciones recientes han propuesto ampliar esta teoría mediante la integración de inteligencia artificial, neurociencia educativa y sistemas inteligentes capaces de adaptarse dinámicamente al comportamiento cognitivo del estudiante [9], [10], [11]. Asimismo, se ha señalado que el uso intensivo de herramientas digitales puede generar fenómenos simultáneos de apoyo cognitivo y saturación mental, dependiendo de la forma en que las tecnologías son implementadas dentro del proceso de aprendizaje [12].

A pesar de los avances existentes, aún persisten limitaciones relacionadas con la integración de modelos predictivos capaces de analizar simultáneamente variables académicas, tecnológicas y cognitivas dentro de contextos universitarios reales. Muchos estudios se concentran principalmente en aspectos pedagógicos o psicológicos, dejando en segundo plano el desarrollo de arquitecturas computacionales orientadas al monitoreo inteligente de estados cognitivos [13]. En consecuencia, resulta necesario fortalecer investigaciones interdisciplinarias que incorporen herramientas de aprendizaje automático, simulación computacional y análisis predictivo para comprender el comportamiento de la sobrecarga cognitiva en estudiantes universitarios [14].

En función de ello, el presente estudio tuvo como objetivo desarrollar y evaluar un modelo computacional predictivo orientado a la identificación de factores asociados a la sobrecarga cognitiva en estudiantes de administración dentro de entornos educativos digitales. Para ello, se integraron técnicas de aprendizaje automático, análisis estadístico y simulación computacional, con el propósito de diseñar un sistema inteligente capaz de contribuir a la reducción de la fatiga cognitiva y optimización del aprendizaje universitario.

II. MARCO TEÓRICO

La sobrecarga cognitiva constituye un fenómeno asociado a la incapacidad del sistema cognitivo para procesar eficientemente grandes volúmenes de información de manera simultánea. En entornos educativos digitales, este problema se ha intensificado debido al incremento de actividades virtuales, multitarea académica y exposición prolongada a plataformas tecnológicas [1], [3]. Diversos estudios han señalado que la saturación informativa afecta directamente la atención, memoria de trabajo, motivación y desempeño académico de los estudiantes universitarios [5], [12].

La teoría de la carga cognitiva ha sido uno de los principales fundamentos para comprender cómo el exceso de estímulos y demandas mentales impacta el aprendizaje. Sin embargo, investigaciones recientes sostienen que los modelos tradicionales deben complementarse con enfoques basados en inteligencia artificial y neurociencia educativa, capaces de analizar dinámicamente el comportamiento cognitivo del estudiante y adaptar el entorno de aprendizaje según sus necesidades [10], [14]. En este sentido, las tecnologías inteligentes permiten no solo automatizar procesos educativos, sino también optimizar la distribución de contenidos y reducir la fatiga mental generada por entornos digitales complejos [4].

El desarrollo de modelos computacionales aplicados a educación ha permitido incorporar herramientas de aprendizaje automático orientadas a la predicción de comportamientos académicos y estados cognitivos. Estudios recientes destacan que algoritmos computacionales como *Random Forest* y sistemas predictivos adaptativos poseen alta capacidad para identificar patrones relacionados con estrés académico, fatiga digital y sobrecarga cognitiva [2], [7]. Estas aproximaciones facilitan el diseño de sistemas inteligentes capaces de generar recomendaciones académicas personalizadas y mecanismos automáticos de regulación educativa.

De manera complementaria, la interacción humano-computador y la analítica educativa han adquirido relevancia dentro de los entornos virtuales de aprendizaje, particularmente en investigaciones orientadas a reducir la fatiga digital y mejorar la experiencia académica [11]. Asimismo, se ha señalado que el uso de inteligencia artificial puede generar simultáneamente beneficios cognitivos y riesgos de dependencia tecnológica, dependiendo del diseño e implementación de las herramientas digitales [13]. En consecuencia, la integración de modelos computacionales, aprendizaje automático y simulación predictiva representa una alternativa relevante para el desarrollo de sistemas educativos inteligentes capaces de monitorear y reducir la sobrecarga cognitiva en estudiantes universitarios, especialmente en contextos académicos caracterizados por alta demanda informacional y exposición tecnológica constante.

III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo de tipo aplicado, orientado al diseño y evaluación de modelos computacionales para identificar y reducir la sobrecarga cognitiva en estudiantes universitarios de administración en entornos digitales. Se adoptó un diseño no experimental de alcance predictivo-explicativo, considerando variables académicas, cognitivas y tecnológicas asociadas al comportamiento estudiantil. La población estuvo conformada por estudiantes universitarios de administración en modalidad presencial y virtual. La muestra fue seleccionada mediante muestreo no probabilístico por conveniencia, considerando estudiantes con participación activa en plataformas virtuales de aprendizaje.

