



POSGRADOS

Maestría en
**TECNOLOGÍAS DE
LA INFORMACIÓN Y
COMUNICACIÓN PARA EDUCACIÓN**

RPC-SO-06-NO.185-2021

Opción de Titulación:

Artículos profesionales de alto nivel

Tema:

Seguimiento del aprendizaje mediante minería
de datos educativos

Autor(es)

Gisella Belén Montero Castillo

Director:

Joe Llerena Izquierdo

GUAYAQUIL – Ecuador

2025

Autor(es):



Gisella Belén Montero Castillo

Ingeniera de Sistemas mención Telemática

Candidato a Magíster en Tecnologías de la Información y Comunicación para Educación por la Universidad Politécnica Salesiana – Sede Guayaquil.

gmonteroc@est.ups.edu.ec

Dirigido por:



Joe Llerena Izquierdo

Ingeniero en Computación

Magister en Sistemas de Información Gerencial

Máster en Administración de Empresas

Máster en Ciencias de la Educación

jlllerena@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

2025 © Universidad Politécnica Salesiana.

Elija un elemento. – ECUADOR – SUDAMÉRICA

Gisella Belén Montero Castillo

Seguimiento del aprendizaje mediante minería de datos educativos

1. Título

Seguimiento del aprendizaje mediante minería de datos

2. Resumen

La minería de datos educativos está enfocada en crear métodos para explorar los tipos únicos de datos que provienen de entornos educativos con el fin de generar soluciones y estrategias en distintos niveles, pedagógico, curricular, a nivel directivo e institucional. Este trabajo tiene como objetivo ser un aporte al modelo predictivo en el seguimiento académico mediante el uso de la minería de datos educativos. En este proyecto se desarrolló el método PCN en un diseño cuasiexperimental, en la cual se puede cuantificar el aprendizaje académico mediante comentarios escritos de forma libre, que permite a los docente obtener una visualización de las tendencias para futuras clases enfocada a la enseñanza personalizada, la educación no solo se basa en que los estudiantes adquieran conocimientos, si no en la forma de interactúan, idealizar, reflexionar y aprender a lo largo de la educación. Se concluye que es fundamental contribuir a la mejora de la experiencia del estudiante de un curso de educación superior, así como a las expectativas en su trayectoria académica, pero sobre todo ver la oportunidad de obtener información del proceso que realiza el estudiante de acuerdo con el análisis de su aprendizaje, de tal manera que se determinen factores que afecten positivamente al patrón de comportamiento, su compromiso y su desempeño.

Palabras clave: Minería de datos educativo, método PCN, análisis de aprendizaje. Metodología CRISP-DM

Abstract: This Educational data mining focuses on creating methods to explore the unique types of data that come from educational environments to generate solutions and strategies at different levels: pedagogical, curricular, management, and institutional. This work aims to contribute to the predictive model for academic monitoring using educational data mining. In this project, the PCN method was developed in a quasi-experimental design, in which academic learning can be quantified through free written comments. This allows teachers to obtain a visualization of trends for future classes focused on personalized teaching. Education is not only based on students acquiring knowledge, but also on the way they interact, idealize, reflect, and learn throughout their education. It is concluded that it is essential to contribute to improving the student experience in a higher education course, as well as their expectations for their academic career, but above all, to see the opportunity to obtain information about the process that the student carries out according to the analysis of their learning, in such a way that factors that positively affect the pattern of behavior, their commitment and their performance are determined.

Keywords: Educational data mining, PCN method, Learning Analytics, methodology CRISP-DM

3. Introducción

El uso de tecnologías mejoradas en la educación, la minería de datos educativos y las técnicas de análisis del aprendizaje permiten a trabajos de investigación enfocarse en detectar, determinar y predecir situaciones de riesgo académico que afectan a estudiantes y su grupo en contexto (Akhuseyinoglu & Brusilovsky, 2022a) (Zakaria & Johnson Lim, 2022). Estas tecnologías como los sistemas del manejo de la información de los centros educativos, que generan grandes cantidades de datos, son las fuentes precisas para desarrollar sobre ellos la aplicación de algoritmos de minería de datos y determinar el comportamiento de los estudiantes (Araka et al., 2022). Con esto aplicar planes de contingencia a un determinado grupo de estudiantes definidos por un patrón específico en el rendimiento son los desafíos que actualmente se evidencian en distintos trabajos (Liu et al., 2022).

Los entornos virtuales de aprendizaje y sistemas de apoyo a la educación con tecnología son una oportunidad para extraer información que permita a los profesores tomar decisiones que apunten a mejorar la situación del estudiante y su grupo (Lopez-Chila et al., 2023). Este trabajo tiene como objetivo ser un aporte de la revisión de literatura en el ámbito del seguimiento académico mediante el uso de la minería de datos educativos (Puga Paredes, 2023).

En los últimos años ha surgido el seguimiento de aprendizaje como fortaleza para el campo de la educación permitiendo alcanzar metas a corto y largo plazo (Andrade et al., 2023) consiguiendo que la docencia sea una de las profesiones que requiera actualizaciones constante (Bessadok et al., 2023) uno de los temas más preocupantes educativos, es el avance en cuanto al rendimiento de los estudiantes, desconocer la predicción del rendimiento para la formación académica y retroalimentación para educar correctamente con un enfoque en minería de datos (Ayala-Carabaja & Llerena-Izquierdo, 2023). Los modelos de predicción ayudan a diseñar planes de estudio adecuados para estudiantes con medio y bajo rendimiento académico (Dien et al., 2020), el nivel de educación en las instituciones públicas y privadas varía en todas las regiones del mundo, los indicadores claves para evaluar el desempeño institucional difieren de los indicadores de desempeño de los estudiantes en función a resultados académicos (Alam et al., 2021).

Hay varias formas de poder evaluar el desempeño del alumno, como por ejemplo mediante cuestionarios, evaluaciones puntuales, promedio general, entre otros (Llerena-Izquierdo et al., 2024; Tumbaco-Loor & Llerena-Izquierdo, 2024). Los docentes no sólo enseñan a los estudiantes, sino que también intentan adquirir información sobre la experiencia de aprendizaje de estos (Atiaja Balseca, 2023).

En este artículo se evalúa el aprendizaje del estudiante en la materia del área musical, mediante 5 preguntas bajo el método PCN (Previous, Current, Next) abreviatura de Anterior, Actual y Siguiente la cual proporciona la capacidad de adquirir información temporal de la actividad de aprendizaje de cada estudiante en donde el docente lee y responde respectivamente las preguntas, sin embargo se busca automatizar el proceso de respuestas a preguntas mediante un método predictivo, donde el docente tendrá un seguimiento de aprendizaje por materia sin necesidad de leer las encuestas realizadas.

4. Estado del Arte

Las tecnologías de información y comunicación se han visto inmersas al cambio constante en el diario vivir del ser humano, evolucionando a un ritmo cada vez mayor, impactando diferentes ámbitos de la sociedad, entre ellas, la educación (Alrababah & Molnár, 2021; Llerena-Izquierdo & Ayala-Carabajo, 2022; Saúde et al., 2024). Con el tiempo la gran cantidad de información ha sido considerablemente almacenada en herramientas clásicas, de gestión educativa mejorando en eficiencia, beneficio y efecto (L. Chen et al., 2020; X. Chen et al., 2023).

Esto ha sentado una buena base para la aplicación de la tecnología de minería de datos en administración de educación donde han permitido a las organizaciones satisfacer sus necesidades (Rahman et al., 2022) (Llerena-Izquierdo, 2023). Pero la problemática en se evidencia en aquellos modelos más tradicionales de bases de datos donde se ven perjudicados ya que a veces tardan en incorporar los registros y puede que no sean lo ágiles e inmediatos para ello (Akhuseyinoglu & Brusilovsky, 2022) (Liu et al., 2022)(Feng et al., 2022).

La minería de datos educativos está enfocada en crear métodos para explorar los tipos únicos de datos que provienen de entornos educativos con el fin de generar soluciones y estrategias a nivel pedagógico, curricular, a nivel directivo e institucional (Y. Chen & Zhai, 2023) (Llerena-Izquierdo et al., 2022). Mejorando los procesos educativos de manera automatizada, identificando patrones nuevos y no triviales y, resolviendo y mejorando aquellos procesos educativos que involucran de manera relevante a los recursos de aprendizaje, así como la capacidad que adquieren los estudiantes de encontrar patrones de comportamiento para una trayectoria académica eficaz (Angeioplastis et al., 2025; Gupta et al., 2022).

Se implementa el uso de herramientas o técnicas de minería de datos educativo (EDM) que son de gran importancia, para el examen de grandes bases de datos permitiendo de cierta manera buscar, encontrar tendencias, variaciones de comportamientos en los datos y mejorar la experiencia educativa (Okoye et al., 2022) (Cedeno-Tello & Llerena-Izquierdo, 2023).

En los últimos años, EDM se ha convertido en una herramienta eficaz utilizada para identificar patrones ocultos en los datos educativos, predecir el rendimiento académico y mejorar el entorno de aprendizaje/enseñanza (Almasri et al., 2023; X. Wang et al., 2023).

