

Tutor Inteligente: Un Enfoque de Gestión de Aprendizaje Personalizado utilizando el Razonamiento Basado en Casos

Intelligent Tutor: A Personalized Learning Management Approach using Case-Based Reasoning

Benjamin Maraza-Quispe¹, Nicolás Esleyder Cayturo Silva², Erick Abel Arizaca Machaca³
^{1,2,3} Universidad Nacional de San Agustín de Arequipa

Resumen

La aplicación de las Tecnologías de Información y Comunicación en la educación y el impacto de Internet han fomentado el aprendizaje online, rompiendo muchas barreras limitantes de la educación tradicional como el espacio, tiempo, cantidad y cobertura. Sin embargo, las nuevas propuestas afectan la calidad de los servicios educativos, como el acceso lineal a los contenidos, estructuras de enseñanza padronizadas y métodos no flexibles al estilo de aprendizaje de los usuarios. En este contexto se implementa un Modelo Inteligente de Gestión de Aprendizaje Personalizado en un Ambiente de Simulación Virtual Basado en Instancias de Objetos de Aprendizaje, con el objetivo de identificar el mejor estilo de aprendizaje de un estudiante para proporcionarle el mejor objeto de aprendizaje, utilizando para ello una función de similaridad a través la Distancia Euclidiana Multidimensional Ponderada. Se valida la propuesta a través de una cross validation y la experimentación e la plataforma MIGAP (Modelo Inteligente de Gestión de Aprendizaje Personalizado), para el montaje de cursos de dominio de la Mecánica Newtoniana. Los resultados muestran que el modelo propuesto tiene una eficiencia de clasificación de un 100%; por encima de los modelos: Simple Logistic con un 99.50%, Naïve Bayes con un 97.98%, Tree J48 con un 96.98%, y Redes Neuronales con un 94.97% de aciertos. La aplicación de este modelo en otras áreas del conocimiento permitirá la identificación del mejor estilo de aprendizaje; con la finalidad de permitir que los recursos, actividades y servicios educativos sean flexibles al estilo de aprendizaje del estudiante, mejorando la calidad de los servicios educativo.

Palabras clave: Modelo, Sistema, Gestión, Aprendizaje, Estilos de Aprendizaje, Razonamiento Basado en Casos.

Abstract

The application of Information and Communication Technologies in education and the impact of the Internet have fostered online learning, breaking many limiting barriers of traditional education such as space, time, quantity, and coverage. However, these new approaches affect the quality of educational services, such as linear access to content, standardized teaching structures, and inflexible methods that do not adapt to users' learning styles. In this context, an Intelligent Model for Personalized Learning Management is implemented in a Virtual Simulation Environment based on Instances of Learning Objects, with the aim of identifying the best learning style for a student and providing them with the most suitable learning object. This is accomplished by using a similarity function based on Weighted Multidimensional Euclidean Distance. The proposal is validated through cross-validation and experimentation on the MIGAP (Intelligent Model for Personalized Learning Management) platform for the design of courses on Newtonian Mechanics. The results show that the proposed model achieves a classification efficiency of 100%, surpassing other models such as Simple Logistic with 99.50%, Naïve Bayes with 97.98%, Tree J48 with 96.98%, and Neural Networks with 94.97% accuracy. The application of this model in other knowledge areas will allow for the identification of the best learning style, aiming to make educational resources, activities, and services flexible to the student's learning style and improve the quality of educational services.

Keywords: Model, System, Management, Learning, Learning styles, Case-Based Reasoning.

Introducción

Los estudiantes tienen diferentes ritmos y estilos de aprendizaje de acuerdo a sus necesidades educativas (Inan, 2023). Al brindar una enseñanza padronizada, se limita la capacidad de adaptar el contenido y los métodos de enseñanza a las características individuales de los estudiantes (Maraza-Quispe, et al., 2023). Esto puede dificultar su comprensión y retención de la información, y puede llevar a la falta de motivación y compromiso ya que la enseñanza padronizada tiende a centrarse en la transmisión de información y en la memorización de datos, esto limita las oportunidades para fomentar la creatividad, el pensamiento crítico y la resolución de problemas (Maraza-Quispe, et al., 2022). Los estudiantes no tienen la oportunidad de explorar diferentes enfoques, plantear preguntas

¹ **Correspondencia:** Benjamín Maraza-Quispe, bmaraza@unsa.edu.pe.

desafiantes o desarrollar habilidades de pensamiento crítico que son esenciales en el mundo actual. En el mundo actual, se requieren habilidades como el pensamiento crítico, la resolución de problemas, la colaboración y la creatividad para tener éxito. Sin embargo, una enseñanza padronizada se centra en la transmisión de conocimientos teóricos y no brinda oportunidades para desarrollar estas habilidades del siglo XXI. Esto puede dejar a los estudiantes mal preparados para enfrentar los desafíos del mundo real y limitar su capacidad de adaptarse y prosperar en entornos cambiantes (Maraza-Quispe, et al., 2020). Cuando los estudiantes experimentan una enseñanza padronizada, es más probable que se sientan desmotivados y desconectados del proceso de aprendizaje. La falta de variedad, personalización y relevancia puede hacer que perciban el aprendizaje como aburrido, lo que afecta negativamente su compromiso y su disposición a participar activamente.