Para la recolección de datos se aplicó un cuestionario tipo Likert validado por expertos, orientado a medir dimensiones relacionadas con sobrecarga cognitiva, fatiga digital, estrés académico, complejidad de contenidos y rendimiento académico percibido. La confiabilidad del instrumento fue evaluada mediante el coeficiente alfa de Cronbach.

El componente ingenieril del estudio se centró en el desarrollo de un modelo computacional predictivo basado en técnicas de aprendizaje automático. Los datos fueron sometidos a procesos de limpieza, normalización y análisis estadístico previo al entrenamiento de los algoritmos. Se implementaron modelos como regresión logística y *Random Forest* para identificar patrones asociados a estados elevados de sobrecarga cognitiva, utilizando fases de entrenamiento y validación para evaluar la estabilidad del sistema.

Adicionalmente, se desarrolló una simulación computacional para representar distintos escenarios académicos relacionados con el incremento de carga mental, tiempo de exposición digital y estrés académico. El desempeño del modelo fue evaluado mediante métricas como *accuracy*, precisión, sensibilidad y *F1-score*, complementadas con análisis de importancia de variables para identificar los factores con mayor influencia dentro del sistema predictivo.

Finalmente, los resultados fueron analizados mediante estadística descriptiva, correlacional y regresión múltiple, utilizando herramientas de programación orientadas a sistemas inteligentes e ingeniería educativa.

IV. RESULTADOS

A. Caracterización de la muestra

Con el propósito de contextualizar el comportamiento de las variables cognitivas y tecnológicas analizadas, inicialmente se realizó una caracterización general de los estudiantes participantes. La distribución de la muestra permitió identificar patrones relevantes asociados al entorno académico digital, particularmente en relación con la intensidad de uso de plataformas virtuales, carga académica y tiempo

promedio de exposición tecnológica. La Tabla 1 presenta las principales características sociodemográficas y académicas consideradas en el estudio.

Tabla 1. Características generales de la muestra estudiantil.

Variable	Categoría	Frecuencia	Porcentaje (%)
Género	Femenino	78	52,0
	Masculino	72	48,0
Edad	18-21 años	64	42,7
	22-25 años	58	38,7
	26 años o más	28	18,6
Modalidad académica	Presencial	81	54,0
	Virtual	69	46,0
Tiempo diario en plataformas virtuales	1-3 horas	39	26,0
	4-6 horas	71	47,3
	Más de 6 horas	40	26,7
Nivel de carga académica percibida	Baja	18	12,0
	Moderada	79	52,7
	Alta	53	35,3

Nota. La tabla presenta la distribución sociodemográfica y académica de los estudiantes participantes.

Los resultados evidenciaron una distribución relativamente equilibrada entre hombres y mujeres, predominando estudiantes entre 18 y 25 años. Asimismo, se observó que el 74% de los participantes permanecía más de cuatro horas diarias interactuando con plataformas virtuales, situación que refleja una elevada exposición a entornos digitales de aprendizaje. De manera paralela, más de un tercio de los estudiantes reportó percibir niveles altos de carga académica, lo que sugiere condiciones potencialmente favorables para la aparición de sobrecarga cognitiva y fatiga mental. Desde una perspectiva ingenieril, estos resultados justificaron la necesidad de implementar modelos computacionales capaces de monitorear y predecir dinámicamente escenarios de saturación cognitiva, especialmente en contextos universitarios donde convergen múltiples estímulos digitales, actividades simultáneas y elevados requerimientos de procesamiento de información.

B. Validación y consistencia interna del instrumento

Con la finalidad de garantizar la confiabilidad y estabilidad estadística de las mediciones utilizadas en el modelo computacional, se evaluó la consistencia interna del instrumento aplicado a los estudiantes. El análisis permitió verificar el grado de coherencia entre los ítems asociados a las dimensiones cognitivas, académicas y tecnológicas incluidas en el estudio. La Tabla 2 presenta los coeficientes de confiabilidad obtenidos para cada dimensión evaluada.

Tabla 2. Consistencia interna de las dimensiones analizadas.

Dimensión	Número de ítems	Alfa de Cronbach
Sobrecarga cognitiva	8	0.91
Fatiga digital	6	0.88
Estrés académico	7	0.90
Complejidad percibida de contenidos	5	0.84
Interacción con plataformas virtuales	5	0.86
Rendimiento académico percibido	4	0.82
Instrumento global	35	0.93

Nota. Los coeficientes muestran la consistencia interna de las dimensiones utilizadas para alimentar el modelo computacional predictivo.