4.1. Primera fase de la investigación

La primera fase se orienta en la recolección de datos en este contexto la analítica de aprendizaje (LA), se fundamenta en la recolección y análisis de información para optimizar el proceso educativo. Según Sánchez, la minería de datos educativos busca descubrir patrones ocultos en el aprendizaje, utilizando técnicas como la clasificación y la predicción (Sánchez & Mateos, 2023) para ello se utiliza el cuestionario basado en cinco preguntas predefinidas relacionadas con diversos aspectos según la experiencia de aprendizaje siguiendo el método PCN (Makhlouf & Mine, 2020) la composición de las 5 preguntas se dividen en 3 subconjuntos, P, C, N, el primer subconjunto P (Previous) preguntamos a los estudiantes sobre la preparación previa a la clase, el segundo subconjunto C (Current), está compuesta por 3 interrogantes, en esta sección los estudiantes comienzan reportando novedades y partes que no entendieron de la clase, en la segunda pregunta, describen las partes que descubrieron y entendieron, finalmente indican las actividades realizadas entre compañeros de clase. El último subconjunto N (Next) los estudiantes responden sobre sus planes o motivación en clases futuras (Makhlouf & Mine, 2021), ver Tabla 1.

Tabla 1. Preguntas y comentarios basado en el método PCN

Método	Preguntas	Respuestas, ejemplo de comentarios
P	¿Te preparaste para esta clase?	Sí, tuvimos nivelación No más o menos
C	¿Tienes alguna pregunta de algo que no entendiste? ¿Qué fue lo más te gustó de la clase? ¿Comentaste con tus compañeros algo de la clase?	No Sí entendí todo Notas musicales, melodía Pentagrama, dibujos No Sí Mucho
N	¿Qué deseas revisar en tu próxima clase?	Aprender a dibujar Autores No se

La encuesta se emplea 2 veces por trimestre a los 29 estudiantes, luego se validan comentarios vacíos posterior ubicamos los comentarios en una tabla de Excel para poder ser cuantificados (ver Fig. 1).

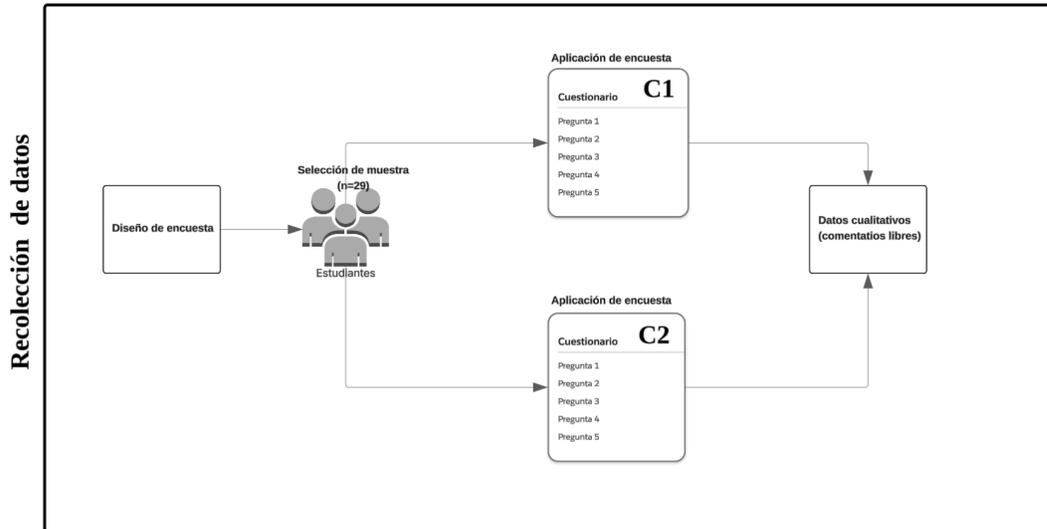


Figura 1. Flujo de procesos, Fase 1 de la investigación

4.2. Segunda fase de la investigación

En esta segunda fase, se realiza el preprocesamiento y limpieza de datos , los comentarios se ubican en una escala donde se colocan los comentarios libres según lo leído, -1 asociamos comentarios “no me gustó”, “aburrido”, “no quiero aprender más”, “no quiero”, 0 se toman en cuenta comentarios neutrales, “ok”, “gracias”, “más o menos”, “todo bien”, 1, se consideraron los comentarios, “si quisiera revisar”, “todo bien en la clase”, “entendí el tema”, “me pareció bien”, 2 se tomaron comentarios, “si me pareció muy buena la clase”, “si me gustó todo”, “sí me preparé”, “estuve revisando el tema”, ver Tabla 2. Una vez identificados los comentarios en la escala se colocan en Excel para realizar el proceso de limpieza para verificar la consistencia de la codificación y llevar la información a Power BI.

Tabla 2. Escala por comentarios de encuestas

Escala	Resultado de comentarios
-1	Poco satisfecho
0	Neutral
1	Bueno
2	Totalmente satisfecho

Estas técnicas facilitan a los educadores y docentes la identificación de estudiantes en situación de riesgo, permitiéndoles ajustar enfoque de enseñanzas para atender necesidades particulares de cada uno. La revisión sistemática realizada por Pérez – Suasnavas, destaca el desarrollo de las técnicas de minería de datos y la implementación en la educación superior, sobresaliendo la importancia de manejar grandes cantidades de información para extraer un significativo (Pérez-Suasnavas et al., 2023), La anotación de datos es un componente esencial en este contexto, ya que implica la clasificación y etiquetado de datos significativos que se adquieren mediante encuestas y otras metodologías de recopilación de información. Por ejemplo, en una investigación sobre el desempeño académico en la carrera Ingeniería Agroindustrial se validaron datos importantes como género, motivación y metacognición, los cuales fueron analizados mediante minería de datos para realizar el seguimiento a los estudiantes académicamente (Riobóo & Pedroza, 2020), la aplicación de encuestas facilitan la evaluación eficiente de estrategias de enseñanzas y aprendizaje, como se demuestra en el estudio que emplearon encuestas para medir dentro de los entornos virtuales la experiencia que se obtuvo en el aprendizaje (González Jaimes, N.L., Tejeda Alcántara, A.A., Espinosa Méndez, C.M., y Ontiveros Hernández, 2020), EDM (Educational Data Mining) la minería de datos educativos facilita la conversión de cantidades grandes de datos generados en entornos de aprendizaje en información importante, puede ser empleada para la toma de decisiones basadas en la enseñanza y el aprendizaje (Maphosa et al., 2020) (ver Fig. 2).

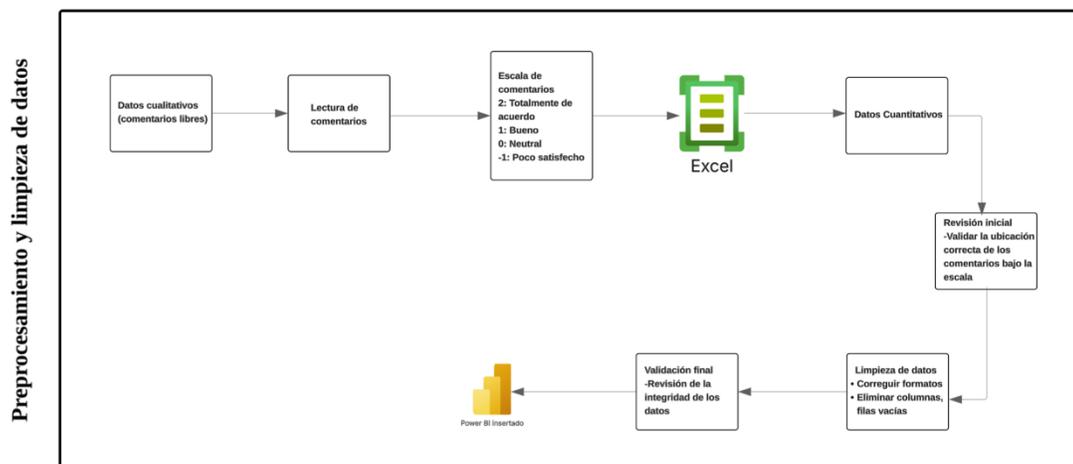


Figura 2. Flujo de procesos, Fase 2 de la investigación

4.3. Tercera fase de la investigación

En la tercera fase de la investigación se realiza un análisis exploratorio y se evalúa el diseño del modelo predictivo, se inicia esta fase con la estrategia de visualización de datos, sustentada el archivo final de Excel en la plataforma analítica seleccionada, se realiza el modelado de datos donde se validan las relaciones de tablas y se desarrollan las métricas DAX personalizadas para obtener los resultados. Para el análisis exploratorio de datos que abarca la recolección y el análisis de distintas fuentes, en este caso las encuestas, permite una posible identificación de patrones y tendencias en el comportamiento de estudiantes (Adam & Dzang Alhassan, 2020), posterior en la evaluación de modelos predictivos en la minería de datos se fundamenta en metodologías organizadas como CRISP-DM, que ofrece un marco para el diseño de proyectos. Este modelo abarca fases como el entendimiento del problema, la preparación de datos, para llegar a la toma de decisiones (Espinosa-Zúñiga & Espinosa-Zúñiga, 2020). Estos modelos tienen la capacidad de poder identificar a estudiantes que se encuentren en riesgo de aprendizaje y permite a los docentes implementar una intervención temprana. Además, la revisión sistemática de Mangina y Psyrra sobre la aplicación de LA y EDM destaca que el análisis predictivo es una de las metodologías más utilizada en este campo, empleada para predecir calificaciones y detectar factores que afectan al rendimiento estudiantil (Mangina & Psyrra, 2021). Este tipo de análisis permite a las instituciones educativas realizar intervenciones tempranas y personalizadas, contribuyendo a la mejora del rendimiento académico (Q. Wang & Mousavi, 2023). Finalmente se visualizan resultados mediante dashboard, gráficos, tablas, mapas dinámicos, la interpretación de resultados anticipa el bajo rendimiento de los estudiantes permitiendo personalizar las intervenciones pedagógicas junto con la toma de decisiones para el trabajo a realizar (Bergmans et al., 2021; Grant, 2019; Llerena et al., 2021; Llerena-Izquierdo et al., 2023) (ver Fig. 3).