La Inteligencia Artificial (IA) aplicada a la educación constituye un campo creciente de interés, donde se trata fundamentalmente de aportar en la formulación y aplicación de técnicas al desarrollo de sistemas que soporten los procesos de enseñanza y de aprendizaje asistidas por computador con el propósito de construir sistemas más inteligentes (Carbonel, 2009). El término “inteligente” utilizado en estos sistemas queda determinado fundamentalmente por su capacidad de adaptación continua a las características del aprendizaje y del conocimiento de los diferentes usuarios (Wenger, 2007).

En el ámbito de la Inteligencia Artificial aplicada a la educación, las investigaciones están enfocadas en el desarrollo de sistemas para la educación, basándose aspectos del conocimiento (Vicari, 2020). En la figura 1 se muestra las principales técnicas de la IA que se aplican a la educación.




Figura 1. Principales técnicas de IA aplicadas a la educación. Adaptado de (Vicari, 2020).

Según (Caro et al., 2015) elaboraron un curso en cinco lecciones con un nivel básico de complejidad para explicación de conceptos sobre fundamentos de programación. De acuerdo con la metodología MODESEC, el estudiante puede efectuar cambios a recomendaciones realizadas por el sistema y en este caso, se calificará como una recomendación inapropiada. Si la cantidad de cambios necesarios para ajustar una estrategia pedagógica de acuerdo con el perfil del estudiante es alta, el nivel de personalización será bajo. Los autores, no evaluaron el rendimiento académico sobre dicha asignatura, sino la pertinencia de una estrategia recomendada por parte del sistema.

En la investigación desarrollada por (Abdullah et al., 2017), los autores compararon entre notas finales de dos secciones de un curso de programación. Una de las secciones se enseñó tradicionalmente y la otra, se adaptó para que coincidiera el estilo de aprendizaje del estudiante con el estilo de enseñanza del profesor. En este caso, los resultados experimentales mostraron un gran contraste entre las calificaciones finales de los estudiantes de ambas secciones.

Asimismo, (Supangat et al., 2020) demostraron que los módulos realizados pueden ayudar a los profesores para distribuir el material de adecuado a los estilos de aprendizaje de los estudiantes ayudando a que los estudiantes estudien más eficazmente de acuerdo con sus preferencias. Dentro de las componentes del modelo, se tienen: una biblioteca multimedia, un repositorio de objetos de aprendizaje, un estudiante modelo (caso), un modelo de instrucción, un motor adaptativo y una interfaz de usuario.

Finalmente, (Karagiannis et al., 2018) proporcionan en su estudio, un enfoque que detecta el estilo de aprendizaje de los estudiantes con el fin de proporcionar cursos adaptables en Moodle e incluye una herramienta novedosa que es la evaluación de la interacción de los estudiantes con los diferentes recursos. Para esta investigación, se formaron dos grupos de estudiantes: el experimental y el de control. El primero tuvo acceso a un curso de Moodle que detectó automáticamente sus estilos de aprendizaje y tenía un mecanismo adaptativo, mientras que el segundo tenía acceso a una versión estándar de un curso de Moodle. Demostraron que el grupo del curso adaptativo tuvo un mejor desempeño y una mayor motivación para el desarrollo de la asignatura.

Los estilos de aprendizaje son los rasgos cognoscitivos, afectivos y fisiológicos que sirven como indicadores relativamente estables, de cómo los alumnos perciben interacciones y responden a sus ambientes de aprendizaje (Aguilera, 2009). Se puede concluir que cada persona tiene su propia “huella digital” de aprendizaje. Cada persona desarrolla y potencia cierta estrategia (algunos aprenden de su lectura, otros practicando, algunos del trabajo en grupo, otros del trabajo aislado), sin embargo, todos poseemos en diferentes porcentajes algún rasgo de los diferentes estilos de aprendizaje.

Los modelos que se mencionan a continuación se enfocan en el proceso de aprendizaje, razón por lo cual son analizados en la investigación desarrollada.

El modelo de Honey, basado en el modelo de Kolb, especifica 4 estilos de aprendizaje (Alonso, 2004): Estilos: Activo, reflexivo, teórico y pragmático.

Tabla 1
Características de cada estilo de aprendizaje (Alonso, 2004).

