

Modelado de un entorno e-Learning Adaptativo Inteligente analizando estados emocionales en estudiantes universitarios de Oaxaca

Modeling of an Intelligent Adaptive e-Learning Environment Analyzing Emotional States in University Students from Oaxaca

ERNESTO CORTÉS PÉREZ*
LUIS ALAN ACUÑA GAMBOA**
EDUARDO MARTÍNEZ MENDOZA***

 [10.29043/liminar.v21i2.989](https://doi.org/10.29043/liminar.v21i2.989)

Resumen: El presente documento muestra los resultados del desarrollo y la aplicación de un ambiente e-Learning adaptativo inteligente a estudiantes universitarios del Istmo de Tehuantepec, Oaxaca. El objetivo es analizar cómo influyen en el desempeño académico las actividades de aprendizaje individualizadas y los estados emocionales. La identificación de los estados emocionales se llevó a cabo mediante algoritmos basados en Inteligencia Artificial. Los resultados mostraron una importante relación entre estado-emocional y calificación. Se llegó a la conclusión de que la sorpresa y el miedo propician la obtención de buenas calificaciones: hay evidencia en relación con este hecho, de un incremento en la media de 6.8 a 9.7. Estos resultados se compararon con los de semestres anteriores sin el uso de este ambiente de aprendizaje.

Palabras clave: Entorno adaptativo, Expresiones faciales, Inteligencia Artificial, Programación genética, Red neuronal.

Abstract: This document contains the results of the development and the application of an intelligent adaptive e-Learning environment to university students from the Isthmus of Tehuantepec, Oaxaca. The objective is to analyze how the individualized learning activities and the emotional states influence in academic performance. The identification of emotional states was carried out by algorithms based on Artificial Intelligence. The results showed an important relationship between emotional state and grade, which refers to the fact that surprise and fear generate a tendency to obtain good grades, since an increase in the average from 6.8 to 9.7 was obtained. These results were compared with those of semesters above without the use of this learning environment.

Keywords: Adaptive environment, Facial expressions, Artificial intelligence, Genetic programming, Neural network.

* Maestro en Cómputo Educativo por el Tecnológico de México. Profesor-investigador de tiempo completo en la Universidad del Istmo Campus Tehuantepec, en el departamento de Ingeniería en Computación.
cope144@gmail.com
 0000-0003-2234-7673

** Doctor en Estudios Regionales. Profesor-investigador en la Universidad Autónoma de Chiapas, Facultad de Arquitectura.
luis.gamboa@unach.mx
 0000-0002-8609-4786

*** Doctor en Ciencias de la Administración por la UNAM. Profesor-investigador de tiempo completo en la Universidad del Istmo Campus Tehuantepec, en el departamento de Ingeniería Industrial.
cope144@gmail.com
 0000-0003-2234-7673

Introducción¹

Los ambientes de aprendizaje e-Learning están constituidos por métodos que permiten mejorar las habilidades y el conocimiento de instructores, profesores y aquellos que buscan nuevas estrategias para que el proceso de aprendizaje sea más efectivo. El modelado de entornos de aprendizaje virtual ha recibido una amplia atención desde múltiples disciplinas incluyendo las ciencias de la computación, la psicología y la pedagogía (Megahed & Mohammed, 2020). En el sector educativo el perfil de aprendizaje representa los estilos y habilidades mentales de aprendizaje de todo estudiante (El-Bishouty *et al.*, 2019), identificarlo ha demostrado contribuir en el desempeño académico del alumno. Uno de los métodos más conocidos para identificar el estilo de aprendizaje en estudiantes de nivel superior es el cuestionario de Felder-Silverman (Aissaoui *et al.*, 2019; Bajaj & Sharma, 2018; Felder & Silverman, 1988), el cual considera cuatro dimensiones que representan la personalidad del estudiante: activo/reflexivo, sensitivo/intuitivo, visual/verbal y secuencial/global.

Sin embargo, plataformas de estudio convencionales no consideran el estado emocional del estudiante durante el proceso de aprendizaje. El estado emocional puede afectar/beneficiar la calidad del aprendizaje y el logro de los resultados deseados. Este estado es representado por el conjunto de emociones y sentimientos que determinan la relación de una persona con su entorno (Saarni *et al.*, 2007). La importancia de identificarlo no recae en el hecho de reconocer qué emoción se genera al momento de aprender, más bien busca analizar el comportamiento del estudiante al interactuar en entornos virtuales de aprendizaje y, así, asignar contenidos acordes a intereses y preferencias individuales. Una de las mejores fuentes para reconocer el estado emocional es el rostro humano mediante expresiones prototípicas como: felicidad, miedo, disgusto, enojo, tristeza, sorpresa y neutral (Ahmady *et al.*, 2022; Albraikan *et al.*, 2022; H. Liu *et al.*, 2023).

En la actualidad, uno de los temas de mayor interés en el ámbito educativo son los ambientes de aprendizaje e-Learning. Hoy en día se han encontrado considerables progresos en la interoperabilidad de estos ambientes, por ejemplo, la adopción de otros actores como las técnicas basadas en algoritmos de Machine Learning (ML), Inteligencia Artificial (IA) y Métodos Adaptativos permiten la integración de un nuevo diseño pedagógico según el perfil del alumno. Las plataformas e-Learning que integran IA forman lo que hoy se denomina Aprendizaje Adaptativo Inteligente (AAI), ya que poseen la capacidad de adaptar dinámica y automáticamente las actividades de aprendizaje a los requerimientos y necesidades específicos de cada estudiante, por ello es una de las tendencias en el presente.