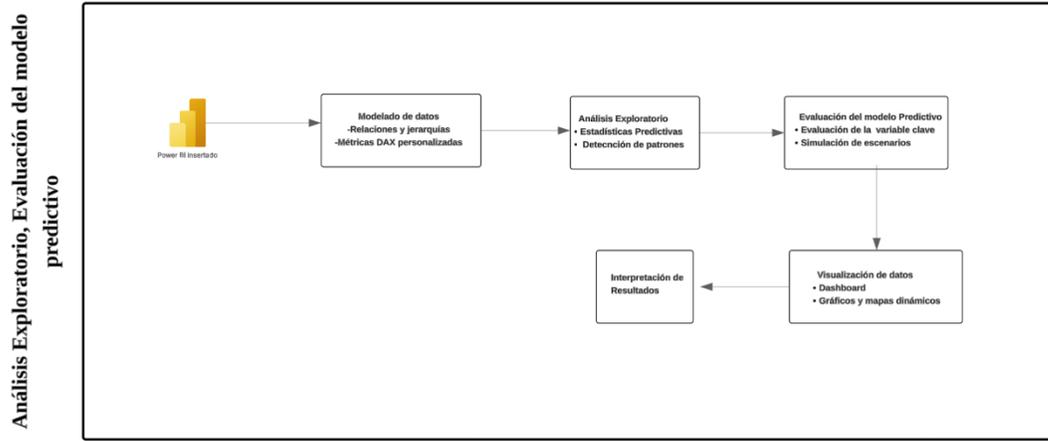


Figura 3. Flujo de procesos, Fase 3 de la investigación

5. Metodología

El seguimiento del aprendizaje mediante minería de datos ha evolucionado significativamente en los últimos años, destacando la importancia de los métodos predictivos para mejorar la educación. La minería de datos educativos (EDM) se centra en el análisis de datos generados por los estudiantes para identificar patrones que pueden predecir su rendimiento y comportamiento. La minería de datos también facilita la detección de estudiantes con riesgos académicos, lo que les permite a las instituciones educativas aplicar intervenciones para mejorar el rendimiento y desempeño (Adam & Dzang Alhassan, 2020). Esto no solo ayuda a los educadores a ajustar sus métodos de enseñanza, sino que también proporciona retroalimentación valiosa para el desarrollo profesional del docente (Souto-Seijo et al., 2020).

Para este proyecto se desarrolló el método PCN en un diseño cuasiexperimental, en la cual se puede cuantificar el aprendizaje académico mediante comentarios escritos de forma libre, que permite a los docente obtener una visualización de las tendencias para futuras clases enfocada a la enseñanza personalizada, el docente debe tener claro la nomenclatura del método PCN (Previous, Current, Next) abreviatura de Anterior, Actual y Siguiete, P indica la preparación previa a la clase, C corresponde al tiempo real, N indica la preparación posterior a la clase. Los comentarios escritos son leídos por el docente el cual evalúa en una escala para determinar cómo será procesado, para ir formando un criterio con la finalidad de categorizar las respuestas según la experiencia de los estudiantes, la encuesta le permite al estudiante mostrar la experiencia del aprendizaje en la materia, una vez ajustados en la escala el docente puede realizar la toma de decisiones (ver Fig. 4).



Figura 4. Relación de bases de datos C1 vs C2

Para la revisión del primer trimestre se revisaron C1 vs C2 la información cargada en ambas bases representa la información inicial de la investigación, éstas se conectan de muchos a muchos porque tiene relación de id del estudiante y las preguntas que se realizaron en las encuestas se mantiene para todo el proyecto. Los estudiantes respondieron 2 encuestas con una holgura de dos semanas para validar avances dentro de un trimestre para que el docente le permita tener retroalimentaciones buscando estrategia de mejora de aprendizaje tanto individual como grupal. Este proceso se realizó para los cuestionarios C3 vs C4 y C5 vs C6 (ver Fig. 5).

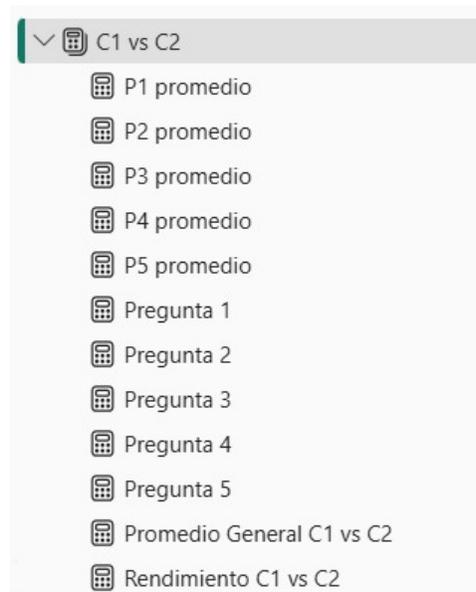


Figura 5. Proceso de query en la plataforma para la gestión y análisis sistemático de los datos recolectados.

Luego de eso realizamos los procesos de query entre las dos bases que corresponden a cada trimestre permitiendo tener un seguimiento visual para tener una detección temprana de estudiantes que mantiene novedades, permitiendo una intervención oportuna dentro del trimestre y comenzar con los seguimientos de aprendizajes.

Este proceso se replica para las bases de los cuestionarios C3 vs C4, este análisis permite tener un monitero continuo de los estudiantes detectados con novedades y con intervenciones para obtener resultados satisfactorios, para las bases de cuestionarios C5 vs C6, se realiza un análisis del antes y después del estudiante con novedades para validar la intervención temprana si se tuvo éxito (Ayala-Carabajo & Llerena-Izquierdo, 2023).

6. Resultados

Se desarrolla una metodología de investigación mediante una revisión de literatura para el análisis de contenido. Se establecen trabajos similares de relevancia utilizando el método de selección con flujo el PRISMA, y de acuerdo con las preguntas de investigación, ver Tabla 3.

Tabla 3. Preguntas de investigación

Qn	Preguntas	Objetivo de la pregunta
Q1	¿Qué temáticas se aborda en el seguimiento del aprendizaje académico mediante minería de datos educativos?	Determinar aquellos temas que son sobresalientes
Q2	¿Qué problemas se han identificado en el seguimiento del aprendizaje académico mediante minería de datos educativos?	Determinar los problemas más relevantes
Q3	¿Cuáles son las limitaciones que se encuentran identificados en el seguimiento del aprendizaje académico mediante minería de datos educativos?	Identificar las limitaciones existentes
Q4	¿Qué propuestas han sido desarrolladas en el seguimiento del aprendizaje académico mediante minería de datos educativos?	Presentar aquellas propuestas más relevantes
Q5	¿Qué soluciones o resultados son encontrados en el seguimiento del aprendizaje académico mediante minería de datos educativos?	Determinar aquellos trabajos que evidencian soluciones o resultados importantes

Se identifican 1692 trabajos del repositorio de indexación de la base Web of Science. Removiendo de la selección aquellos trabajos que, de acuerdo con criterios de exclusión, encontrarse en otro idioma al inglés, antes del año 2021, encontrarse en otra área de investigación distinta a educación, así como documentos duplicados. Así como incluir aquellos trabajos de los tres últimos años. Luego del proceso de las fases de identificación, selección y elegibilidad, se incluyen aquellos trabajos que, por la relevancia del tema y una revisión del contenido, se determinan un número de 28 artículos científicos, (ver Fig. 6).

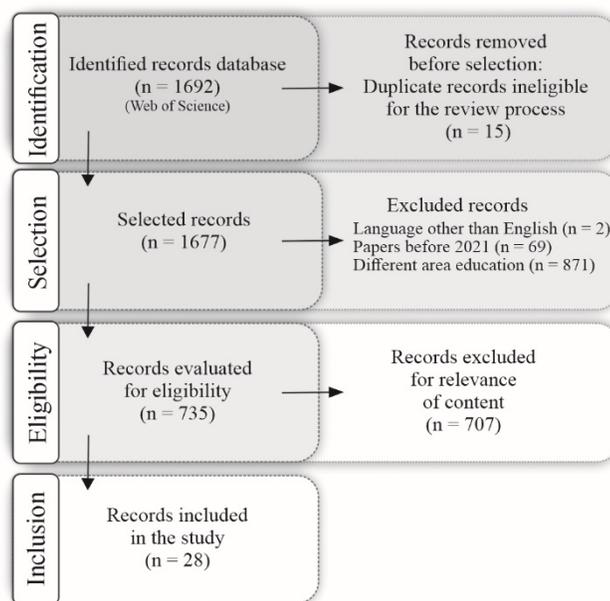


Figura 6. Fases metodológicas del estudio utilizando el modelo de flujo PRISMA

Se realiza además un análisis gráfico mediante el programa VOSviewer de aquellas contribuciones en el campo de la minería de datos educativos realizados por diferentes países y su relación más significativa. Se destacan los países como China, India, EE. UU., Arabia Saudita, Corea del Sur, España y Australia entre los más destacados en sus interconexiones, (ver Fig. 7).