Estilos de Aprendizaje	Principales Características
Activo	Animador, Improvisador, Descubridor, Arriesgado, Espontáneo
Reflexivo	Ponderado, Conciencioso, Receptivo, Analítico, Exhaustivo
Teórico	Metódico, Lógico, Objetivo, Crítico, Estructurado
Pragmático	Experimentador, Práctico, Directo, Eficaz, Realista

Métodología

El objetivo principal de la presente investigación, es desarrollar métodos dinámicos para la búsqueda e identificación del mejor estilo de aprendizaje de un estudiante para proporcionarle los recursos y actividades de acuerdo a este estilo de aprendizaje. Estos métodos son aplicados en tiempo real, utilizando una técnica de la Inteligencia Artificial denominada el Razonamiento Basado en Casos (RBC); a través, de la función de similaridad, utilizando la Distancia Euclidiana Multidimensional Ponderada. El RBC proveerá un método para la personalización de la mejor estrategia de aprendizaje. La eficiencia en cuanto a selección de estilos de aprendizaje vía RBC son comparados con los resultados obtenidos por otros algoritmos de selección de estilos de aprendizaje como: Redes Neuronales, Naive Bayes, Tree J48 y Simple Logistic. En este contexto se diseña e implementa la plataforma MIGAP (Modelo Inteligente de Gestión de Aprendizaje Personalizado), para presentar contenidos de aprendizaje, los cuales se adaptan al mejor estilo de aprendizaje de acuerdo al modelo de (Alonso, 2004)

Técnica de la Inteligencia Artificial aplicada a la propuesta

La técnica de la Inteligencia Artificial aplicada es el Razonamiento Basado en Casos, la cual en una primera instancia detecta el estilo de aprendizaje del estudiante para determinar la mejor estrategia de aprendizaje que se adecue mejor a este estilo de aprendizaje. El RBC es el proceso de solucionar nuevos problemas basándose en las soluciones de problemas anteriores.

Razonamiento Basado en Casos

El Razonamiento Basado en Casos (RBC) es un cuerpo de conceptos y técnicas que tocan temas relacionados a la representación del conocimiento, razonamiento y aprendizaje a partir de la experiencia (Pal, 2014). La similaridad es el concepto que juega un papel fundamental en el RBC.

Definición de un caso

También conocido como instancia, objeto o ejemplo. Puede ser definido como una pieza de conocimiento contextualizado que representa una experiencia significativa.

Etapas de RBC

Las principales etapas son cuatro: Recuperación, Reutilización, Revisión y Retención. Estas cuatro etapas envuelven tareas básicas como: agrupamiento y clasificación de casos, selección y generación de casos, aprendizaje e indexación de casos, medición de similaridad de casos, recuperación e inferencia de casos, razonamiento, reglas de adaptación y minería de datos.

Ciclo de vida de RBC

El ciclo de vida para la solución de problemas usando un sistema RBC consta de cuatro estados.

- Recuperación de casos similares de una base de experiencia.
- Reutilización de casos mediante copia o integración de soluciones desde los casos recuperados.
- Revisión o Adaptación de la solución(es) recuperada(s) para resolver el nuevo problema
- Retención de una nueva solución, una vez haya sido confirmada o validada.




Figura 2. Ciclo de vida del RBC (Pal, 2014).

Distancia euclidiana ponderada

Basado en la ubicación de los objetos en el espacio Euclidiano, se recupera un conjunto ordenado de números reales que representan las distancias más cortas entre objetos.

Formalmente la distancia Euclidiana entre los casos es expresada de la siguiente manera. Donde se denota $CB = \{e_1; e_2; \dots e_N\}$ la librería de N casos, representando a la base de datos de estilos de aprendizaje (Maraza-Quispe, 2019)

Cada caso en esta librería está representado por un índice de su correspondiente característica, además cada caso está asociada a una etiqueta de identificación.

La distancia métrica ponderada puede definirse como:

$$d_{pq}^{(w)} = d^{(w)}(e_p, e_q) = \left[\sum_{j=1}^n w_j^2 (x_{pj} - x_{qj})^2 \right]^{\frac{1}{2}} = \left(\sum_{j=1}^n w_j^2 x_j^2 \right)^{\frac{1}{2}} \quad (1)$$

La distancia entre dos casos e_p y e_q se calcula mediante:

$$d_{pq}^w = \sqrt{\sum_{j=1}^n w_j^2 \rho_j^2(e_{pj}, e_{qj})}$$

Arquitectura del modelo propuesto

La arquitectura del modelo propuesto tiene tres componentes principales: una interfaz de usuario, un motor de inferencia y una base de casos. La base de casos contiene las descripciones de los problemas resueltos previamente en forma de rasgos (predictores y objetivos). Cada caso puede describir un episodio particular o una generalización de un conjunto de episodios relacionados. El motor de inferencia es la máquina de razonamiento del sistema, la cual

compara el problema insertado con los que están almacenados en la base de casos y como resultado infiere una respuesta con el mayor grado de semejanza a la que se busca. La interfaz de usuario permite la comunicación entre el sistema y el usuario, dando la posibilidad de interactuar con la base de casos, plantear nuevos problemas y consultar los resultados inferidos.