Las contribuciones de este estudio se dan en cuatro partes. Primero, para el modelado del entorno de aprendizaje adaptativo, se identificó el perfil de aprendizaje del estudiante mediante un cuestionario en *Google Forms* que aplica el instrumento de Felder-Silverman. Segundo, de acuerdo con el perfil identificado se genera un marco de trabajo constituido por un corpus de

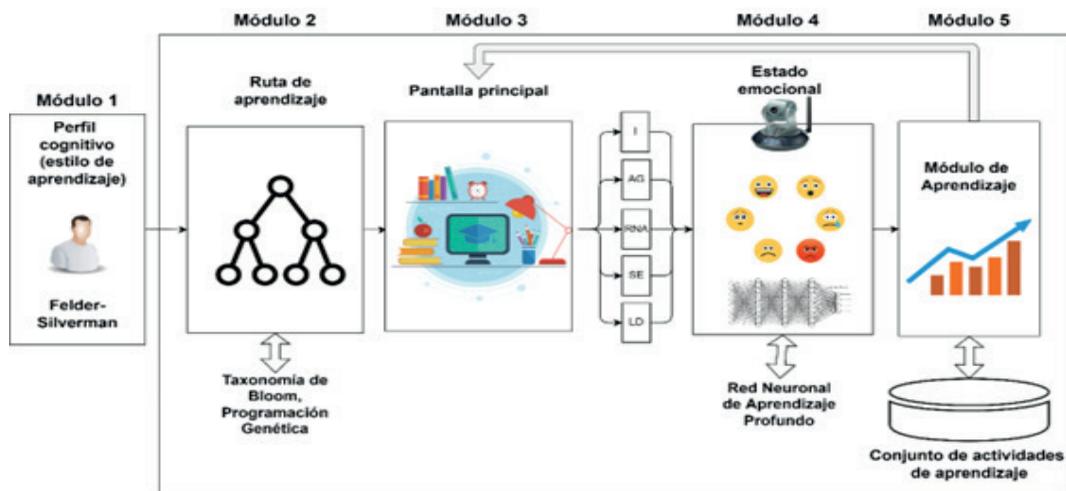
¹ Este trabajo fue apoyado por CONACyT mediante el otorgamiento de una beca de colegiatura que permitió llevar a cabo estudios doctorales en la Universidad Autónoma de Querétaro.

actividades de aprendizaje y exámenes en relación con los niveles de abstracción de la taxonomía de Bloom (Bloom, 1956). La tercera contribución es la integración de un módulo híbrido formado por un Programa Genético (PG) y una Red Neuronal Convolutiva de Aprendizaje Profundo (RNC). El PG se encarga de construir un camino con actividades acordes al perfil de aprendizaje del estudiante y la RNC se encarga de detectar los estados emocionales al momento que el estudiante interactúa con el entorno de aprendizaje, con ello es posible conocer la eficiencia y desempeño de la plataforma propuesta. Finalmente, la cuarta contribución es la calibración de los parámetros que integran la RNC para la detección de las expresiones faciales, para ello se construyó un corpus de datos con 466 rostros de hombres y mujeres de entre 18 y 25 años, considerando las expresiones: felicidad, tristeza, enojo, disgusto, miedo y sorpresa.

Desarrollo

El modelado del ambiente e-Learning adaptativo consta de cinco módulos (ver Figura 1) desarrollados bajo el paradigma Orientado a Objetos con el software *MATLAB App Designer 2021b* y *Google Workspace*.

Figura 1. Arquitectura del ambiente de aprendizaje adaptativo inteligente



Nota: Módulos que componen la arquitectura del ambiente de aprendizaje adaptativo.

Fuente: Construcción personal.

El estilo de aprendizaje: está representado por las preferencias que tienen los estudiantes al abordar una situación en un contexto de aprendizaje, para identificarlo se emplea el cuestionario de Felder y Silverman aplicado a una muestra no probabilística de 52 estudiantes de nivel superior y a otro grupo piloto de cinco estudiantes. El cuestionario de Felder y Silverman permite identificar dichos estilos caracterizados por cuatro dimensiones que describen cómo los estudiantes prefieren procesar (activo/reflexivo), percibir (sensitivo/intuitivo), recibir (verbal/visual) y comprender (secuencial/global). Estas dimensiones pueden ser vistas independientemente una de otra y no

son nuevas en el campo de los estilos de aprendizaje (Felder, 1996; Honey & Mumford, 1992; Kolb, 1981), lo novedoso recae en el cómo se describe el estilo de aprendizaje de un estudiante (Aissaoui *et al.*, 2019; El-Bishouty *et al.*, 2019; Nafea *et al.*, 2019; Sihombing *et al.*, 2020).

Creación de la ruta de aprendizaje: Bloom formuló una taxonomía de actividades de aprendizaje en la cual se definen seis niveles de abstracción desde un orden inferior hasta un orden superior. En el presente estudio, para establecer una relación entre los estilos de aprendizaje de Felder-Silverman y la taxonomía de Bloom, se identificaron actividades propias de cada perfil y se eliminaron actividades repetidas en cada uno de los niveles de abstracción (Birlik, 2015; Bloom, 1956; Honey & Mumford, 1992; Kolb, 1981), (ver Tabla 1).