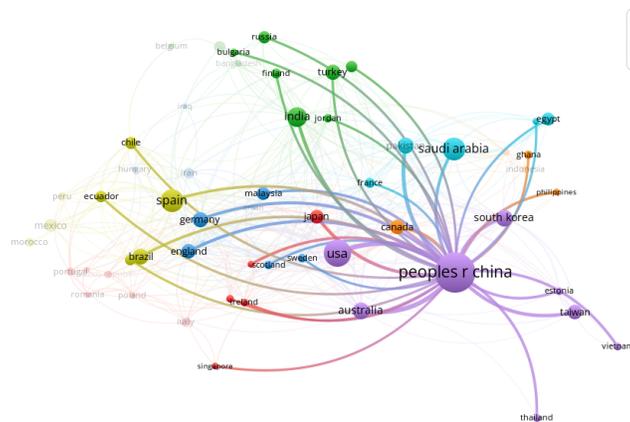


Figura 7. Countries with the greatest scientific contribution in the field of EDM modeling using VOSviewer software

Los resultados de la revisión de literatura responden a las preguntas de investigación planteadas. Para la primera pregunta sobre qué temáticas se aborda en el seguimiento del aprendizaje académico mediante minería de datos educativos, se evidencia que el 50% se enfocan en la importancia de los patrones de comportamiento de los participantes, el 18% se enfocan en la importancia de la necesidad de las grandes cantidades de datos que pueden utilizarse de los entornos de aprendizajes establecidos, el 18% se enfocan en el modelamiento académico y emocional mediante el seguimiento del aprendizaje automático y el 14% se enfocan a la importancia de los patrones y reglas que se pueden obtener en la forma de resolver problemas por los estudiantes (ver Fig. 8).

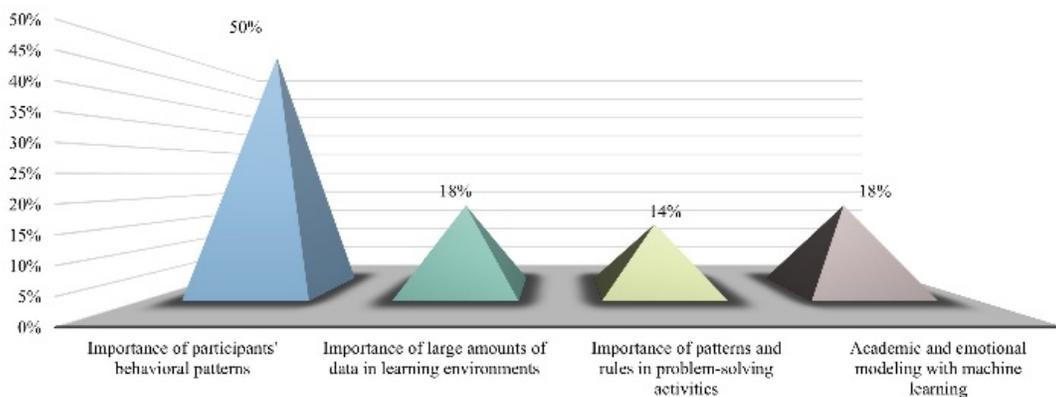


Figura 8. Porcentaje de trabajos que evidencian temáticas que aborda en el seguimiento del aprendizaje académico mediante minería de datos educativos

Los resultados a la pregunta sobre los problemas que distintos autores han identificado en el seguimiento del aprendizaje académico mediante minería de datos educativos evidencian que el 25% precisa como problema el conjunto de algoritmos para un adecuado análisis, el 22% el problema deriva en determinar

aquellos factores de comportamiento que afectan el rendimiento en un contexto determinado, el 21% determina el problema en la forma de extraer modelos abstractos para identificar patrones y factores que afectan el éxito de los estudiantes, el 18% determina como problema encontrado a los escenarios de aprendizaje que promueven el compromiso del patrón de comportamiento, y el 14% determina que el problema se enfoca en el extraer información adecuada de las grandes cantidades de datos para mejoras oportunas (ver Fig. 9).

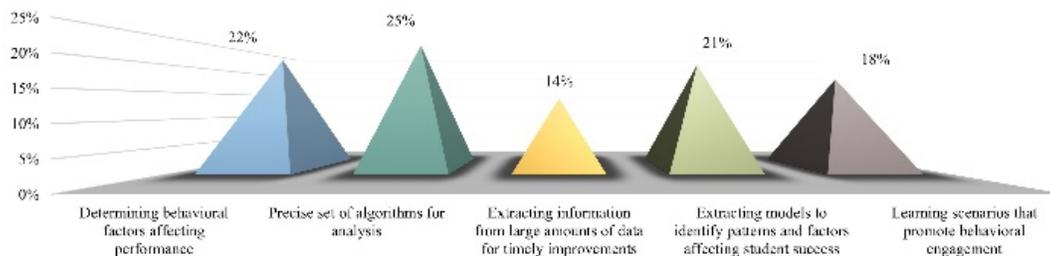


Figura 9. Porcentaje de trabajos que abordan problemas se han identificado en el seguimiento del aprendizaje académico mediante minería de datos educativos

Los resultados a la pregunta sobre cuáles son las limitaciones que se encuentran identificados en el seguimiento del aprendizaje académico mediante minería de datos educativos evidencian que el 46% se refiere a las brechas existentes entre los modelos tradicionales y actuales en las diferencias individuales temporales, el 32% indica que las limitaciones se enfocan en la estructura computacional para el modelado, el 11% indica que es necesario superar la diferencias entre las localidades y regiones que afectan a los modelos, y el 11% expresan que la limitaciones se enmarcan en las habilidades para el análisis de la información (ver Fig. 10).

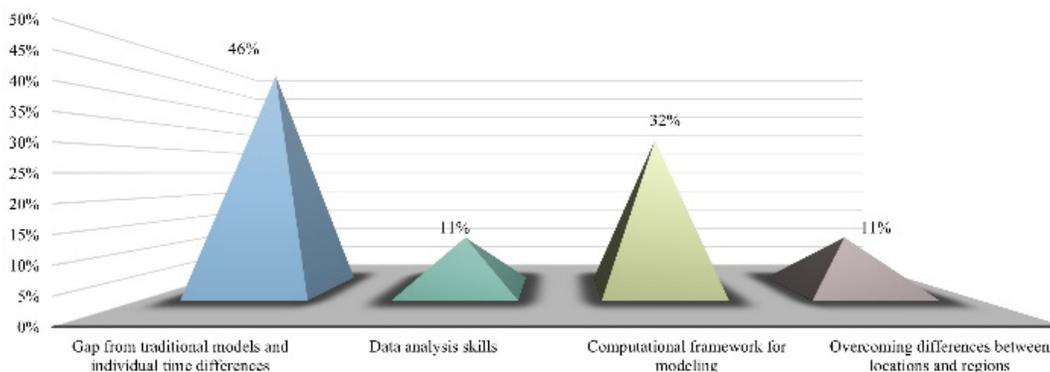


Figura 10. Porcentaje de trabajos que abordan limitaciones identificadas en el seguimiento del aprendizaje académico mediante minería de datos educativos

Los resultados a la pregunta sobre las propuestas que han sido desarrolladas en el seguimiento del aprendizaje académico mediante minería de datos educativos se evidencia que el 36% determina que la minería de patrones secuencial es oportuno para el proceso de aprendizaje en el tiempo, el 25% determina que un conjunto de algoritmos específicos son necesarios para determinar perfiles de estudiantes, el 25% determina un marco educativo de minería de datos para apoyar el aprendizaje de una asignatura y el 14% determina un modelado para extraer información de características de estudiantes (ver Fig. 11).

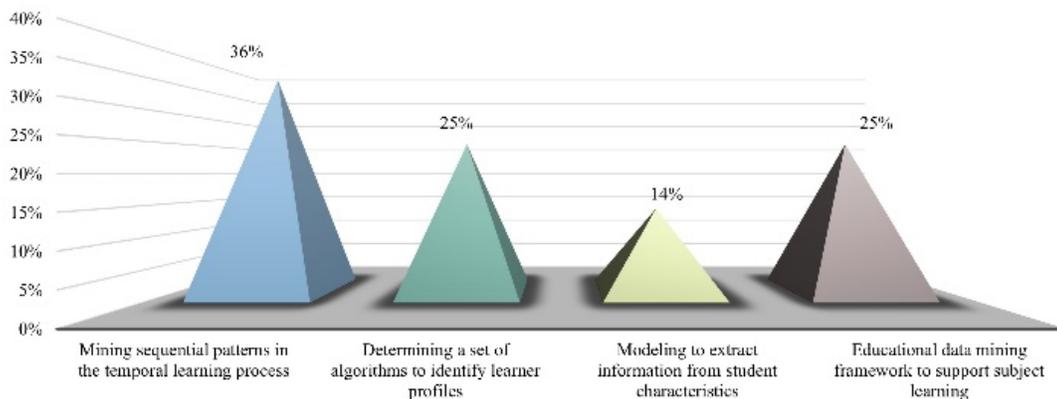


Figura 11. Porcentaje de trabajos que identifican propuestas desarrolladas en el seguimiento del aprendizaje académico mediante minería de datos educativos

Los resultados a la pregunta sobre las soluciones o resultados encontrados en el seguimiento del aprendizaje académico mediante minería de datos educativos se evidencia que el 39% de trabajos determinan como solución el uso de escalas para cuantificar patrones de los participantes, profesores y estudiantes, el 36% determina el uso de un adecuado sistema de gestión del aprendizaje en función del comportamiento de los participantes, el 14% determina lo favorable del uso de una metodología del descubrimiento del conocimiento en las bases de datos (KDD) y el 11% determina el soporte de un sistema de alerta temprana para precisar la clasificación (ver Fig. 12).