El modelo incorpora a la arquitectura clásica de un Sistema Tutor Inteligente, un proceso de selección de objetos de aprendizaje (contenidos), influenciado por las estrategias de enseñanza de los estilos de aprendizaje del alumno. Estas estrategias de enseñanza serán el vínculo de los objetos de aprendizaje a través de las estrategias de enseñanza-aprendizaje aplicadas al diseño de los contenidos del curso.




Figura 3. Arquitectura general del modelo propuesto.

La estructura general del modelo propuesto: Sistema Inteligente de Gestión de Aprendizaje personalizado considera los estilos de aprendizaje de los estudiantes, integrando el Razonamiento Basado en Casos, para la selección de las estrategias de enseñanza-aprendizaje y para la identificación del estilo de aprendizaje con mayor énfasis. La arquitectura plantea innovaciones en la representación del módulo tutor y del módulo de conocimiento. En particular, en el módulo tutor se incorpora la técnica del RBC, el cual se encargará de elegir los contenidos considerando las estrategias de enseñanza que favorezcan los estilos de aprendizaje del alumno.

El módulo de conocimientos está influenciado por las estrategias de enseñanza de los estilos de aprendizaje del alumno. Estas estrategias de enseñanza serán el vínculo de los objetos de aprendizaje a través de las estrategias de enseñanza-aprendizaje aplicadas al diseño de los contenidos del área.

A continuación, se describen las modificaciones realizadas a los módulos de la arquitectura general del Sistema Tutorial Inteligente:

a) Módulo tutor

En el módulo tutor se incorporan las estrategias de enseñanza-aprendizaje consideradas en el diseño de los temas de los diferentes cursos, así como la redefinición de las estrategias de enseñanza según el estilo de aprendizaje del alumno. También se incorporan un proceso para adecuar los contenidos que se presentarán:

Identificar los estilos de aprendizaje.

Seleccionar los temas a mostrar al alumno, vinculando su estilo de aprendizaje con las estrategias de enseñanza utilizadas en la creación de los temas y así favorecer su aprendizaje.

En el módulo de conocimiento se añade una base de datos que almacenará las competencias de la asignatura. Así como la utilización de algunos metadatos en los contenidos del curso para caracterizar las competencias que se buscan desarrollar.

El módulo de interfaz mostrará los objetos de aprendizaje elegidos por el proceso de selección del módulo tutor.

Se añade el módulo del Razonamiento Basado en Casos, el cual es un enfoque que aborda nuevos problemas

tomando como referencia problemas similares resueltos en el pasado. De modo que problemas similares tienen soluciones similares.




Figura 4. Módulo tutor.

La base de casos está conformada por resultados del test de (Alonso, 2004) realizada a 199 estudiantes en donde se puede apreciar el estilo de aprendizaje predominante y las preferencias a cuanto al material que utilizan para comprender un determinado contenido. En la Figura 4 se pueden observar la base de casos utilizada.

b) Módulo del conocimiento y estudiante

Como primer paso se crean e importan los objetos de aprendizaje (OA) al LMS. Los OA son definidos como cualquier entidad, digital o no digital, que puede ser usada, reutilizada o referenciada durante el aprendizaje soportado por tecnología. Los OA son diseñados e implementados utilizando diversos programas, integrando en estos programas los materiales didácticos (texto, video, imágenes, sonido, simulaciones, etc.).

Una vez importados los OA al módulo de conocimiento, se inicia el proceso determinando el estilo de aprendizaje que posee el estudiante y la personalización de contenidos de aprendizaje.





Figura 5. Módulo del conocimiento y módulo estudiante.

c) Módulo del Razonamiento basado en casos

En el módulo RBC se recupera un caso semejante al nuevo y la solución del problema recuperado se propone como solución potencial del nuevo problema. Esto se deriva de un proceso de adaptación en el cual se adecua la vieja solución a la nueva situación. Estos sistemas definen una serie de pasos y componentes que interactúan en un ciclo de razonamiento. A partir de un nuevo problema son recuperados los casos similares al introducido, que posteriormente pasan por un proceso de adaptación lográndose una respuesta acorde a la situación planteada. Luego, de ser necesario y posterior a su revisión, el sistema decide si aprender o no la solución dada. Lo



anteriormente expuesto es considerado el ciclo de razonamiento basado en casos como se muestra en la figura 6.