Tabla 1. Relación entre las dimensiones de Felder-Silverman/Taxonomía de Bloom

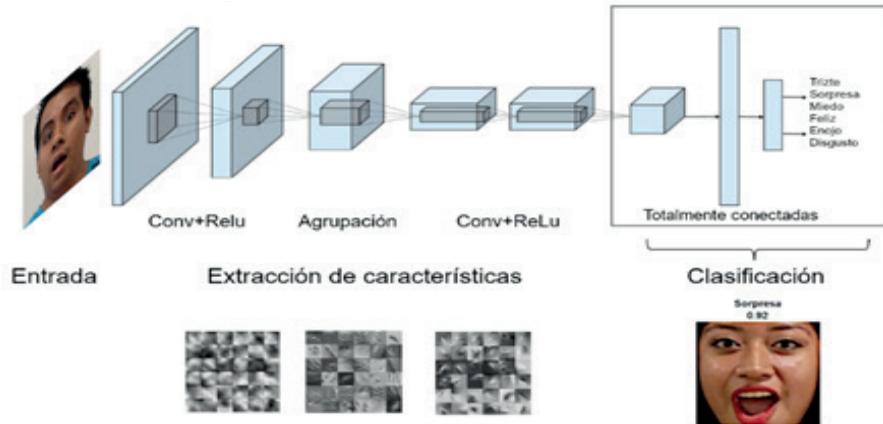
		ESTILOS DE APRENDIZAJE DE FELDER-SILVERMAN								
Nivel de complejidad		Sensitivo/Intuitivo-Visual/Verbal-Activo/Reflexivo-Secuencial/Global								
TAXONOMÍA DE BLOOM	Conoce	Define	Duplica	Enlista	Memoriza	Recuerda	Repite	Reproduce	-	-
	Comprende	Clasifica	Describe	Discute	Explica	Identifica	Localiza	Reconoce	Reporta	Selecciona
	Aplica	Demuestra	Dramatiza	Emplea	Ilustra	Interpreta	Opera	Programa	Bosqueja	Resuelve
	Analiza	Compara	Contrasta	Critica	Diferencia	Discrimina	Distingue	Examina	Experimenta	Cuestiona
	Evalúa	Argumenta	Defiende	Juzga	Selecciona	Apoya	Valora	Evalúa	Infiere	-
	Crea	Ensambla	Construye	Crea	Diseña	Desarrolla	Formula	Escribe	-	-

Fuente: Construcción personal.

Pantalla principal: La pantalla principal es la encargada de mostrar el ambiente e-Learning adaptativo, también muestra la información relacionada con las cinco unidades temáticas y actividades de aprendizaje que forman el curso. Dichas actividades están compuestas por: documentos PDF, presentaciones en Power Point, videos cortos (máx. 10 min), artículos de revistas, capítulos de libros, infografías, páginas web, video tutoriales, mapas conceptuales y manuales.

Estado emocional del estudiante: Para el reconocimiento del estado emocional, el ambiente de aprendizaje adaptativo emplea imágenes obtenidas de la webcam integrada en cada equipo personal y procesadas por una Red Neuronal de Aprendizaje Profundo llamada *Alexnet* (Krizhevsky *et al.*, 2017; Cortes & Sanchez, 2021; Pérez *et al.*, 2012), (ver Figura 2). El reconocimiento se lleva a cabo al finalizar cada actividad, así el sistema lleva un registro de forma individual.

Figura 2. Identificación del estado emocional



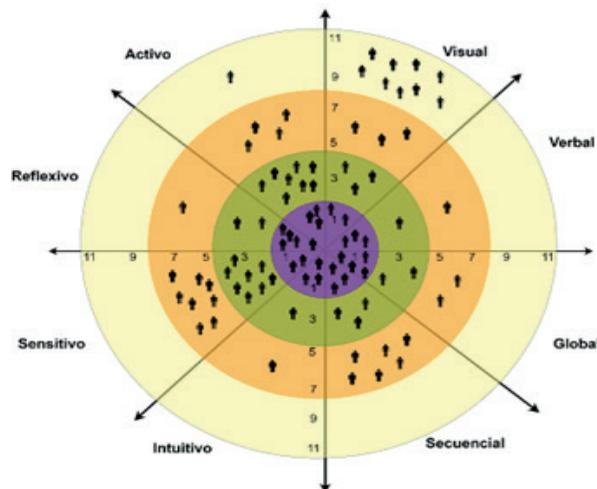
Nota: Las capas de la Red Neuronal Convolucional de Aprendizaje Profundo para detectar el estado de ánimo. Fuente: Construcción personal.

Resultados

Esta sección presenta los resultados de la aplicación del ambiente de aprendizaje adaptativo a la población de estudiantes de la carrera de Ingeniería en Computación de la Universidad del Istmo, ubicada en Santo Domingo Tehuantepec en el estado de Oaxaca, México.

El cuestionario de Felder-Silverman: Como resultado de la aplicación del cuestionario de Felder-Silverman a la población, se encontró que, de un total de 52 estudiantes encuestados, 32 tienen la personalidad *visual/verbal*, 13 de ellos tienen la personalidad *sensitiva/intuitivo*, cuatro son *activo/reflexivo* y tres pertenecen a la dimensión *secuencial/global* (ver Figura 3).