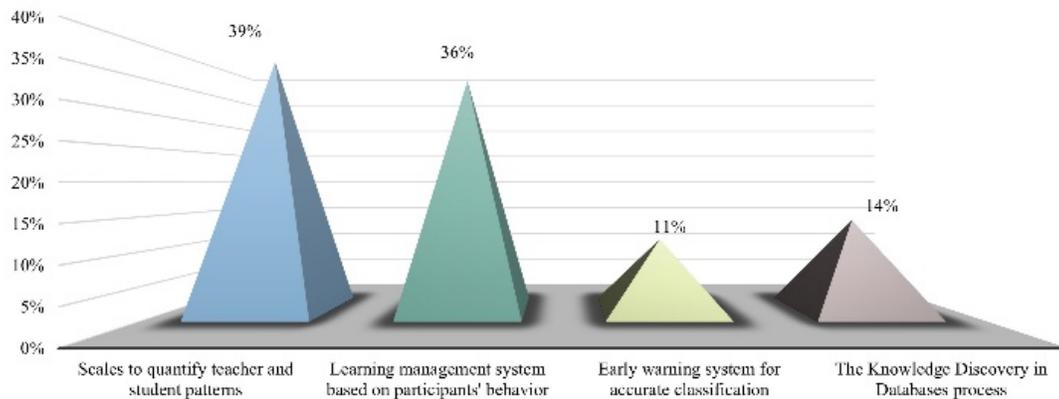


Figura 12. Porcentaje de trabajos que evidencian soluciones o resultados en el seguimiento del aprendizaje académico mediante minería de datos educativos

Se destacan cuatro ámbitos donde la minería de datos educativos da soporte al seguimiento de los estudiantes.

Identificación de patrones de éxito: Se identifican patrones de comportamiento que permiten detectar situaciones de riesgo donde es posible aplicar estrategias, buenas prácticas o intervenciones de índole pedagógico para conducir a un adecuado rendimiento académico (Blundo et al., 2022)(Kokoç et al., 2021)(Tang et al., 2023) (Valles-Coral et al., 2022)(C. Wang & Zhu, 2022)

Predicción del rendimiento académico: Se identifican aquellos algoritmos de aprendizaje automático que permitan predecir el rendimiento académico, así como el éxito futuro del participante de un curso en función de datos históricos y características específicas (Deeva et al., 2022)(Hilal et al., 2021)(Memon et al., 2022)(Xing et al., 2023)(Yang et al., 2021)

Detección de factores de riesgo: Se identifican factores que afecten al proceso del seguimiento o trayectoria académica del participante de un curso, así como el compromiso o desempeño en temas donde el profesor interviene de manera oportuna permitiendo ofrecer un soporte adicional (Aydin, 2022; de Brito Lima & Lautert, 2022; Kim et al., 2021; Llerena & Ayala-Carabajo, 2020).

Personalización del aprendizaje: Se identifican necesidades académicas de los estudiantes, así como sus preferencias permitiendo al profesor adaptar los contenidos curriculares, prácticas y enfoques de enseñanza para ofrecer una experiencia educativa eficaz y personalizada (Liu et al., 2022) (Llerena-Izquierdo, 2023)

Los resultados del proyecto se basaron en las encuestas realizadas a los estudiantes durante un trimestre, en total de los comentarios fue de 870 efectuados de manera general.

ID ESTUDIANTE	P1 promedio	P2 promedio	P3 promedio	P4 promedio	P5 promedio
1	1,50	2,00	2,00	1,00	1,00
2	1,00	2,00	2,00	0,00	2,00
3	1,50	2,00	2,00	1,00	1,50
4	2,00	2,00	1,00	0,00	1,00
5	1,50	2,00	1,50	1,00	2,00
6	1,50	2,00	2,00	1,00	1,00
7	1,00	2,00	1,50	0,50	1,50
8	1,00	2,00	2,00	1,00	1,50
9	2,00	2,00	2,00	1,00	1,50
10	1,50	2,00	1,50	2,00	1,00
11	1,50	2,00	1,50	0,50	2,00
12	1,00	2,00	2,00	1,00	2,00
13	1,50	2,00	1,50	1,00	2,00
14	1,50	2,00	2,00	1,00	2,00
15	1,50	2,00	2,00	1,00	1,00
16	2,00	2,00	0,50	0,00	2,00
17	1,50	2,00	2,00	1,00	1,50
18	1,50	2,00	2,00	1,00	1,50
19	1,50	2,00	1,50	1,00	2,00
20	1,50	2,00	1,50	1,00	1,00
21	2,00	2,00	2,00	0,50	2,00
22	2,00	2,00	2,00	2,00	1,50
23	2,00	2,00	1,50	1,00	2,00
24	2,00	2,00	1,50	1,00	1,50
25	1,00	2,00	2,00	1,00	2,00
26	1,50	2,00	1,50	0,50	1,50
27	2,00	2,00	2,00	1,00	1,00
28	1,50	2,00	2,00	1,00	2,00
29	2,00	2,00	2,00	0,50	2,00
Total	1,57	2,00	1,74	0,88	1,60

Tabla 4. Análisis de estudiantes con novedades en el primer trimestre C1 vs C2

En el primer trimestre se evalúa C1 vs C2, se realiza el análisis individual entre los 29 estudiantes para ellos se evalúan las 5 preguntas y se filtran los estudiantes que están por debajo del 1.00 para poder identificar los estudiantes que necesitan seguimiento de aprendizaje. La tabla 4, permite conocer que las preguntas 1,2,5 no tienen novedades, sin embargo, en la pregunta 3 “¿Qué fue lo que más te gustó de la clase?”, el estudiante número 16 tiene un promedio 0,50 puntos mostró un desinterés por el aprendizaje, en la pregunta 4 “¿Comentaste con tus compañeros algo de la clase?”, los estudiantes número 2, 4, 7, 11, 16, 21, 26, 29, no mantiene interactividad con sus compañeros ni comparten enseñanzas aprendidas.

ID ESTUDIANTE	P1 promedio	P2 promedio	P3 promedio	P4 promedio	P5 promedio
2	1,50	2,00	2,00	1,50	1,50
8	1,50	2,00	2,00	1,50	1,00
10	1,50	2,00	1,50	2,00	2,00
11	1,50	2,00	2,00	1,50	1,50
12	1,50	2,00	2,00	1,00	2,00
13	1,50	2,00	1,50	1,50	2,00
14	1,50	2,00	2,00	1,00	2,00
15	1,50	2,00	2,00	1,50	1,50
17	1,50	2,00	2,00	1,50	1,50
19	1,50	2,00	1,50	2,00	1,50
20	1,50	2,00	2,00	2,00	1,50
26	1,50	2,00	1,50	0,50	1,00
1	2,00	2,00	2,00	1,50	1,50
3	2,00	2,00	2,00	1,00	1,50
4	2,00	2,00	1,50	1,50	1,00
5	2,00	2,00	1,50	1,00	1,50
6	2,00	2,00	2,00	1,50	1,50
7	2,00	2,00	2,00	1,00	1,50
9	2,00	2,00	2,00	1,00	1,50
16	2,00	2,00	1,50	1,00	2,00
18	2,00	2,00	2,00	1,00	1,50
21	2,00	2,00	2,00	2,00	2,00
22	2,00	2,00	2,00	2,00	1,50
23	2,00	2,00	2,00	1,00	2,00
24	2,00	2,00	2,00	1,50	1,50
25	2,00	2,00	2,00	1,50	2,00
27	2,00	2,00	2,00	1,50	1,00
28	2,00	2,00	2,00	2,00	1,50
29	2,00	2,00	2,00	1,50	1,50
Total	1,79	2,00	1,88	1,41	1,57

Tabla 5. Análisis continuo del progreso de estudiantes con novedades en el segundo trimestre C3 vs C4

Los resultados que se presentan en el segundo trimestre con respecto a los cuestionarios C3 vs C4, nos permite validar la intervención temprana en los estudiantes fortaleciendo las estrategias de aprendizajes, el monitero continuo fortalece la intervención de docente favoreciendo la toma de decisiones, rediseño de estrategias didácticas alineando la planificación curricular. La tabla 5 nos indica que hay una reducción de alumnos con comentarios negativos, solo se mantiene un estudiante con la novedad de aprendizaje estudiante 26 con resultado de 0,50 puntos, el análisis grupal nos indica que en la pregunta 1, los estudiantes se preparan para llegar a clases mantiene un resultado de 1,79 puntos que equivale a un 89,5%, en la pregunta 2 el resultado se genera por 2 puntos que equivale a un 100% de estudiantes que entendieron todas las clase impartidas en el aula, la pregunta 3 tiene un resultado de 1,88 puntos que equivale a un 94% los estudiantes realizaron comentarios positivo de acogida a los temas abordados, la pregunta 4 tiene un resultado de 1,41 puntos que equivale a 70,5% es una pregunta con una visual de mejora se trabaja en los estudiantes que la enseñanza no solo se individual si no grupal, en la pregunta 5 arroja un resultado de 1,57 puntos que equivale 78,5% teniendo un tendencia de avance e iniciativa de los estudiantes en querer aprender temas nuevos.