Figura 6. Módulo Razonamiento Basado en Casos.

Validación del modelo propuesto

En la experimentación realizada la base de datos está conformada por 199 estudiantes, la cual de acuerdo con sus estilos de aprendizaje son ingresados al mecanismo Razonador Basado en Casos, previo a un proceso de indexación de casos, recupera casos usando como medida de similaridad la distancia euclidiana en n dimensiones. Concluido el proceso de evaluación el ganador es revisado, retornando el contenido personalizado de acuerdo al estilo de aprendizaje ingresado, si este caso es significativo es retenido; tal como se observa en la figura 4. (Ver base de casos aquí)

Para llevar a cabo la experimentación se experimentó en la plataforma MIGAP con la finalidad de determinar el estilo de aprendizaje predominante, se analizaron las frecuencias de los estilos de aprendizaje detectados a cada uno de los estudiantes de cada curso, para conocer si estos influyeron en el desempeño de los estudiantes.

En el gráfico 7 se puede observar que 37 estudiantes poseen el estilo de aprendizaje activo, 59 estudiantes poseen el estilo de aprendizaje reflexivo, 44 estudiantes poseen el estilo de aprendizaje teórico y 59 estudiantes poseen el estilo de aprendizaje pragmático.




Figura 7. Estilos de aprendizaje detectados.

Resultados

Para evaluar los resultados de la propuesta con otros algoritmos se utiliza la técnica de la validación cruzada o cross-validation que es utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones.

Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar cómo de preciso es el modelo que se llevará a cabo a la práctica. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

En la tabla 2 presenta los resultados obtenidos aplicando RBC donde el porcentaje de acierto es del 100% y un porcentaje de error del 0% para ello se utiliza una búsqueda por similitud a través, de la Distancia Euclidiana Ponderada. Teniendo como datos de entrada los estilos de aprendizaje obtenidos a través del test de (Alonso, 2004) y las preferencias de estrategias de enseñanza obtenida a través de una encuesta.

Tabla 2
Matriz de Confusión aplicando RBC.

Estilos de Aprendizaje	Activo	Reflexivo	Teórico	Pragmático	Datos	Datos	Errores
Activo	51	0	0	0	51	51	0
Reflexivo	0	48	0	0	48	48	0
Teórico	0	0	53	0	53	53	0
Pragmático	0	0	0	47	47	47	0
Porcentaje de aciertos y errores						199	0
						100.0%	0.00%

En la tabla 3 se puede ver los resultados obtenidos a través del algoritmo Simple Logistic con un porcentaje de acierto del 98.99%. El algoritmo Simple Logistic resulto ser el segundo mejor en la lista; esto se debe a que, si bien logró clasificar correctamente una gran cantidad de instancias positivas, también clasificar de manera errónea instancias negativas con un promedio de 0.003.

Tabla 3
Matriz de Confusión aplicando el Algoritmo Simple Logistic.

Estilos de Aprendizaje	Activo	Reflexivo	Teórico	Pragmático	Datos	Datos	Errores
Activo	37	0	0	0	37	37	0
Reflexivo	0	58	0	0	59	58	1
Teórico	0	0	44	0	44	44	0
Pragmático	0	0	0	59	59	59	0
Porcentaje de aciertos y errores						198	1
						99.5%	0.50%

En la tabla 4 podemos ver los resultados obtenidos a través del clasificador Naive Bayes con un porcentaje de acierto del 97.98%. Se trata de una técnica de clasificación y predicción supervisada que construye modelos que predicen la probabilidad de posibles resultados. Constituye una técnica supervisada porque necesita tener ejemplos clasificados para que funcione.

Tabla 4
Matriz de Confusión aplicando el Algoritmo Naive Bayes.

Estilos de Aprendizaje	Activo	Reflexivo	Teórico	Pragmático	Datos	Datos	Errores
Activo	35	0	0	2	37	35	2
Reflexivo	0	58	1	0	59	58	1
Teórico	0	0	44	0	44	44	0
Pragmático	1	0	0	58	59	58	1
Porcentaje de aciertos y errores						195	4

97.98% 2.01 %

En la tabla 5 se presentan los resultados obtenidos a través del clasificador Tree J48 con un porcentaje de acierto del 96.98%. Los árboles de decisión constituyen un método de aprendizaje y clasificación muy utilizado, debido a la facilidad de organización y comprensión del conocimiento que proponen. Un árbol de decisión representa un conjunto de restricciones o condiciones que se organizan de forma jerárquica y que se aplican sucesivamente desde una raíz hasta llegar a un nodo terminal u hoja del árbol.

Tabla 5
Matriz de Confusión aplicando el Algoritmo Tree J48.