Los coeficientes obtenidos evidenciaron niveles elevados de consistencia interna en todas las dimensiones analizadas, registrándose valores superiores a 0,80, considerados adecuados para investigaciones aplicadas en ciencias sociales e ingeniería educativa. La dimensión asociada a sobrecarga cognitiva presentó el valor más alto de confiabilidad ($\alpha = 0,91$), indicando una elevada estabilidad en las respuestas

relacionadas con fatiga mental, saturación informativa y dificultad de procesamiento académico. De manera complementaria, el instrumento global alcanzó un alfa de Cronbach de 0,93, resultado que confirmó la robustez estadística del sistema de medición utilizado para alimentar el modelo computacional predictivo. Estos resultados permitieron establecer una base metodológica sólida para el procesamiento de datos y el entrenamiento de los algoritmos de aprendizaje automático implementados posteriormente. Desde el enfoque ingenieril, la validación del instrumento constituyó una etapa crítica dentro de la arquitectura computacional propuesta, debido a que la calidad y estabilidad de los datos de entrada condicionan directamente el desempeño predictivo de los modelos inteligentes utilizados para la detección de sobrecarga cognitiva en entornos educativos digitales.

C. Análisis descriptivo de las variables cognitivas y tecnológicas

Posteriormente, se realizó un análisis descriptivo de las principales variables incorporadas al modelo computacional, con el propósito de identificar tendencias asociadas a la sobrecarga cognitiva y al comportamiento académico-digital de los estudiantes. Este análisis permitió reconocer patrones iniciales relacionados con niveles de estrés, fatiga digital y percepción de complejidad académica, elementos fundamentales para el entrenamiento del sistema predictivo. La Figura 1 presenta los promedios obtenidos en las dimensiones evaluadas mediante escalas de cinco niveles.

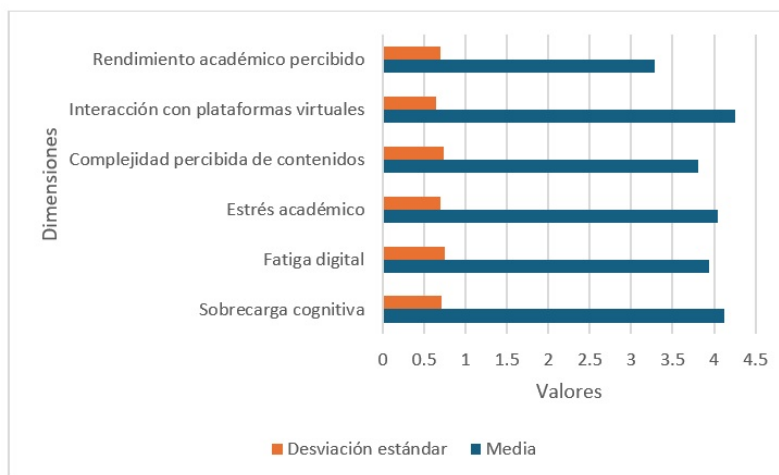


Fig. 1. Promedio de las dimensiones cognitivas y tecnológicas analizadas.

Los resultados evidenciaron niveles elevados de interacción con plataformas virtuales y sobrecarga cognitiva, registrándose medias superiores a 4,0 en ambas dimensiones. Este comportamiento sugiere una relación directa entre la intensidad de exposición digital y el incremento de la fatiga mental en estudiantes universitarios de administración. Asimismo, el estrés académico presentó valores elevados y relativamente homogéneos entre los participantes, indicando una presencia constante de presión cognitiva dentro del entorno formativo. Por otro lado, el rendimiento académico percibido mostró valores moderados en comparación con las demás dimensiones, lo que podría indicar que el incremento sostenido de estímulos digitales y carga mental no necesariamente se traduce en mejoras proporcionales del desempeño académico. Esta tendencia resulta particularmente relevante desde el enfoque computacional, ya que evidencia la necesidad de sistemas inteligentes capaces de regular dinámicamente los niveles de complejidad educativa y distribución de tareas.

En términos ingenieriles, el comportamiento descriptivo de las variables permitió identificar condiciones críticas de saturación cognitiva que posteriormente fueron utilizadas como parámetros de entrada para el entrenamiento y simulación del modelo predictivo. Estos hallazgos constituyeron una base fundamental para la construcción de escenarios computacionales orientados a optimizar el equilibrio entre exigencia académica y capacidad de procesamiento cognitivo estudiantil.