ID ESTUDIANTE	P1 promedio	P2 promedio	P3 promedio	P4 promedio	P5 promedio
1	2,00	2,00	2,00	1,50	2,00
2	2,00	2,00	2,00	1,50	1,00
3	2,00	2,00	2,00	1,00	2,00
4	2,00	2,00	2,00	1,50	1,50
5	2,00	2,00	1,50	1,00	1,50
6	2,00	2,00	2,00	1,50	1,50
7	2,00	2,00	2,00	1,00	1,50
8	2,00	2,00	2,00	1,50	1,00
9	2,00	2,00	2,00	1,00	1,00
10	2,00	2,00	1,50	2,00	2,00
11	2,00	2,00	2,00	1,50	1,00
12	2,00	2,00	2,00	1,00	2,00
13	2,00	2,00	1,50	1,50	1,50
14	2,00	2,00	2,00	1,00	2,00
15	2,00	2,00	2,00	1,50	1,50
16	2,00	2,00	1,50	1,00	1,50
17	2,00	2,00	2,00	1,50	1,50
18	2,00	2,00	2,00	1,00	1,50
19	2,00	2,00	1,50	2,00	1,50
20	2,00	2,00	2,00	2,00	1,00
21	2,00	2,00	2,00	2,00	2,00
22	2,00	2,00	2,00	2,00	1,50
23	2,00	2,00	2,00	1,00	2,00
24	2,00	2,00	2,00	1,50	1,50
25	2,00	2,00	2,00	1,50	1,50
26	2,00	2,00	2,00	1,00	1,50
27	2,00	2,00	2,00	1,50	1,50
28	2,00	2,00	2,00	2,00	1,50
29	2,00	2,00	2,00	2,00	1,50
Total	2,00	2,00	1,91	1,45	1,53

Tabla 6. Seguimiento de aprendizaje de estudiantes en el tercer período C5 vs C6

En este último período se valida todo el proyecto con respecto al seguimiento de aprendizaje basado en la minería de datos, en el tercer trimestre donde se realiza el análisis de los cuestionarios C5 vs C6, se valida que los seguimientos a los estudiantes con novedades han permitido tener una mejora y gráficamente se puede observar que no hay ningún estudiante con novedad, los promedios de las cinco interrogantes mantienen un promedio bueno con oportunidades de mejora para alcanzar el 100%, ver Tabla 6.

La pregunta 1 y 2 alcanzan 2 puntos que equivale al 100% donde los estudiantes se preparan en su totalidad para tomar las clases y los temas impartidos en el aula son entendidos, en la pregunta 3 tiene un resultado de 1,91 puntos equivalente a 95,5% en esta interrogante podemos validar que los estudiante en cada trimestre mantienen más entusiasmo por aprender de la materia hay una gran grado de acogida, en la pregunta 4 tiene el resultado de 1,45 puntos que equivale a 72,5% aunque que es un tema con oportunidad de mejora ha avanzado en los trimestre la participación grupal entre estudiantes, la pregunta 5 tiene un promedio de 1,53 puntos equivalente a 76,5% con interés de aprendizaje para futuras clases.

RESULTADOS GENERALES



Figura 13. Resultados generales de los 3 trimestres

Finalmente podemos mencionar que no hay estudiantes con novedades en el seguimiento de aprendizaje, ni problemas en la materia, los estudiantes que presentaron novedades tuvieron un monitoreo de seguimiento, identificando los contenidos con mayor dificultad así ajustándolo para que el estudiante puede tener respuestas óptimas.

Para los resultados generales se realizaron las comparaciones entre los tres trimestres, para el primer trimestre de los cuestionarios C1 vs C2 se obtuvo un resultado de 1,56 puntos que equivale al 78%, en el segundo trimestre C3 vs C4 el resultado es de 1,73 puntos que equivale 86,5% y por último el tercer trimestre C5 vs C6 tiene un promedio de 1,78 puntos equivalente a 89%, el aumento progresivo del avance del proyecto se valida que entre el primer y segundo trimestre hay un aumento de 8,5%, del segundo trimestre al tercer trimestre hay un avance de 2,5%.

7. Discusión

El estudio evalúa el seguimiento de aprendizaje del estudiante en la materia del área musical, mediante 5 preguntas bajo el método PCN (Previous, Current, Next), con el fin de poder identificar a estudiantes con novedades de aprendizaje de forma preventiva y temprana para tener una visual del progreso, realizar la toma de decisiones en cuanto al trabajo a elaborar por parte de los docentes para obtener resultados positivos.

(Sánchez & Mateos, 2023) destacan el uso de patrones en grandes volúmenes de datos, lo que permite tener visuales para la toma de decisiones en cuanto al seguimiento de aprendizaje, esta visión toma forma en nuestro trabajo donde el uso de la herramienta de análisis permitió identificar a los estudiantes que presentaban novedades, se pudo monitorear en temprana instancia el rendimiento estudiantil con una eficacia a diferencia de métodos convencionales. Cabe recalcar que el estudio de Sánchez R, Mateos J fue basado teóricamente y general sobre la minería de datos usando clúster, árboles de decisión entre otros, en cuanto al trabajo realizado realizamos un enfoque más aplicado no sólo encontrar los estudiantes con novedades si no presentar el valor agregado de seguimiento utilizando herramientas que permitan tener respuestas óptimas replicándose en varios períodos para tener revisiones con más precisión.

Por otro lado Makhlof J, Mine T (Makhlof & Mine, 2020), introducen las técnicas de minería de datos orientadas al análisis de comentario escritos libres por parte de los estudiantes, para ser analizados y evaluar el desempeño (Makhlof & Mine, 2021), el complemento de Makhlof J, Mine T mediante otro artículo es generar un apoyo al docente con resultados obtenidos para fortalecer temas que no tenga una buena acogida en las aulas, en el trabajo realizado se comparte la finalidad de mejorar el aprendizaje estudiantil mediante el análisis, pero el uso de los datos fueron estructurados obtenidos de cuestionarios cerrados llevándolo a una escala para tener resultados más directos y cuantificable.

Se puede inferir que el enfoque adoptado en este trabajo es viable con la aplicación de estudios y el contraste de procesos en los artículos analizados, todos mantienen la orientación de identificar estudiantes con novedades, realizar el seguimiento de aprendizaje y obtener resultados positivos ante el cierre de un período escolar.

8. Conclusiones

Para la obtención de resultados entre los tres trimestres se evidenció el avance en un 11% desde que inició este trabajo, el análisis sistemático permitió tener un monitoreo visual de estudiantes con novedades y a lo largo de los trimestres se trabajó con aquellos estudiantes mejorando su rendimiento académico.

El seguimiento del aprendizaje mediante minería de datos y métodos predictivos es una herramienta poderosa para mejorar la educación. La combinación de analítica de aprendizaje, modelos predictivos y técnicas de minería de datos permite a los educadores comprender mejor el comportamiento de los estudiantes y adaptar sus estrategias de enseñanza para maximizar el aprendizaje, permiten comprender mejor el comportamiento de los estudiantes y mejorar los resultados académicos.

La combinación de analítica de aprendizaje, modelos predictivos y plataformas digitales proporciona un marco robusto para la mejora continua en la educación. En conclusión, el monitoreo del aprendizaje mediante minería de datos, complementado con la recolección de datos a través de encuestas, se valida como una estrategia eficaz para poder mejorar la calidad de la enseñanza educativa. Este enfoque no solo facilita una comprensión más profunda del proceso de aprendizaje, sino que también favorece la personalización de la enseñanza, ajustándose a las necesidades individuales de los estudiantes y promoviendo un aprendizaje más relevante y eficiente.

Este trabajo pudo constatar que el seguimiento de aprendizaje mediante minería de datos fortalece el rendimiento académico de los estudiantes, permitiendo anticipar problemas académicos y mejorando la calidad del aprendizaje individual y grupal. Los docentes en conjunto a los resultados obtenidos realizaron ajustes para mejorar la calidad de entrega de temas a ser vistos en clases.

Las diferentes situaciones de riesgo académico de los estudiantes es un desafío que todavía está abierto a los investigadores. El uso técnicas algorítmicas y modelos de abstracción de información con minería de datos llegan a ser relevantes como propuestas prometedoras para definir patrones de comportamiento de datos que con marcas de tiempo al dejar registros estos permiten ser identificados.

Se evidencia además que las características de los profesores de acuerdo con un patrón de comportamiento tienen un fuerte efecto positivo en el patrón de comportamiento de los estudiantes y que contribuye al desarrollo académico efectivo en un curso.

Es fundamental contribuir a la mejora de la experiencia del estudiante de un curso de educación superior, así como a las expectativas en su trayectoria académica, pero sobre todo ver la oportunidad de obtener información del proceso que realiza el estudiante de acuerdo con el análisis de su aprendizaje, de tal manera que se determinen factores que afecten al patrón de comportamiento, su compromiso y desempeño.

AGRADECIMIENTOS: En este trabajo se agradece la colaboración a los docentes que conforman el programa de maestría en educación. A la Universidad Politécnica Salesiana por la guía en el desarrollo del proyecto para la investigación presentada.