Estilos de Aprendizaje	Activo	Reflexivo	Teórico	Pragmático	Datos	Datos	Errores
Activo	37	0	0	0	37	37	0
Reflexivo	0	54	4	1	59	54	5
Teórico	0	1	43	0	44	43	1
Pragmático	0	0	0	59	59	59	0
Porcentaje de aciertos y errores						193	6
						96.48%	3.01 %

En la tabla 6 se presenta los resultados obtenidos a través del clasificador Redes Neuronales con un porcentaje de acierto del 94.97% y un porcentaje de error de 5.02%.

Tabla 6
Matriz de Confusión aplicando Redes Neuronales.

Estilos de Aprendizaje	Activo	Reflexivo	Teórico	Pragmático	Datos	Datos	Errores
Activo	35	0	0	2	37	35	2
Reflexivo	0	55	4	0	59	55	4
Teórico	0	4	40	0	44	40	4
Pragmático	0	0	0	59	59	59	0
Porcentaje de aciertos y errores						189	10
						94.97%	5.02%

En la figura 8 se puede observar que el mayor número de aciertos en la clasificación corresponden a la técnica propuesta del Razonamiento Basado en Casos con un 99.50% de aciertos y un 0.5% de error, en contraposición con la utilización de las demás técnicas utilizadas que tiene un porcentaje de aciertos por debajo de la propuesta.




Figura 8. Comparación del índice de error de RBC con otras técnicas.

Se aprecia que el mayor número de casos correctamente clasificados corresponde al RBC, con un error absoluto medio de 0%. Luego de realizadas las comparaciones con otros algoritmos de clasificación le siguen en segundo

lugar el algoritmo Simple Logistic, en tercer lugar, el algoritmo Naive Bayes, en cuarto lugar, el algoritmo Tree J48 y en quinto lugar por debajo de las anteriores el algoritmo de Redes Neuronales Artificiales.

En la tabla 7 se observa que los mejores resultados de las técnicas presentadas, son obtenidas por el RBC, con una eficiencia del 100% vs el 98.99% obtenido por el clasificador Simple Logistic, le sigue el clasificador Naive Bayes que obtiene una eficiencia del 97.98% seguidamente tenemos al clasificador Tree J48 con una eficiencia del 96.98% y por último tenemos al clasificador Perceptron Multicapa con una eficiencia del 94.97 %. Además, se presenta la comparación del índice de error de la propuesta es de 0% con el índice de error de las demás propuestas.

Tabla 6

Matriz de Confusión aplicando Redes Neuronales.

Estilos de Aprendizaje	Datos clasificados correctamente	Datos clasificados incorrectamente	Precisión	Instancias correctamente clasificadas	Precisión y resiliencia	Área de características operativas del receptor
Activo	1	0	1	1	4	1
Reflexivo	0.966	0	1	0.966	0.983	1
Teórico	0.967	0.015	1	0.967	0.978	1
Pragmático	1	0.014	0.967	1	1	1
Activo	0.99	0.007	0.99	0.99	0.99	1

Discusión y conclusiones

De acuerdo con los resultados obtenidos, se debe considerar la importancia de contrastar modelos de aprendizaje y modelos curriculares en términos de personalización. Es importante recordar que un sistema altamente técnico con poco contenido de aprendizaje desanimará a los estudiantes a usarlo. Por otro lado, se ha observado que se han desarrollado varios enfoques diferentes para los modelos de personalización de IA, principalmente desarrollados desde un punto de vista conceptual, y el dominio de la aplicación sigue siendo un caso de uso actual muy específico y principalmente relacionado con el dominio de sistemas y Tecnologías de información. Esto está en línea con (Raj, 2021), quienes argumentaron que los sistemas en este dominio serán sistemas autónomos ubicuos que utilizan el conocimiento de los sistemas de recomendación. Por otro lado, los resultados muestran un alto potencial de la IA en diferentes procesos de aprendizaje, lo que está en línea con (Bouzenada et al., 2018), ya que el contenido de aprendizaje se puede adaptar y adaptar directamente al conocimiento y las competencias de dominio del alumno individual. Algunos datos importantes de las técnicas de personalización revisadas: Desde una perspectiva pedagógica, es necesario mirar la intencionalidad, el desarrollo de contenidos, las relaciones y los criterios de evaluación. Desde el punto de vista del currículo, el principio de unicidad es evidente, porque no se puede ignorar el entorno educativo y la formación y dinámica de los alumnos, porque el discurso educativo no es estático, al contrario, es constante. cambiar. Vuelve y cambia según el resultado. Los estudiantes pueden evaluar la adecuación de los recursos asignados y, además, proporcionar retroalimentación sobre el proceso. Las herramientas técnicas apoyan y optimizan el proceso de selección de recursos. Los estudiantes son más conscientes de sus procesos y estilos de aprendizaje (Urretavizcay-Loinaz, 2022). Si bien los elementos técnicos son importantes en la adaptación de los objetos de aprendizaje, no existe evidencia que sustente la evaluación de intervenciones específicas para mejorar el aprendizaje a partir de los datos proporcionados por estos sistemas en sus casos de uso. Esto también está de acuerdo con (Tetzlaff et al., 2021) quienes argumentan que la personalización es más exitosa cuando las características relevantes del alumno se miden repetidamente durante el proceso de aprendizaje y estos datos se utilizan para adaptar sistemáticamente el entrenamiento, un aspecto fundamental de la inteligencia artificial.