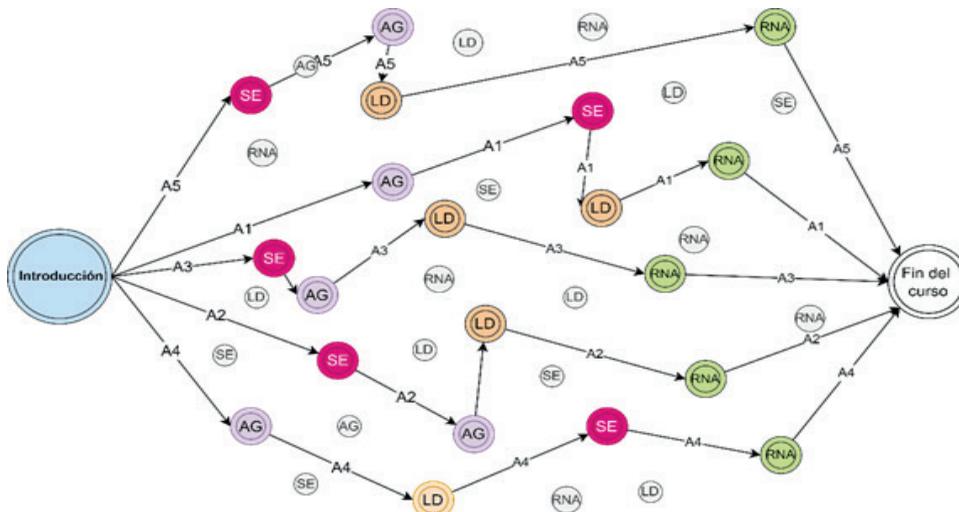
Figura 3. Resultados de la aplicación del cuestionario de Felder-Silverman



Fuente: Construcción personal.

Ruta de aprendizaje: El grupo piloto que utilizó el ambiente e-Learning adaptativo se formó por una muestra seleccionada por conveniencia de cinco estudiantes pertenecientes al octavo semestre, de los cuales, cuatro de ellos se encuentran en la dimensión *Visual* y uno de ellos se encuentra en la dimensión *Sensitivo*. Los resultados de los estudiantes con perfil *Visual* serán representados con la nomenclatura A1 (Alumno1), A2 (Alumno 2), A4 (Alumno 4), A5 (Alumno 5), y un estudiante con perfil *Sensitivo* será representado con la notación A3 (Alumno 3). La Figura 4 muestra los caminos de forma individual de los estudiantes.

Figura 4. Ruta de aprendizaje en el ambiente e-Learning adaptativo de los estudiantes A1 hasta A5



Fuente: Construcción personal.

La calidad de cada ruta y actividades de aprendizaje es medida en términos de una *función de aptitud* (Koza, 1994). Esta función mide el número de instancias correctas e incorrectas. Una instancia correcta representa una coincidencia en la asignación de una actividad de aprendizaje del nivel de la taxonomía de Bloom con el perfil del estudiante (ver Tabla 1). Esta función de aptitud está definida por la ecuación (1)

$$f(k) = \frac{\mu * \max(\sum \sigma i * \Delta i)}{N}$$

Donde:

$f(k)$: es el árbol a evaluar, $k=1$ hasta número de individuos

N : es el número de niveles del árbol ($N=6$)

i : desde 1 hasta N (niveles del árbol)

μ : perfil de aprendizaje (*sensitivo/intuitivo, visual/verbal, activo/reflexivo, secuencial/global*)

Δ_i : 1 si la actividad coincide con el nivel asignado por la taxonomía de Bloom al perfil del estudiante, 0 en otro caso.

α_i : valor de 1 si se encuentra en el nivel Δ_i y el nodo coincide con alguna de las actividades en el nivel Δ_i , y el estilo de aprendizaje μ , 0 en otro caso.

El estado emocional: El reconocimiento del estado emocional en el ambiente e-Learning adaptativo, se realizó mediante el empleo de una RNC, para ello se construyó una base de datos con 466 imágenes de distintas expresiones emocionales de estudiantes de entre 15 y 29 años, la Figura 5 muestra 200 de ellas.

Figura 5. Base de datos con expresiones emocionales



Fuente: Construcción personal.

La base de datos contiene las expresiones emocionales: disgusto, enojo, feliz, miedo, sorpresa y tristeza (Ekman, 1993), (ver Figura 6).

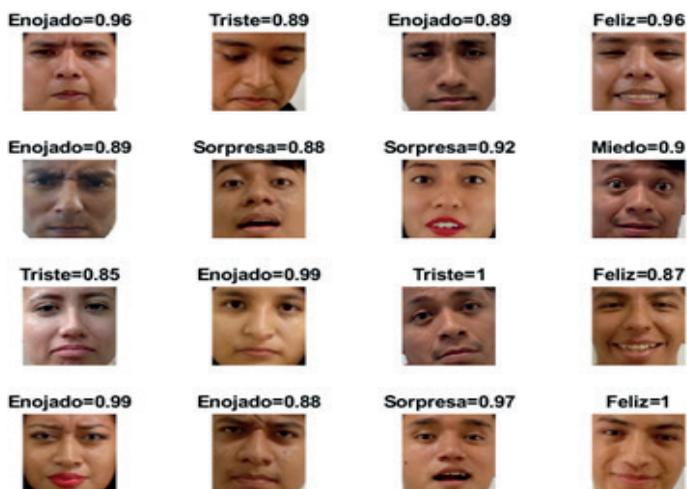
Figura 6. Expresiones prototípicas de Ekman



Fuente: Construcción personal.

Para demostrar la exactitud en el reconocimiento del estado de ánimo, 16 estudiantes fueron clasificados de acuerdo a su expresión emocional, su probabilidad de pertenencia está en el intervalo [0 - 1], 0 = no pertenece, 1= pertenece, (ver Figura 7).

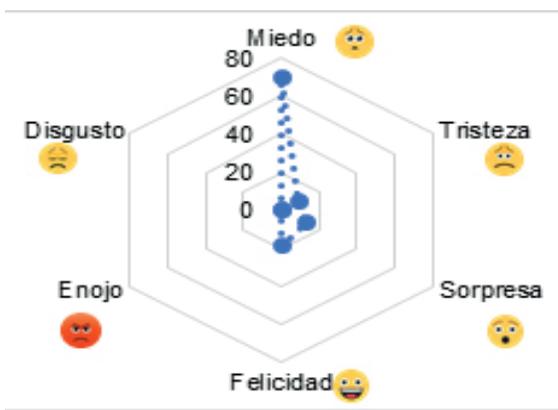
Figura 7. Resultados de 16 personas de acuerdo a su expresión emocional



Fuente: Construcción personal.