Referencias

- Adam, I. O., & Dzang Alhassan, M. (2020). Bridging the global digital divide through digital inclusion: the role of ICT access and ICT use. *Transforming Government: People, Process and Policy*, 15(4), 580–596. <https://doi.org/10.1108/TG-06-2020-0114/FULL/HTML>
- Akhuseyinoglu, K., & Brusilovsky, P. (2022). Exploring Behavioral Patterns for Data-Driven Modeling of Learners' Individual Differences. *Frontiers in Artificial Intelligence*, 5, 807320. <https://doi.org/10.3389/FRAI.2022.807320/BIBTEX>
- Alam, T. M., Mushtaq, M., Shaukat, K., Hameed, I. A., Sarwar, M. U., & Luo, S. (2021). A Novel Method for Performance Measurement of Public Educational Institutions Using Machine Learning Models. *Applied Sciences 2021, Vol. 11, Page 9296*, 11(19), 9296. <https://doi.org/10.3390/APP11199296>
- Almasri, A., Obaid, T., Abumandil, M. S. S., Eneizan, B., Mahmoud, A. Y., & Abu-Naser, S. S. (2023). Mining Educational Data to Improve Teachers' Performance. *Lecture Notes in Networks and Systems*, 550 LNNS, 243–255. https://doi.org/10.1007/978-3-031-16865-9_20
- Alrababah, S. A., & Molnár, G. (2021). The evolution of technology-based assessment: Past, present, and future. *International Journal of Learning Technology*, 16(2), 134–157. <https://doi.org/10.1504/IJLT.2021.117765;PAGEGROUP:STRING:PUBLICATION>
- Andrade, T., Almeida, C., & Barbosa, J. (2023). Modelo de Sistema de Recomendación integrado con Metodologías Activas, EDM y Analítica de Aprendizaje para la mitigación de la deserción escolar en Educación a Distancia. *Rev. Latinoam. Tecnol.* <https://relatec.unex.es/index.php/relatec/article/download/4781/2908#page=185>
- Angeioplastis, A., Aliprantis, J., Konstantakis, M., & Tsimpiris, A. (2025). Predicting Student Performance and Enhancing Learning Outcomes: A Data-Driven Approach Using Educational Data Mining Techniques. *COMPUTERS*, 14(3). <https://doi.org/10.3390/computers14030083> WE - Emerging Sources Citation Index (ESCI)
- Araka, E., Oboko, R., Maina, E., & Gitonga, R. (2022). Using Educational Data Mining Techniques to Identify Profiles in Self-Regulated Learning: An Empirical Evaluation. *The International Review of Research in Open and Distributed Learning*, 23(1), 131–162. <https://doi.org/10.19173/IRRODL.V22I4.5401>
- Atiaja Balseca, L. E. (2023). *Uso de la analítica del aprendizaje de los estudiantes para minimizar la pérdida escolar en las diferentes modalidades de estudio* [B.S.} thesis]. <https://dspace.ups.edu.ec/handle/123456789/25199>
- Ayala-Carabajo, R., & Llerena-Izquierdo, J. (2023). Modelo preventivo para minimizar estudiantes en riesgo académico para las asignaturas del primer año universitario. *CODES*, 5. <https://doi.org/10.15443/codes1917>
- Aydin, M. (2022). A multilevel modeling approach to investigating factors impacting computer and information literacy: ICILS Korea and Finland sample. *Education and Information Technologies*, 27(2), 1675–1703. <https://doi.org/10.1007/S10639-021-10690-1/METRICS>
- Bergmans, E., Metelmann, C., Metelmann, B., Rübsam, M.-L., von Au, F., & Thies, K.-C. (2021). Technology-enhanced learning in anesthesiology and emergency medicine: A new approach to medical school teaching in the wake of the pandemic; [„Technology-enhanced learning“ in Anästhesiologie und Notfallmedizin: Ein neuer Weg in der studentischen Lehre i. *Anaesthesist*. <https://doi.org/10.1007/s00101-021-01057-9>
- Bessadok, A., Abouzinadah, E., & Rabie, O. (2023). Exploring students digital activities and performances through their activities logged in learning management system using educational data mining approach. *Interactive Technology and Smart Education*, 20(1), 58–72. <https://doi.org/10.1108/ITSE-08-2021-0148/FULL/XML>

- Blundo, C., Fenza, G., Fuccio, G., Loia, V., & Orciuoli, F. (2022). Un enfoque basado en FCA y basado en el tiempo para identificar la deserción estudiantil en MOOC. *Revista Internacional De*, 37(4), 2683–2705. <https://doi.org/10.1002/INT.22414>
- Cedeno-Tello, A., & Llerena-Izquierdo, J. (2023). Impact of homogeneous use of virtual classrooms based on a management model for teaching-learning processes. *EDUNINE 2023 - 7th IEEE World Engineering Education Conference: Reimagining Engineering - Toward the Next Generation of Engineering Education, Merging Technologies in a Connected World, Proceedings*. <https://doi.org/10.1109/EDUNINE57531.2023.10102905>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Chen, X., Zou, D., Xie, H., Chen, G., Lin, J., & Cheng, G. (2023). Exploring contributors, collaborations, and research topics in educational technology: A joint analysis of mainstream conferences. *Education and Information Technologies*, 28(2), 1323–1358. <https://doi.org/10.1007/S10639-022-11209-Y/TABLES/5>
- Chen, Y., & Zhai, L. (2023). A comparative study on student performance prediction using machine learning. *Education and Information Technologies*, 28(9), 12039–12057. <https://doi.org/10.1007/S10639-023-11672-1/METRICS>
- de Brito Lima, F., & Lautert, S. L. (2022). Comportamientos de los estudiantes asociados con el uso de recursos y rutas de aprendizaje en escenarios de aprendizaje combinado. *Elsevier Computadoras y Educación, 2022 • Elsevier*. <https://www.sciencedirect.com/science/article/pii/S0360131522001968>
- Deeva, G., Smedt, J. De, Saint-Pierre, C., & ... R. W. (2022). Predicción del rendimiento de los estudiantes mediante la clasificación de secuencias con ventanas basadas en el tiempo. *Sistemas Expertos Con...* <https://www.sciencedirect.com/science/article/pii/S0957417422013471>
- Dien, T. T., Luu, S. H., Thanh-Hai, N., & Thai-Nghe, N. (2020). Aprendizaje profundo con transformación de datos y análisis factorial para la predicción del rendimiento estudiantil. *Revista Internacional De*, 11(8), 711–721. <https://doi.org/10.14569/IJACSA.2020.0110886>
- Espinosa-Zúñiga, J. J., & Espinosa-Zúñiga, J. J. (2020). Aplicación de metodología CRISP-DM para segmentación geográfica de una base de datos pública. *Ingeniería, Investigación y Tecnología*, 21(1), 1–13. <https://doi.org/10.22201/FI.25940732E.2020.21N1.008>
- Feng, G., Fan, M., & Ao, C. (2022). Exploration and Visualization of Learning Behavior Patterns From the Perspective of Educational Process Mining. *IEEE Access*, 10, 65271–65283. <https://doi.org/10.1109/ACCESS.2022.3184111>
- González Jaimes, N.L., Tejada Alcántara, A.A., Espinosa Méndez, C.M., y Ontiveros Hernández, Z. O. (2020). Impacto psicológico en estudiantes universitarios mexicanos por confinamiento durante la pandemia por Covid-19. *Scielo Preprints*. <https://doi.org/10.1590/SCIELOPREPRINTS.756>
- Grant, M. M. (2019). Difficulties in defining mobile learning: analysis, design characteristics, and implications. *ETR\&D-EDUCATIONAL TECHNOLOGY RESEARCH AND DEVELOPMENT*, 67(2), 361–388. <https://doi.org/10.1007/s11423-018-09641-4>
- Gupta, A., Garg, D., & Kumar, P. (2022). Mining Sequential Learning Trajectories with Hidden Markov Models for Early Prediction of At-Risk Students in E-Learning Environments. *IEEE Transactions on Learning Technologies*, 15(6), 783–797. <https://doi.org/10.1109/TLT.2022.3197486>
- Hilal, A., Sarwar Zamani, A., Ahmad, S., Rizwanullah, M., & Author, C. (2021). Una mejor predicción del rendimiento en la educación superior utilizando el árbol de decisiones. *Revista Internacional De*, 21(4). <https://doi.org/10.22937/IJCSNS.2021.21.4.25>
- Kim, K., Kim, H.-S., Shim, J., & Park, J. S. (2021). A Study in the Early Prediction of ICT Literacy Ratings Using Sustainability in Data Mining Techniques. *Sustainability*, 13(4), 2141. <https://doi.org/10.3390/su13042141>