El enfoque de esta reflexión retrospectiva permitirá el desarrollo futuro de un modelo personalizado que incorpore aspectos relevantes de diferentes enfoques para apoyar las estrategias de aprendizaje para mejorar el rendimiento de los estudiantes (Maraza-Quispe, 2022). En el campo de la investigación, la interfaz de la inteligencia artificial y la educación continua es un método desafiante de trabajo en la enseñanza y el aprendizaje (Murray, 2028).

Se desarrolla la arquitectura y funcionamiento de un Modelo Inteligente de Gestión de Aprendizaje Personalizado basado en instancias de objetos de aprendizaje cuyos resultados muestran que el modelo propuesto tiene una eficiencia de un 100%; por encima de los modelos: Simple Logistic con un 99.98%, Naive Bayes con un 97.98%, Tree J48 con un 96.98%, y Redes Neuronales con un 94.97% de aciertos.

Se valida la propuesta utilizando la técnica del Razonamiento Basado en Casos, se aprecia un comportamiento eficiente y significativo en la personalización de contenidos de acuerdo al estilo de aprendizaje de los estudiantes.

Las pruebas con este prototipo permiten proyectar que el uso de esta tecnología e-Learning afectaría directamente en la calidad educativa de la región. Permitiendo optimizar algunos elementos del proceso de aprendizaje que aún

son tradicionales en nuestro medio.

Por otro lado, como muestra la estructura del modelo, los campos de estudio más comunes son los fundamentos de la programación o campos relacionados con la ingeniería de sistemas, ya que los instructores de diseño son aptos en informática. Como parte de las posibilidades de aplicar tecnologías de IA en el campo de la educación, también se evidencia que estas tecnologías son universales. Por lo tanto, no hay dos métodos que puedan realizar la misma tarea y la mayoría de los estudios utilizan métodos diferentes para comparar los resultados. Finalmente, este estudio no identificó estudios que incluyeran conocimientos previos, estilos de aprendizaje y otras variables no académicas que contribuyeran a los modelos de personalización de manera integrada. Como contribución a futuras investigaciones, se sugiere considerar los modelos de aprendizaje y currículo al desarrollar modelos de personalización. Además, se deben comparar los métodos disponibles en la literatura para evaluar sus fortalezas y debilidades. Por otro lado, no debe olvidarse el contexto de la población en la que se enfoca el modelo, que depende no solo del currículo que se imparte, sino también de los objetivos didácticos, los recursos y la disponibilidad de datos disponibles para los estudiantes.