Los estados emocionales presentados por los estudiantes durante el curso fueron analizados estadísticamente con máximos, medias y mínimos, esto posibilitó conocer de forma cuantitativa las frecuencias (ver Figura 8). El estado emocional más frecuente fue: *miedo* (70 veces). Los estados de ánimo *tristeza*, *sorpresa* y *felicidad* también ocurrieron, aunque con menor frecuencia (9, 13 y 19 veces), finalmente, dos estados de ánimo muy parecidos, *enojo* y *disgusto* (0 veces), no fueron notables durante el curso.

Figura 8. Estado emocional de estudiantes durante todo el curso



Fuente: Construcción personal

En estos resultados se encontró una estrecha relación de las emociones *sorpresa* y *miedo* con las actividades de aprendizaje del nivel de abstracción "crear" la cual tiene el mayor nivel de complejidad en la taxonomía de Bloom (ver Tabla 2).

Tabla 2. Relación entre "Actividad de aprendizaje / estado de emocional"

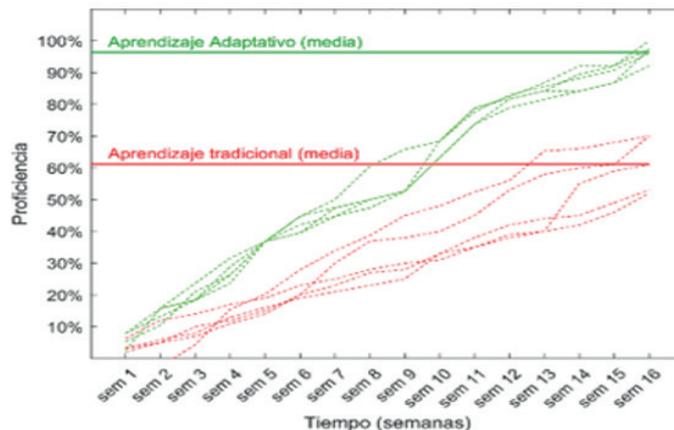
Nivel de abstracción	Estado de ánimo	Actividad de aprendizaje
Crea	😨 😨	Construye, crea, diseña, formula
Evalúa	😟	Selecciona, evalua, argumenta, juzga
Analiza	😨 😊	Compara, critica, diferencia, discrimina
Aplica	😊	Demuestra, ilustra, interpreta
Comprende	😊 😨	Identifica, localiza, reconoce, explica, reporta, selecciona
conoce	😊 😨 😟	Duplica, memoriza, recuerda, define, enlista, memoriza

Fuente: Construcción personal.

Curva de aprendizaje

El aprovechamiento académico de la población es representado por curvas de aprendizaje que muestran los avances obtenidos durante 16 semanas (3 evaluaciones) dentro de las fechas 1 de marzo al 26 de junio de 2022. La Figura 9 muestra en color verde la media y la curva de aprendizaje del grupo de estudiantes que emplearon el ambiente e-Learning adaptativo. En color rojo se observa la curva de aprendizaje del grupo que empleó aprendizaje tradicional. Se considera aprendizaje tradicional el llevado a cabo sin empleo del ambiente e-Learning adaptativo.

Figura 9. Curvas de aprendizaje y valor medio entre aprendizaje adaptativo y aprendizaje tradicional



Fuente: Construcción personal.

Cada estudiante que empleó el ambiente e-Learning adaptativo llevó un ritmo de avance personalizado, este ritmo reflejó un incremento en la media de las calificaciones del grupo de 68.8 a 97.4. El incremento fue notable en comparación con la población que utilizó aprendizaje tradicional en la misma asignatura en el semestre previo.

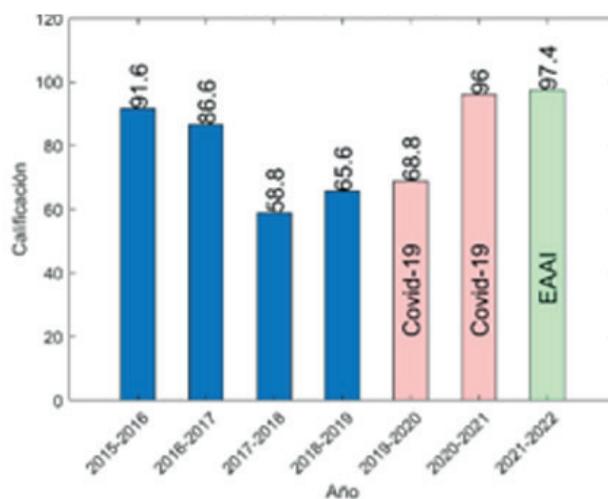
Comparación de resultados con semestres anteriores

Otro punto importante son las diferencias entre la media de la calificación del grupo obtenida con el ambiente de aprendizaje aquí propuesto y la media obtenida en semestres anteriores en la misma asignatura sin el uso de esta herramienta. Para ello se realizó una comparativa tomando en cuenta los semestres dentro de los años 2015 hasta 2022 en la asignatura "Inteligencia Artificial".