- Kokoç, M., Akçapınar, G., Society, M. H.-E. T. &, & 2021, undefined. (2021). Unfolding students' online assignment submission behavioral patterns using temporal learning analytics. *JSTORM Kokoç, G Akçapınar, MN HasnineEducational Technology & Society, 2021*•JSTOR. <https://www.jstor.org/stable/26977869>
- Liu, F., Zhao, L., Zhao, J., Dai, Q., Fan, C., & Shen, J. (2022). Educational Process Mining for Discovering Students' Problem-Solving Ability in Computer Programming Education. *IEEE Transactions on Learning Technologies, 15*(6), 709–719. <https://doi.org/10.1109/TLT.2022.3216276>
- Llerena, J., Alava-Moran, N., & Zamora-Galindo, J. (2021). Learning analytics for student academic tracking, a comparison between Analytics Graphs and Edwiser Reports. *2021 Second International Conference on Information Systems and Software Technologies (ICI2ST)*, 101–107. <https://doi.org/10.1109/ICI2ST51859.2021.00022>
- Llerena, J., & Ayala-Carabajo, R. (2020). Significant learning activities (ASA) in the modality of face-to-face studies with integration of virtual educational media in Engineering careers. *2020 XV Conferencia Latinoamericana de Tecnologías de Aprendizaje (LACLO)*, 1–9. <https://doi.org/10.1109/LACLO50806.2020.9381134>
- Llerena-Izquierdo, J. (2023). Adaptation of the curriculum in relation to student learning outcomes in initial programming courses. *EDUNINE 2023 - 7th IEEE World Engineering Education Conference: Reimagining Engineering - Toward the Next Generation of Engineering Education, Merging Technologies in a Connected World, Proceedings*. <https://doi.org/10.1109/EDUNINE57531.2023.10102894>
- Llerena-Izquierdo, J., & Ayala-Carabajo, R. (2022). Inventory of ICTs for learning in engineering for emergency virtual teaching by COVID-19. *EDUNINE 2022 - 6th IEEE World Engineering Education Conference: Rethinking Engineering Education After COVID-19: A Path to the New Normal, Proceedings*. <https://doi.org/10.1109/EDUNINE53672.2022.9782389>
- Llerena-Izquierdo, J., Guerrero-Roldán, A.-E., & Rodríguez, M. E. (2022). LITERATURE REVIEW ON ASSESSMENT MODELS AND THEIR RELATIONSHIP TO LEARNING ANALYTICS. *EDULEARN22 Proceedings, 1*, 6036–6042. <https://doi.org/10.21125/EDULEARN.2022.1421>
- Llerena-Izquierdo, J., Mendez-Reyes, J., Ayala-Carabajo, R., & Andrade-Martinez, C. (2024). Innovations in Introductory Programming Education: The Role of AI with Google Colab and Gemini. In *Education Sciences* (Vol. 14, Issue 12). <https://doi.org/10.3390/educsci14121330>
- Llerena-Izquierdo, J., Rodríguez, M. E., & Guerrero-Roldán, A.-E. (2023). Monitoring and Adaptation of Assessment Activities in a VLE Supported by Learning Analytic. In V. Robles-Bykbaev, J. Mula, & G. Reynoso-Meza (Eds.), *Intelligent Technologies: Design and Applications for Society* (pp. 409–419). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-24327-1_35
- Lopez-Chila, R., Mora-Saltos, N., Cedeño-Tello, A., & Llerena-Izquierdo, J. (2023). A Learning Resource Management Model for high-enrollment Programming courses in Engineering. *2023 International Conference on Electrical, Communication and Computer Engineering (ICECCE)*, 1–6. <https://doi.org/10.1109/ICECCE61019.2023.10442311>
- Makhlouf, J., & Mine, T. (2020). Prediction Models for Automatic Assessment to Students' Freely-written Comments. *Scitepress.OrgJ Makhlouf, T MineCSEDU (1), 2020*•scitepress.Org, 1, 77–86. <https://doi.org/10.5220/0009580300770086>
- Makhlouf, J., & Mine, T. (2021). Mining Students' Comments to Build an Automated Feedback System. *Proceedings of the 13th International Conference on Computer Supported Education, 1*, 15–25. <https://doi.org/10.5220/0010372200150025>
- Mangina, E., & Psyrra, G. (2021). REVIEW OF LEARNING ANALYTICS AND EDUCATIONAL DATA MINING APPLICATIONS. *EDULEARN21 Proceedings, 1*, 949–954. <https://doi.org/10.21125/EDULEARN.2021.0250>

- Maphosa, M., ... V. M. la 2^a C. I. sobre, & 2020, undefined. (2020). Minería de datos educativos en la educación superior en África subsahariana: una revisión sistemática de la literatura y una agenda de investigación. *DL.Acm.OrgM Maphosa , V MaphosaActas de La 2.ª Conferencia Internacional Sobre Inteligencia y, 2020 • DL.Acm.Org*. <https://doi.org/10.1145/3415088.3415096>
- Memon, M., Lu, Y., Yu, S., Memon, A., Árabes, A. M.-R. I. de T. de la I. y las C., & 2022, undefined. (2022). El enfoque de selección de características críticas utilizando modelos basados en meta conjuntos para predecir el rendimiento académico. *Ccis2k.OrgMQ Memon , Y Lu , S Yu , A Memon , AR MemonRevista Internacional de Tecnología de La Información y La Comunicación, 2022 • Ccis2k.Org, 19(3A)*. <https://doi.org/10.34028/iajit/19/3A/12>
- Okoye, K., Hussein, H., Arrona-Palacios, A., Quintero, H. N., Ortega, L. O. P., Sanchez, A. L., Ortiz, E. A., Escamilla, J., & Hosseini, S. (2022). Impact of digital technologies upon teaching and learning in higher education in Latin America: an outlook on the reach, barriers, and bottlenecks. *Education and Information Technologies 2022 28:2, 28(2)*, 2291–2360. <https://doi.org/10.1007/S10639-022-11214-1>
- Pérez-Suasnavas, A.-L., Salgado-Proañó, B. F., Hasperué, W., R., K. L. Cela., & C., J. L. S. (2023). Evolución de las técnicas de minería de datos para extraer datos provenientes de twitter aplicadas a la educación superior: una revisión sistemática. *South Florida Journal of Development, 4(1)*, 33–55. <https://doi.org/10.46932/sfjdv4n1-002>
- Puga Paredes, J. L. (2023). *Mapeo sistemático sobre el seguimiento del aprendizaje de estudiantes mediante el uso de la minería de datos educativos* [B.S. thesis]. <https://dspace.ups.edu.ec/handle/123456789/26641>
- Rahman, M. M., Watanobe, Y., Matsumoto, T., Kiran, R. U., & Nakamura, K. (2022). Educational Data Mining to Support Programming Learning Using Problem-Solving Data. *IEEE Access, 10*, 26186–26202. <https://doi.org/10.1109/ACCESS.2022.3157288>
- Riobóo, L. M. D., & Pedroza, M. E. (2020). Constructos que han incidido en el rendimiento académico en la carrera de Ingeniería Agroindustrial en la Sede Regional UNI Norte. *Revista Ciencia y Tecnología El Higo, 10(1)*, 38–52. <https://doi.org/10.5377/ELHIGO.V10I1.9925>
- Sánchez, R. G., & Mateos, J. E. G. (2023). Minería de Datos Educativos: Descubrir tesoros ocultos durante el aprendizaje. *REVISTA CIENTÍFICA ECOCIENCIA, 10*, 18–41. <https://doi.org/10.21855/ECOCIENCIA.100.830>
- Saúde, S., Barros, J. P., & Almeida, I. (2024). *Impacts of Generative Artificial Intelligence in Higher Education: Research Trends and Students' Perceptions. 13(8)*. <https://doi.org/10.3390/socsci13080410>
- Souto-Seijo, A., Estévez, I., Fustes, V. I., & González-Sanmamed, M. (2020). Entre lo formal y lo no formal: un análisis desde la formación permanente del profesorado. *Educar.Uab.CatA Souto-Seijo, I Estévez, VI Fustes, M González-SanmamedEducar, 2020•educar.Uab.Cat, 56(1)*, 91–107. <https://doi.org/10.5565/REV/EDUCAR.1095>
- Tang, Y., Li, Z., Wang, G., & Hu, X. (2023). Modelado de comportamientos de aprendizaje y predicción del rendimiento en un sistema de tutoría inteligente: un enfoque de modelado de Markov oculto de dos capas. *Taylor & FrancisY Tang , Z Li, G Wang, X HuEntornos de Aprendizaje Interactivos, 2023 • Taylor & Francis, 31(9)*, 5495–5507. <https://doi.org/10.1080/10494820.2021.2010100>
- Tumbaco-Loor, D., & Llerena-Izquierdo, J. (2024). Use of Leaderboards to Gamified Drive Student Performance as a Motivational Strategy in VLE Environments. In J. P. Salgado-Guerrero, H. R. Vega-Carrillo, G. García-Fernández, & V. Robles-Bykbaev (Eds.), *Systems, Smart Technologies and Innovation for Society* (pp. 179–188). Springer Nature Switzerland.
- Valles-Coral, M. A., Salazar-Ramírez, L., Injante, R., Hernandez-Torres, E. A., Juárez-Díaz, J., Navarro-Cabrera, J. R., Pinedo, L., & Vidaurre-Rojas, P. (2022). Density-Based Unsupervised Learning

- Algorithm to Categorize College Students into Dropout Risk Levels. *Data* 2022, Vol. 7, Page 165, 7(11), 165. <https://doi.org/10.3390/DATA7110165>
- Wang, C., & Zhu, H. (2022). Wrongdoing Monitor: A Graph-Based Behavioral Anomaly Detection in Cyber Security. *IEEE Transactions on Information Forensics and Security*, 17, 2703–2718. <https://doi.org/10.1109/TIFS.2022.3191493>
- Wang, Q., & Mousavi, A. (2023). Which log variables significantly predict academic achievement? A systematic review and meta-analysis. *British Journal of Educational Technology*, 54(1), 142–191. <https://doi.org/10.1111/BJET.13282>;JOURNAL:JOURNAL:14678535;WEBSITE:WEBSITE:BER A-JOURNALS;WGROU:STRING:PUBLICATION
- Wang, X., Zhao, Y., Li, C., & Ren, P. (2023). ProbSAP: A comprehensive and high-performance system for student academic performance prediction. *Pattern Recognition*, 137, 109309. <https://doi.org/10.1016/J.PATCOG.2023.109309>
- Xing, W., Zhu, G., Arslan, O., Shim, J., & Popov, V. (2023). Using learning analytics to explore the multifaceted engagement in collaborative learning. *Journal of Computing in Higher Education*, 35(3), 633–662. <https://doi.org/10.1007/S12528-022-09343-0>/METRICS
- Yang, C., Chen, I., educativas, H. O.-T. y sociedad, & 2021, undefined. (2021). Hacia una educación de precisión. *JSTORCCY Yang , IYL Chen , H OgataTecnología Educativa y Sociedad*, 2021 • JSTOR, 24(1), 1176–3647. <https://www.jstor.org/stable/26977864>
- Zakaria, A. F., & Johnson Lim, S. C. (2022). Data Analytics Skill Development for Design Education: A Case Study in Optimal Product-Service Bundle Design. *Thinking Skills and Creativity*, 46, 101191. <https://doi.org/10.1016/J.TSC.2022.101191>