Referencias

- Abdullah, M., Bayahya, A. Y., Ba Shammakh, E. S., Altuwairqi, K. A., & Alsaadi, A. A. (2017). A novel adaptive e-learning model matching educator-student learning styles based on machine learning. *Communication, Management and Information Technology - Proceedings of the International Conference on Communication, Management and Information Technology, ICCMIT 2016*, 773–782. <https://doi.org/10.1201/9781315375083-109>
- Aguilera Pupo, E., & Ortiz Torres, E. (2009). Las investigaciones sobre los estilos de aprendizaje y sus modelos explicativos. *Revista De Estilos De Aprendizaje*, 2(4). <https://doi.org/10.55777/rea.v2i4.887>
- Alonso C., Gallego D y Honey P. (2004). “Los estilos de aprendizaje: procedimientos de diagnóstico y mejora”. 2nd ed. Bilbao: Ediciones Mensajero, 1994. Páginas. 104-116. ISBN: 84-271-1914-3. Bilbao, España. <https://n9.cl/mhj8o>
- Bouzenada, S. N. E., Zarour, N. E., & Boissier, O. (2018). An agent-based approach for personalised and adaptive learning. *International Journal of Technology Enhanced Learning*, 10(3), 184. <https://doi.org/10.1504/ijtel.2018.10010193>
- Carbonell, J. R. (2021). AI in CAI: An artificial-intelligence approach to computer-assisted instruction. *IEEE transactions on man-machine systems*, 11(4), 190-202. DOI: 10.1109/TMMS.1970.299942
- Caro, M. F., Josyula, D. P., & Jiménez, J. A. (2015). Modelo pedagógico multinivel para la personalización de estrategias pedagógicas en sistemas tutoriales inteligentes. *DYNA (Colombia)*, 82(194), 185–193. <https://doi.org/10.15446/dyna.v82n194.49279>
- Inan, D. I., Hidayanto, A. N., Juita, R., Hasian, C. Y., & Luvian, K. (2023). How personal, technical, social environments affecting generation Z to utilise video-based sharing platform in learning process during crisis? DOI 10.58459/rptel.2024.19003
- Karagiannis, I., & Satratzemi, M. (2018). An adaptive mechanism for Moodle based on automatic detection of learning styles. *Education and Information Technologies*, 23(3), 1331–1357. <https://doi.org/10.1007/s10639-017-9663-5>
- Maraza-Quispe, B., Alejandro-Oviedo, O. M., Llanos-Talavera, K. S., Choquehuanca-Quispe, W. and Cayturo-Silva, S. A.-P. (2023). Towards the Development of Emotions through the Use of Augmented Reality for the Improvement of Teaching-Learning Processes. *International Journal of Information and Education Technology*, 56-63. doi: 10.18178/ijiet.2023.13.1.1780
- Maraza-Quispe, B., Valderrama-Chauca, E., Cari-Mogrovejo, L., Apaza-Huanca, J. and Sanchez-Ilabaca, J. (2022). "A Predictive Model Implemented in KNIME Based on Learning Analytics for Timely Decision Making in Virtual Learning Environments," *International Journal of Information and Education Technology* vol. 12, no. 2, pp. 91-99. doi: 10.18178/ijiet.2022.12.2.1591
- Maraza-Quispe, B., Valderrama-Chauca, E., Cari-Mogrovejo, L., Apaza-Huanca, J. and Sanchez-Ilabaca, J. "A Predictive Model Implemented in KNIME Based on Learning Analytics for Timely Decision Making in Virtual Learning Environments," *International Journal of Information and Education Technology* vol. 12, no. 2, pp. 91-99, 2022. doi: 10.18178/ijiet.2022.12.2.1591
- Maraza-Quispe, B., Olga Melina Alejandro-Oviedo, Walter Choquehuanca-Quispe, Alejandra Hurtado-Mazeyra and Walter Fernandez-Gambarini, “e-Learning Proposal Supported by Reasoning based on Instances of Learning Objects” *International Journal of Advanced Computer Science and Applications (IJACSA)*, 10(10), 2019. <http://dx.doi.org/10.14569/IJACSA.2019.0101035>
- Maraza-Quispe, B., Alejandro-Oviedo, O., Choquehuanca-Quispe, W., Cayturo-Silva, Nicolas and Herrera-Quispe, J. (2020). “Towards a Standardization of Learning Behavior Indicators in Virtual Environments” *International Journal of Advanced Computer Science and Applications (IJACSA)*, 11(11).

<http://dx.doi.org/10.14569/IJACSA.2020.0111119>

Murray W. (2008). "Control for intelligent tutoring systems: A comparison of blackboard architecture and discourse management networks". Research Report R-6267, FMC Corporation, USA.

Pal, S., y Shiu, S. (2004). Foundations of soft case-based reasoning (Vol. 8). Wiley-interscience. ISBN: 978-0-471-64466-8

Raj, N. S., & Renumol, V. G. (2021). A systematic literature review on adaptive content recommenders in personalized learning environments from 2015 to 2020. Journal of Computers in Education. <https://doi.org/10.1007/s40692-021-00199-4>

Supangat, M. B. S. (2020). Development of e-learning system using felder and silverman's index of learning styles model. International Journal of Advanced Trends in Computer Science and Engineering, 9(5), 8554–8561. <https://doi.org/10.30534/ijatcse/2020/236952020>

Tetzlaff, L., Schmiedek, F., & Brod, G. (2021). Developing Personalized Education: A Dynamic Framework. Educational Psychology Review, 33(3), 863–882. <https://doi.org/10.1007/s10648-020-09570-w>

Urretavizcay-Loinaz, M., & de Castro, I. F. (2002). Artificial intelligence and educacia overview. In Conference on Advanced Information Systems Engineering. www. upgrade-cepis.

Vicari, R., Ovalle, D. (2015). "ALLEGRO: Ambiente Multi-Agente de Apoyo a la Enseñanza-Aprendizaje utilizando Planificación Instruccional y Razonamiento Basado en Casos (CBR)". in Proceedings of XIII Congreso Iberoamericano de Educación superior en Computaci1th Latin-American Conference on Informatics CLEI., Medellin, Colombia.

Wenger, E. (2014). Artificial intelligence and tutoring systems: computational and cognitive approaches to the communication of knowledge. ISBN: 9781483221113