En estos resultados (ver Figura 10) se puede observar que la media de la calificación desde 2015 fue de 91.6, pero comenzó a disminuir. Drásticamente decremento a 58.8 en 2017. Era claro que algo estaba ocurriendo y se requería emprender acciones para enfrentar este problema. A partir de 2018 se observó un ligero incremento a 65.6. Desafortunadamente en 2019 llego el COVID-19 y la media de las calificaciones seguía siendo baja: 68.8. Para inicios del 2020, todavía durante la pandemia, la comunidad de docentes y estudiantes habían experimentado las consecuencias de enfrentar un ciclo escolar en línea sin preparación previa y habían adoptado distintas plataformas como Classroom, Moodle, WhatsApp, Skype, Zoom, entre otras, esto generó un grado de familiarización con entornos de aprendizaje virtuales y para inicios del 2021 la media incrementó a 96.0 aún en época de pandemia.

Para mediados del 2021 se desarrolló el ambiente de aprendizaje adaptativo descrito en el presente artículo, mismo que contribuyó al incremento en las calificaciones de los estudiantes y la media pasó de 96.0 en el 2021, a 97.4 a mediados de 2022, fecha en la que concluyó el ciclo escolar.

Figura 10. Media de calificaciones de la asignatura IA desde 2015 a 2022



Fuente: Construcción personal.

Discusión

El modelado del ambiente e-Learning Adaptativo Inteligente aquí presentado permitió demostrar que el desempeño académico puede mejorar significativamente, siempre y cuando los contenidos sean acordes a los perfiles individuales de cada estudiante, desde el inicio hasta el final de un curso. Desde un punto de vista práctico, los resultados aquí presentados muestran ventajas con respecto a los de la literatura revisada (Aissaoui *et al.*, 2019; Castrillón *et al.*, 2020; Hwang *et al.*, 2020; Megahed & Mohammed, 2020; Nisha, 2015; Wang *et al.*, 2020). Una de estas ventajas es el uso de métodos inspirados en la evolución biológica que permiten generar rutas de aprendizaje adecuadas a perfiles individuales. Otra es el empleo de algoritmos del Machine Learning para identificar el estado de ánimo de los estudiantes con menor error y mayor precisión, y con ello conocer la eficiencia del ambiente de aprendizaje adaptativo. Otra ventaja más es la hibridación de los perfiles de Felder-Silverman con las actividades de la taxonomía de Bloom que brindaron opciones para definir actividades de aprendizaje individuales alineadas a los objetivos de la asignatura.

Además, los resultados aquí presentados concuerdan con los hallazgos expuestos por (Castrillón *et al.*, 2020; Mohseni *et al.*, 2014; Nisha, 2015) quienes afirman que en la actualidad es necesario adaptar los contenidos pedagógicos a las necesidades específicas de cada estudiante para obtener más y mejores resultados académicos, dichas necesidades son atendidas en el ambiente de aprendizaje adaptativo propuesto en el presente estudio tomando como referencia los estilos de aprendizaje, tal y como lo recomiendan (Aissaoui *et al.*, 2019; Bajaj & Sharma, 2018; El-Bishouty *et al.*, 2019). Estos resultados también coinciden con (El-Bishouty *et al.*, 2019), quienes afirman que identificar el estilo de aprendizaje del estudiante contribuye a mejorar su desempeño proporcionando actividades acordes a intereses individuales. En este mismo tenor, los resultados reiteran lo mencionado por (Sánchez-Mendiola, 2014), quien hace refiere que el reconocer el estado emocional del estudiante ha sido uno de los retos más difíciles para el docente, tema que es abordado en la presente investigación. De la misma forma, los resultados concuerdan con lo mencionado por (Ekman, 1993), quien afirma que los seis aspectos prototípicos: *felicidad, disgusto, enojo, tristeza, miedo y sorpresa* son suficientes para representar el estado emocional de una persona. También, los hallazgos de esta investigación reflejan de forma semejante lo mencionado por (Brown *et al.*, 2020; Lalitha & Sreeja, 2020) quienes mencionan que las tecnologías emergentes en la educación son el Aprendizaje Adaptativo e Inteligencia Artificial. Por último, los hallazgos también concuerdan con (Boussakssou *et al.*, 2020; Wang *et al.*, 2020) quienes aseveran que los algoritmos basados en Inteligencia Artificial aplicados a la educación encuentran soluciones creativas en tiempo aceptable y se adaptan a las necesidades de la comunidad digital.

Se identificaron las siguientes limitaciones, la población participante estuvo integrada por estudiantes de octavo semestre, por lo que los resultados podrían no ser los mismos en estudiantes de otros niveles. De igual manera, para definir el estilo de aprendizaje del estudiante se limitó al empleo del cuestionario de Felder-Silverman. Nuestro estudio no incluyó variables socio-demográficas tales como la edad, género y lugar de procedencia. Otra limitación fue el número de rasgos prototípicos empleados para identificar el estado de ánimo, dejando fuera al

desinterés, ansiedad, desprecio y estado neutral (Wang *et al.*, 2020). Asimismo, el ambiente de aprendizaje presentado se limita a una sola asignatura, esto quiere decir que la efectividad del ambiente podría ser diferente en otros cursos, por consecuencia el ambiente propuesto debería probarse y evaluarse en un mayor número de estudiantes en varios dominios de aprendizaje.

A partir de las limitaciones anteriores se identificaron las siguientes oportunidades para trabajos futuros: adaptar el ambiente para ser probado en diferentes cursos y en un mayor número de estudiantes; hacer un análisis comparativo con otros métodos de Inteligencia Artificial, incluso hacer una comparación con otras plataformas o ambientes de aprendizaje adaptativo; incorporar mini exámenes al final de cada actividad de aprendizaje, con ello se le exige al estudiante estar actualizado con el tema visto; incluir en el algoritmo Bio-inspirado el perfil del estudiante, la edad, su género y el semestre que cursan; también se considera importante en el ambiente agregar actividades de aprendizaje acordes al estado de ánimo identificado, estas características pueden ayudar a definir nuevas rutas con un enfoque de creatividad e innovación.