D. Análisis correlacional y modelado matemático de la sobrecarga cognitiva

Con el objetivo de identificar relaciones funcionales entre las variables académicas, tecnológicas y cognitivas, se realizó un análisis correlacional previo al entrenamiento del modelo computacional. Esta

etapa permitió establecer la intensidad de asociación entre los factores estudiados y determinar cuáles variables presentaban mayor influencia sobre la sobrecarga cognitiva. La Tabla 3 presenta la matriz de correlaciones obtenida mediante el coeficiente de Pearson.

Tabla 3. Correlaciones entre variables asociadas a la sobrecarga cognitiva.

Variabes	1	2	3	4	5	6
1. Sobrecarga cognitiva	1,00					
2. Fatiga digital	0,81	1,00				
3. Estrés académico	0,76	0,71	1,00			
4. Complejidad de contenidos	0,69	0,62	0,66	1,00		
5. Tiempo en plataformas virtuales	0,73	0,79	0,58	0,54	1,00	
6. Rendimiento académico	-0,48	-0,41	-0,45	-0,32	-0,29	1,00

Nota. Las correlaciones fueron estimadas mediante el coeficiente de Pearson.

Los resultados evidenciaron correlaciones positivas elevadas entre sobrecarga cognitiva y fatiga digital ($r = 0,81$), así como entre sobrecarga cognitiva y estrés académico ($r = 0,76$), indicando que el incremento sostenido de estímulos digitales y presión académica influye directamente en la saturación mental de los estudiantes. Del mismo modo, el tiempo de exposición a plataformas virtuales mostró una asociación considerable con fatiga digital ($r = 0,79$), reflejando la incidencia de los entornos tecnológicos sobre el procesamiento cognitivo estudiantil. En contraste, el rendimiento académico presentó correlaciones negativas moderadas respecto a las variables cognitivas, sugiriendo que niveles elevados de saturación mental podrían afectar progresivamente la percepción de desempeño académico. Estos resultados respaldaron la necesidad de implementar mecanismos computacionales orientados al monitoreo dinámico de estados cognitivos críticos. A partir de las variables con mayor capacidad explicativa, se formuló un modelo matemático multivariable para representar el comportamiento de la sobrecarga cognitiva dentro del sistema computacional propuesto. El modelo fue expresado mediante una ecuación de regresión lineal múltiple:

$$SC = \beta_0 + \beta_1 FD + \beta_2 EA + \beta_3 CV + \beta_4 TP - \beta_5 RA + \varepsilon \quad (1)$$

donde: (SC): sobrecarga cognitiva, (FD): fatiga digital, (EA): estrés académico, (CV): complejidad de contenidos, (TP): tiempo en plataformas virtuales, (RA): rendimiento académico, (ε): término de error del modelo.

La formulación matemática permitió representar computacionalmente la interacción simultánea entre variables cognitivas y tecnológicas, facilitando posteriormente el entrenamiento del sistema predictivo basado en aprendizaje automático. Desde el enfoque ingenieril, este modelo constituyó la estructura funcional inicial para la simulación de escenarios educativos adaptativos y para la detección automatizada de estados de alta carga mental dentro de ambientes universitarios digitales.

E. Entrenamiento y desempeño del modelo computacional predictivo

Con el propósito de identificar patrones asociados a estados de sobrecarga cognitiva y generar predicciones automatizadas dentro del entorno académico digital, se implementaron distintos algoritmos de aprendizaje automático utilizando las variables cognitivas, académicas y tecnológicas previamente analizadas. El conjunto de datos fue dividido en una fase de entrenamiento (80%) y una fase de validación (20%), permitiendo evaluar la estabilidad y capacidad predictiva de cada modelo computacional bajo condiciones controladas. Inicialmente, se compararon tres algoritmos ampliamente utilizados en sistemas inteligentes y analítica predictiva: regresión logística, máquinas de soporte vectorial (SVM) y *Random Forest*. La evaluación del desempeño se realizó mediante métricas de clasificación orientadas a determinar la capacidad del sistema para detectar escenarios de alta sobrecarga cognitiva en estudiantes universitarios. La Tabla 4 presenta los resultados comparativos obtenidos durante el proceso de validación computacional.

Tabla 4. Desempeño comparativo de los modelos predictivos implementados.

Modelo computacional	Accuracy	Precision	Recall	F1-score
Regresión logística	0,81	0,79	0,77	0,78
SVM	0,85	0,83	0,82	0,82
Random Forest	0,91	0,89	0,90	0,89

Nota. El conjunto de datos fue dividido en 80% para entrenamiento y 20% para validación.