Conclusiones

La propuesta del modelado de un ambiente e-Learning Adaptativo Inteligente fue expuesta en el presente estudio, los resultados permitieron conocer que las actividades de aprendizaje individualizado "*construir, crear, diseñar, ilustrar*" contribuyeron a que estudiantes de nivel superior incrementaran su calificación de 68.8 a 97.4, esto no significa que sean las mejores actividades, sin embargo, demostraron ser adecuadas para los perfiles *visual/verbal* y *sensitivo/intuitiva*, del mismo modo, actividades como "*argumenta, evalúa, explica, identifica, e interpreta*", aunque con menor impacto, también contribuyeron a mejorar el promedio de estudiantes con el mismo perfil.

El estado emocional fue otro factor importante considerado en esta investigación, se observó que el "*miedo*" y la "*sorpresa*" fueron los estados de ánimo que la mayoría de estudiantes presentaron al realizar sus actividades de aprendizaje individualizadas, y se encontró que este aspecto está relacionado a la incertidumbre y desconocimiento que mostraron los estudiantes al tener contacto con nuevos ambientes de aprendizaje. Igualmente, los estados de ánimo "*tristeza*" y "*felicidad*" también ocurrieron, aunque con menor frecuencia. Luego, dos estados de ánimo muy parecidos "*enojo*" y "*disgusto*" no fueron notables en la interacción con la plataforma, esto permite conocer que la disposición de los estudiantes al abordar nuevas tecnologías en sus actividades de aprendizaje fue tomada desde una actitud positiva. La relación "*estado de ánimo/calificación*" viene dada por la percepción que el estudiante tiene al abordar nuevos ambientes y/o plataformas de aprendizaje, se encontró que al primer contacto, el alumno percibe estímulos amenazantes al no contar con los conocimientos y recursos suficientes para obtener buenos resultados, generando desde *timidez, enojo, temor, frustración* y *desinterés*. Pero una vez que el estudiante se siente familiarizado, este aspecto va cambiando y se observa poca variación en los estados emocionales de acuerdo al tipo de actividad, dicho de otro modo: cuando se presentan los estados de ánimo *sorpresa* y *miedo* en un ambiente de aprendizaje adaptativo, la tendencia a obtener buenos resultados es mayor y no necesariamente el estudiante debe encontrarse *feliz* o *contento* para obtener buenos resultados.

En resumen:

1. Un ambiente de enseñanza basado en e-Learning adaptativo e Inteligencia Artificial puede apoyar a mejorar el aprovechamiento escolar de estudiantes de nivel superior, quienes demandan actividades basadas en intereses personales.
2. El identificar el perfil de aprendizaje del estudiante favorece en conocer las preferencias que tienen los estudiantes al abordar una situación en un medio ambiente de aprendizaje. Además, permite definir el contenido pedagógico en los programas y planes de estudio en el nivel educativo superior.
3. Reconocer los estados emocionales en el contexto educativo virtual permite asignar contenidos pedagógicos acordes a intereses y preferencias individuales y, al mismo tiempo, evaluar la eficiencia del sistema.
4. La relación *estado de ánimo/calificación* hace referencia a que estados como *sorpres*a y *miedo* generan tendencia a obtener buenas calificaciones.

Referencias

- Ahmady, M., Mirkamali, S. S., Pahlevanzadeh, B., Pashaei, E., Hosseinabadi, A. A. R. y Slowik, A. (2022). *Facial expression recognition using fuzzified Pseudo Zernike Moments and structural features*. *Fuzzy Sets and Systems*, 443, 155-172. <https://doi.org/10.1016/J.FSS.2022.03.013>
- Aissaoui, O. El, El Madani, Y. E. A., Oughdir, L., y Alliou, Y. El. (2019). Combining supervised and unsupervised machine learning algorithms to predict the learners' learning styles. *Procedia Computer Science*, 148, 87-96. <https://doi.org/10.1016/J.PROCS.2019.01.012>
- Albraikan, A. A., Alzahrani, J. S., Alshahrani, R., Yafoz, A., Alsini, R., Hilal, A. M., Alkhayat, A. y Gupta, D. (2022). Intelligent facial expression recognition and classification using optimal deep transfer learning model. *Image and Vision Computing*, 128, 104-132. <https://doi.org/10.1016/J.IMAVIS.2022.104583>
- Krizhevsky, A., Sutskever, I. y Hinton, G. (2017). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 60(6), 84-90. <https://doi.org/https://doi.org/10.1145/3065386>
- Bajaj, R. y Sharma, V. (2018). Smart Education with artificial intelligence based determination of learning styles. *Procedia Computer Science*, 132, 834-842. <https://doi.org/10.1016/j.procs.2018.05.095>
- Birlik, S. (2015). Taxonomy of the Cognitive Domain: An Example of Architectural Education Program. *Procedia - Social and Behavioral Sciences*, 174, 3272-3277. <https://doi.org/10.1016/J.SBSPRO.2015.01.993>
- Bloom, B. S. (1956). Taxonomy of educational objectives. Vol. 1: Cognitive domain. New York: McKay. <http://files/321/Bloom Intro.html>
- Boussakssou, M., Hssina, B. y Erritali, M. (2020). Towards an Adaptive E-learning System Based on Q-Learning Algorithm. *Procedia Computer Science*, 170, 1198-1203. <https://doi.org/10.1016/j.procs.2020.03.028>
- Brown, M., McCormack, M., Reeves, J., Brook, D. C., Grajek, S., Alexander, B., Bali, M., Bulger, S., Dark, S., Engelbert, N., Gannon, K., Gauthier, A., Gibson, D., Gibson, R., Lundin, B., Veletsianos, G. y Weber, N. (2020). *2020 Educause Horizon Report Teaching and Learning Edition*. Denver: EDUCASE. <https://www.learntechlib.org/p/215670/>