Los resultados evidenciaron que el algoritmo *Random Forest* alcanzó el mejor desempeño global, registrando una exactitud del 91% y valores superiores en todas las métricas de clasificación. Este comportamiento indicó una elevada capacidad del modelo para reconocer patrones complejos asociados a la saturación cognitiva estudiantil, incluso en escenarios donde múltiples variables interactuaban simultáneamente. Por otro lado, aunque la regresión logística presentó resultados aceptables, su capacidad predictiva fue inferior frente a los algoritmos basados en aprendizaje no lineal, particularmente en contextos donde la interacción entre variables cognitivas y tecnológicas resultó altamente dinámica. De manera similar, el modelo SVM mostró un desempeño intermedio, evidenciando una adecuada capacidad de clasificación, aunque con menor estabilidad frente a variaciones en los datos de entrenamiento.

Desde el enfoque ingenieril, los resultados confirmaron que los modelos basados en ensamblaje computacional poseen una mayor capacidad para representar sistemas educativos complejos caracterizados por múltiples factores simultáneos de influencia. La arquitectura *Random Forest* permitió además reducir problemas de sobreajuste y mejorar la generalización predictiva del sistema inteligente propuesto. Complementariamente, el comportamiento matemático del algoritmo seleccionado puede representarse mediante una función de decisión basada en la agregación de árboles de clasificación independientes:

$$F(x) = \frac{1}{N} \sum_{i=1}^N T_i(x) \quad (2)$$

donde: ($F(x)$) representa la predicción final del sistema computacional, ($T_i(x)$) corresponde a cada árbol de decisión individual, (N) representa el número total de árboles utilizados en el modelo.

Esta formulación permitió integrar múltiples criterios de decisión dentro de un único sistema predictivo robusto, incrementando la precisión del análisis cognitivo y facilitando la detección temprana de condiciones académicas potencialmente críticas. Desde una perspectiva aplicada, el modelo desarrollado puede constituir la base para futuros sistemas inteligentes adaptativos capaces de regular dinámicamente actividades académicas, complejidad de contenidos y distribución de tareas según el estado cognitivo estimado de cada estudiante.

F. Simulación computacional de escenarios académicos

Con la finalidad de analizar el comportamiento dinámico del modelo predictivo ante diferentes condiciones académicas y tecnológicas, se desarrolló una simulación computacional basada en escenarios progresivos de carga cognitiva. Esta etapa permitió evaluar la sensibilidad del sistema inteligente frente a variaciones en el tiempo de exposición digital, complejidad de contenidos y niveles de estrés académico, reproduciendo condiciones similares a las experimentadas en entornos universitarios reales.

La simulación fue ejecutada mediante iteraciones computacionales controladas, donde las variables de entrada fueron modificadas gradualmente para observar el comportamiento predictivo del algoritmo *Random Forest*. Los escenarios evaluados permitieron estimar probabilidades de saturación cognitiva y detectar umbrales críticos asociados al deterioro del rendimiento académico. La Figura 2 presenta el comportamiento del nivel estimado de sobrecarga cognitiva según el incremento progresivo de la exposición digital y presión académica.

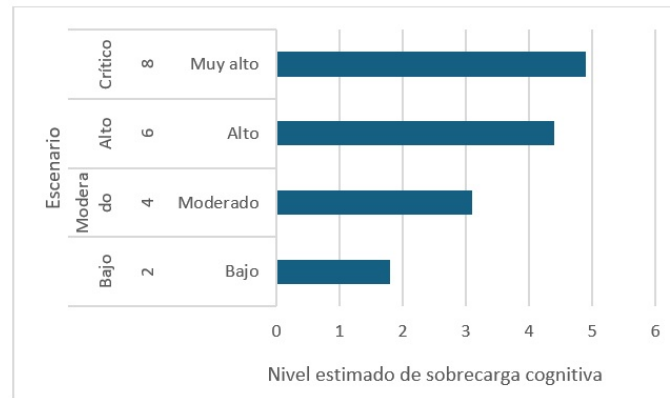


Fig. 2. Simulación computacional del nivel de sobrecarga cognitiva en función de la exposición digital y estrés académico.

Los resultados evidenciaron un crecimiento no lineal de la sobrecarga cognitiva conforme aumentaban simultáneamente las horas de interacción digital y los niveles de presión académica. Particularmente, los escenarios superiores a seis horas diarias de exposición tecnológica mostraron incrementos acelerados en los niveles de saturación mental, aproximándose a estados críticos de fatiga cognitiva y disminución del rendimiento académico. Desde el análisis computacional, el modelo demostró una elevada sensibilidad frente a cambios pequeños en las variables de entrada, permitiendo detectar transiciones rápidas entre estados moderados y críticos de carga mental. Este comportamiento resultó especialmente relevante para el diseño de sistemas inteligentes adaptativos, ya que evidencia la posibilidad de implementar mecanismos automáticos de alerta temprana y regulación académica. El comportamiento dinámico de la simulación pudo representarse mediante una función de crecimiento no lineal asociada al incremento acumulativo de estímulos cognitivos:

$$SC(t) = \alpha \ln(ED + 1) + \beta EA + \gamma CC \quad (3)$$

donde: ($SC(t)$): nivel de sobrecarga cognitiva estimada, (ED): exposición digital, (EA): estrés académico, (CC): complejidad de contenidos, (α, β, γ): coeficientes de ponderación del sistema.

La incorporación de esta formulación matemática permitió representar computacionalmente la evolución progresiva de la carga cognitiva en función de múltiples estímulos académicos simultáneos. Desde el enfoque ingenieril, la simulación desarrollada constituye un aporte relevante para el diseño de plataformas inteligentes orientadas a monitorear estados cognitivos en tiempo real y optimizar dinámicamente la distribución de actividades educativas dentro de entornos universitarios digitales.

G. Importancia computacional de las variables predictoras

Con el propósito de identificar cuáles factores ejercían mayor influencia dentro del sistema inteligente propuesto, se realizó un análisis de importancia de variables utilizando el algoritmo *Random Forest* seleccionado previamente. Esta etapa permitió cuantificar el aporte relativo de cada variable al proceso de predicción de la sobrecarga cognitiva, facilitando la comprensión del comportamiento interno del modelo computacional y fortaleciendo la interpretabilidad del sistema. El análisis de importancia se ejecutó mediante la reducción promedio de impureza generada por cada variable dentro de los árboles de decisión del modelo. Este procedimiento permitió determinar cuáles factores contribuían en mayor medida a la clasificación de estados cognitivos críticos. La Figura 3 presenta la jerarquización computacional de las variables predictoras incorporadas en el sistema.




Fig. 3. Importancia relativa de las variables dentro del modelo predictivo.

Los resultados evidenciaron que la fatiga digital constituyó la variable de mayor influencia dentro del sistema predictivo, seguida del estrés académico y del tiempo de interacción con plataformas virtuales. Este comportamiento confirmó que la exposición prolongada a entornos digitales y la acumulación de presión académica representan factores determinantes en la aparición de estados de saturación cognitiva en estudiantes universitarios. Asimismo, la complejidad percibida de los contenidos presentó una influencia considerable dentro del modelo, indicando que no solamente la cantidad de actividades académicas afecta la carga mental, sino también el nivel de dificultad cognitiva requerido para procesar la información. En contraste, variables como calidad del descanso y rendimiento académico mostraron una participación menor dentro de la estructura predictiva, aunque continuaron aportando información relevante para mejorar la estabilidad global del sistema.

Desde el enfoque ingenieril, estos resultados permitieron optimizar la arquitectura computacional mediante la priorización de variables críticas durante el entrenamiento del algoritmo. La reducción de dimensionalidad y la identificación de factores dominantes favorecieron además la eficiencia computacional del modelo, disminuyendo tiempos de procesamiento y mejorando la capacidad de generalización predictiva. La importancia relativa de las variables dentro del sistema puede representarse matemáticamente mediante una función ponderada de contribución computacional:

$$I_j = \frac{\sum_{k=1}^n \Delta E_{jk}}{\sum_{j=1}^m \sum_{k=1}^n \Delta E_{jk}} \quad (4)$$

donde: (I_j): importancia relativa de la variable (j), (ΔE_{jk}): reducción de error generada por la variable (j) en el nodo (k), (m): número total de variables, (n): número total de nodos evaluados.

Esta formulación permitió cuantificar matemáticamente el aporte individual de cada variable al desempeño global del sistema inteligente, proporcionando una base sólida para el diseño de futuras plataformas adaptativas orientadas a la regulación automática de la carga cognitiva en contextos educativos digitales.

H. Arquitectura del sistema inteligente para la reducción de la sobrecarga cognitiva

Con base en los resultados obtenidos mediante el análisis estadístico, el modelado matemático y la simulación computacional, se diseñó una arquitectura conceptual orientada a la detección y mitigación automatizada de estados de sobrecarga cognitiva en estudiantes universitarios. El sistema propuesto integra procesos de adquisición de datos académicos, análisis predictivo y retroalimentación adaptativa, permitiendo generar recomendaciones dinámicas según el comportamiento cognitivo estimado del estudiante. La arquitectura desarrollada fue estructurada en cuatro módulos principales: adquisición de variables cognitivas y académicas, procesamiento computacional de datos, motor predictivo basado en aprendizaje automático y sistema adaptativo de respuesta académica. La Figura 4 presenta la estructura funcional del sistema inteligente propuesto.