- Castrillón, O. D., Sarache, W. y Ruiz-Herrera, S. (2020). Predicción del rendimiento académico por medio de técnicas de inteligencia artificial. *Formación Universitaria*, 13(1), 93-102. <https://doi.org/10.4067/s0718-50062020000100093>
- Cortes, E. y Sánchez, S. (2021). Deep Learning Transfer with AlexNet for Chest X-Ray COVID-19 Recognition. *IEEE Latin America Transactions*, 19(6), 944-951. <https://doi.org/10.1109/TLA.2021.9451239>
- Ekman, P. (1993). Facial expression and emotion. *American Psychologist*, 48(4), 384-392. <https://doi.org/10.1037/0003-066X.48.4.384>
- El-Bishouty, M. M., Aldraiweesh, A., Alturki, U., Tortorella, R., Yang, J., Chang, T.-W. y Graf, S. (2019). Use of Felder and Silverman learning style model for online course design. *Educational Technology Research and Development*, 67(1), 161-177.
- Felder, R. (1996). Matters of style. *ASEE Prism*, 6(4), 18-23. <http://files/278/Felder - 1996 - Matters of style.pdf>
- Felder, R. y Silverman, L. (1988). Learning and Teaching Styles in Engineering Education. *Engineering Education*, 7(78), 674-681.
- Honey, P. y Mumford, A. (1992). *The manual of learning styles* (Vol. 3). Berkshire: Peter Honey Maidenhead. <http://files/276/466244.html>
- Hwang, G., Sung, H., Chang, S. y Huang, X. (2020). A fuzzy expert system-based adaptive learning approach to improving students' learning performances by considering affective and cognitive factors. *Computers and Education: Artificial Intelligence*, 1(August), 100003. <https://doi.org/10.1016/j.caeai.2020.100003>
- Kolb, D. A. (1981). Learning styles and disciplinary differences. *The Modern American College*, 1(January 1981), 232-235.
- Koza, J. R. (1994). Genetic programming as a means for programming computers by natural selection. *Statistics and Computing*, 4(2), 87-112. <https://doi.org/10.1007/BF00175355/METRICS>
- Lalitha, T. B. y Sreeja, P. S. (2020). Personalized Self-Directed Learning Recommendation System. *Procedia Computer Science*, 171(2019), 583-592. <https://doi.org/10.1016/j.procs.2020.04.063>
- Liu, H., Cai, H., Lin, Q., Zhang, X., Li, X. y Xiao, H. (2023). FEDA: Fine-grained emotion difference analysis for facial expression recognition. *Biomedical Signal Processing and Control*, 79, 104209. <https://doi.org/10.1016/J.BSPC.2022.104209>
- Megahed, M. y Mohammed, A. (2020). Modeling adaptive E-Learning environment using facial expressions and fuzzy logic. *Expert Systems with Applications*, 157, 113460. <https://doi.org/10.1016/j.eswa.2020.113460>
- Mohseni, S., Zarei, N. y Ramazani, S. (2014). Facial expression recognition using anatomy based facial graph. *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, 2014-January(January), 3715-3719. <https://doi.org/10.1109/SMC.2014.6974508>
- Nafea, S. M., Siewe, F. y He, Y. (2019). On Recommendation of Learning Objects Using Felder-Silverman Learning Style Model. *IEEE Access*, 7, 163034-163048. <http://files/260/8798626.html>
- Nisha, D. S. (2015). Face Detection and Expression Recognition using Neural Network Approaches. *Global Journal of Computer Science and Technology: F Graphics & Vision*, 15(3), 1-7.
- Pérez, E. C., Rodríguez, A. N., Torre, R. E. M. D. La, Danguillecourt, O. L. y Portela, J. R. D. (2012). Forecast of Wind Speed with a Backpropagation Artificial Neural Network in the

- Isthmus of Tehuantepec Region in the State of Oaxaca, Mexico. *Acta Universitaria*, 22, 7-14. <https://doi.org/10.15174/AU.2012.335>
- Saarni, C., Campos, J. J., Camras, L. A. y Witherington, D. (2007). Emotional Development: Action, Communication, and Understanding. En W. Damon & R. M. Lerner (Eds.), *Handbook of Child Psychology* (Vol. 3, pp. 17-357). New York: John Wiley & Sons, Inc. <https://doi.org/10.1002/9780470147658.chpsy0305>
- Sánchez-Mendiola, M. (2014). ¿Aprender con la mente o con el corazón? Retos de la investigación en educación médica. *Investigación en educación médica*, 3(10), 63-64.
- Sihombing, J. H., Laksitowening, K. A. y Darwiyanto, E. (2020). *Personalized E-Learning Content Based On Felder-Silverman Learning Style Model*. 1-6. <http://files/256/9166452.html>
- Wang, S., Christensen, C., Cui, W., Tong, R., Yarnall, L., Shear, L. y Feng, M. (2020). When adaptive learning is effective learning: comparison of an adaptive learning system to teacher-led instruction. *Interactive Learning Environments*. 1-11. <https://doi.org/10.1080/10494820.2020.1808794>