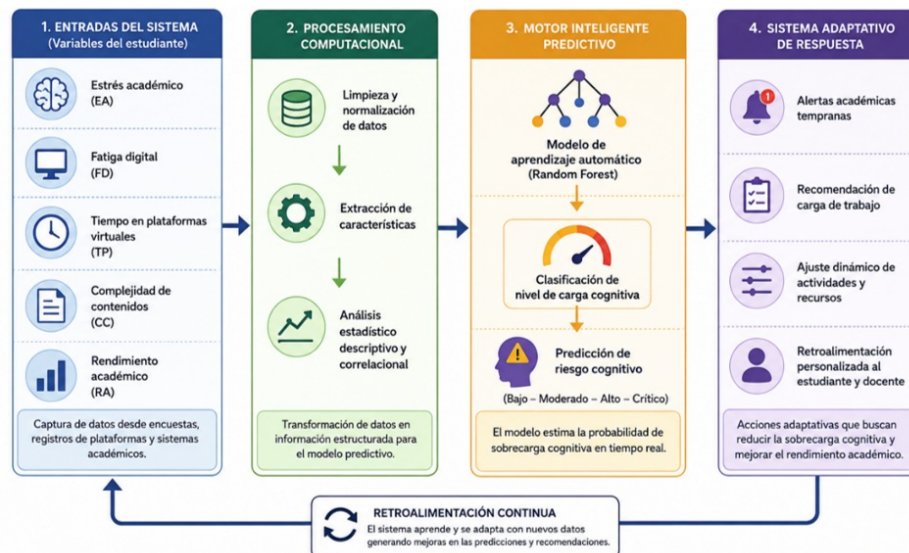


Fig. 4. Arquitectura conceptual del sistema inteligente para la reducción de la sobrecarga cognitiva.

Los resultados obtenidos demostraron que la integración de modelos computacionales dentro de entornos educativos universitarios permite detectar tempranamente condiciones asociadas a fatiga mental y saturación cognitiva. Asimismo, la arquitectura propuesta evidencia el potencial de los sistemas inteligentes adaptativos para optimizar procesos de aprendizaje mediante mecanismos automáticos de regulación académica. Desde el enfoque ingenieril, el sistema desarrollado constituye una aproximación funcional hacia plataformas educativas capaces de combinar analítica predictiva, modelado matemático y aprendizaje automático en tiempo real, favoreciendo una gestión más eficiente de los procesos cognitivos estudiantiles en entornos digitales de alta exigencia.

CONCLUSIONES

Los resultados obtenidos evidenciaron que la sobrecarga cognitiva en estudiantes de administración se encuentra estrechamente relacionada con factores como la fatiga digital, el estrés académico y el tiempo de interacción con plataformas virtuales. La elevada exposición a entornos digitales y la acumulación simultánea de actividades académicas generaron condiciones favorables para el incremento de la saturación mental y la disminución del rendimiento académico percibido. El desarrollo del modelo computacional predictivo permitió identificar patrones relevantes asociados a estados de alta carga cognitiva, demostrando que las técnicas de aprendizaje automático constituyen herramientas efectivas para el análisis de variables académicas y cognitivas en contextos universitarios digitales. Entre los algoritmos implementados, el modelo *Random Forest* presentó el mejor desempeño predictivo, alcanzando niveles elevados de precisión y estabilidad computacional.

Asimismo, la simulación de escenarios académicos confirmó que el incremento progresivo de la exposición digital y la presión académica produce un crecimiento significativo de los niveles de sobrecarga cognitiva. Estos hallazgos evidencian la necesidad de incorporar sistemas inteligentes adaptativos capaces de monitorear dinámicamente el comportamiento cognitivo estudiantil y generar mecanismos automáticos de regulación académica. Desde el enfoque ingenieril, la investigación permitió integrar modelado matemático, aprendizaje automático y simulación computacional dentro de una arquitectura funcional orientada a la detección temprana de estados críticos de fatiga mental. El sistema propuesto representa una aproximación aplicable al desarrollo de plataformas educativas inteligentes capaces de optimizar procesos de aprendizaje mediante análisis predictivo y adaptación dinámica de actividades académicas.

Finalmente, el estudio aporta evidencia sobre el potencial de la inteligencia artificial y los modelos computacionales para fortalecer la gestión educativa en entornos digitales universitarios, contribuyendo al diseño de estrategias orientadas a mejorar el bienestar cognitivo y la sostenibilidad del aprendizaje en contextos de creciente complejidad tecnológica.

REFERENCIAS

- [1] N. Qamar, I. Ullah, F. Zeib, and M. Z. Khan, "The role of AI in reducing cognitive overload complex learning environments," *Review of Applied Management and Social Sciences*, vol. 8, no. 2, pp. 1111–1127, 2025, doi: 10.47067/ramss.v8i2.541.
- [2] H. Pang, X. Jin, and W. Zhang, "Deciphering the underlying repercussions of cognitive overload on university students' fatigue, frustration and academic productivity: Implementation of stimulus–organism–response model," *Acta Psychologica*, vol. 260, p. 105469, 2025, art. no. 105469. doi: 10.1016/j.actpsy.2025.105469.
- [3] M. A. Pasha, S. Nadeem, A. Rasool, F. Shafique, H. Imran, S. Kanwal, and K. Yasmeen, "Digital fatigue and cognitive overload as managerial challenges understanding the impact of workload management on the workforce," *The Critical Review of Social Sciences Studies*, vol. 3, no. 4, pp. 1629–1641, 2025, doi: 10.52970/grsse.v5i2.1275.
- [4] M. Kabir, A. Zafar, Z. Naz, and F. Maqsood, "The role of personalized AI-based learning tools in reducing cognitive overload and enhancing academic motivation," *Review of Applied Management and Social Sciences*, vol. 8, no. 3, pp. 1261–1275, 2025, doi: 10.47067/ramss.v8i3.544.
- [5] S. M. Kashlot, I. Ruthven, and Y. Moshfeghi, "Strategies for managing information overload: a systematic review," *Journal of Documentation*, vol. 82, no. 2, pp. 249–265, 2026, doi: 10.1108/JD-09-2025-0257.
- [6] S. Barigidad, S. Hameed, N. Karri, S. K. Jangam, P. S. R. Pedda, and D. Gupta, "Computational modeling of AI-enhanced learning pathways: A mathematical framework for optimizing knowledge acquisition, cognitive load management, and student performance in STEM education," in *2025 International Conference on AI-Driven STEM Education and Learning Technologies (AISTEMEDU)*, 2025, pp. 1–7.
- [7] M. N. Algewatta and K. Manathunga, "A BI approach for student engagement and retention along with cognitive load analysis for educator," in *2025 5th International Conference on Advanced Research in Computing (ICARC)*, Belihuloya, Sri Lanka, 2025, pp. 1–6, doi: 10.1109/ICARC64760.2025.10962823.
- [8] L. Rodrig and L. Marlow, "Cognitive load management in digital learning environments: Implications for student performance," *Innovative Journal of Educational Research and Insights*, pp. 188–197, 2025.
- [9] E. Gkintoni, H. Antonopoulou, A. Sortwell, and C. Halkiopoulos, "Challenging cognitive load theory: The role of educational neuroscience and artificial intelligence in redefining learning efficacy," *Brain Sciences*, vol. 15, no. 2, p. 203, 2025, art. no. 203. doi: 10.3390/brainsci15020203.
- [10] K. Twabu, "Enhancing the cognitive load theory and multimedia learning framework with AI insight," *Discover Education*, vol. 4, p. 160, 2025, art. no. 160. doi: 10.1007/s44217-025-00592-6.
- [11] X. Wan and J. Liu, "Human-computer interaction strategies to alleviate information overload in business contexts," *International Journal of Human-Computer Interaction*, vol. 41, no. 21, pp. 13 349–13 362, 2025, doi: 10.1080/10447318.2025.2470296.
- [12] P. Gupta and A. Prashar, "Learners' psychological needs in online learning environment for executive education: role of cognitive overload and learning self-efficacy," *Behaviour & Information Technology*, vol. 44, no. 9, pp. 1942–1963, 2025, doi: 10.1080/0144929X.2024.2383777.
- [13] G. Chirayath, K. Premamalini, and J. Joseph, "Cognitive offloading or cognitive overload? How AI alters the mental architecture of coping," *Frontiers in Psychology*, vol. 16, p. 1699320, 2025, art. no. 1699320. doi: 10.3389/fpsyg.2025.1699320.
- [14] A. Batubara, F. Rachman, R. Nababan, L. Siagian, and A. Latifah, "Brain flow: A gamified digital assessment with chunking enhancing patriotism reducing cognitive overload," in *International Conference on Social Sciences and Interdisciplinary Studies (ICSSIS 2025)*. Paris, France: Atlantis Press, 2025, pp. 273–281, doi: 10.2991/978-2-38476-499-0_22.