DOI: https://doi.org/10.26620/uniminuto.inventum.21.42.2026 ISSN 1909-2520 (Impreso), ISSN 2590-8219 (En línea)

Desarrollo de un modelo predictivo para evaluar el rendimiento académico de estudiantes del programa de gastronomía, mediante el análisis de sentimientos de PQRS y datos del sistema académico, mediante técnicas de aprendizaje de máquina en una institución tecnológica con ciclos trimestrales

Development of a predictive model to evaluate the academic performance of students in the gastronomy program, through sentiment analysis of complaints, claims, and requests (PQRS) and data from the academic system, using machine learning techniques in a technological institution with trimester cycles

Desenvolvimento de um modelo preditivo para avaliar o desempenho acadêmico de estudantes do curso de gastronomia, por meio da análise de sentimentos em reclamações, queixas e solicitações (PQRS) e dados do sistema acadêmico, utilizando técnicas de aprendizado de máquina em uma instituição tecnológica com ciclos trimestrais.

C. A. Castillo y Y. J. Nezhad

Resumen

Esta investigación tiene como propósito desarrollar un modelo predictivo para evaluar el rendimiento académico de los estudiantes del programa de gastronomía de una institución tecnológica con ciclos trimestrales, integrando principalmente la información del sistema de Peticiones, Quejas, Reclamos y Sugerencias (PQRS). El estudio adopta una metodología mixta que combina análisis cualitativo de los textos de las PQRS mediante técnicas de procesamiento de lenguaje natural (PLN) y análisis cuantitativo mediante modelos de aprendizaje de máquina.

Las PQRS, tradicionalmente utilizadas como mecanismos administrativos de atención al usuario, se emplean en este estudio como fuente alternativa de información emocional y perceptual de los estudiantes. Para ello, se implementaron procesos de análisis de sentimiento, detección de emociones, categorización temática y extracción de variables relevantes mediante PLN y LLM.

Se entrenaron y compararon diversos modelos predictivos, observándose que los modelos basados en árboles presentaron un mejor desempeño frente a los lineales, dada la complejidad del comportamiento humano y la naturaleza no lineal de los datos. Aunque la capacidad explicativa del modelo es moderada, se evidenció una capacidad aceptable para discriminar estudiantes con mayor probabilidad de presentar pérdida académica.

Los resultados muestran que es posible aprovechar la información contenida en las PQRS para fortalecer los sistemas institucionales de alerta temprana, permitiendo identificar patrones de riesgo asociados a factores emocionales, administrativos y académicos. Este enfoque aporta una nueva perspectiva para la gestión institucional, al integrar análisis de sentimientos y modelos predictivos en

la toma de decisiones orientadas al mejoramiento del rendimiento estudiantil y la satisfacción académica.

Palabras clave: Análisis de sentimientos, Modelos de predicción, XGBoost, Procesamiento de Lenguaje Natural (PLN), IA, ChatGPT, PQRS, Educación, IES.

Abstract

This research aims to develop a predictive model to evaluate the academic performance of students in the gastronomy program of a technological institution with quarterly cycles, mainly integrating information from the Petitions, Complaints, Claims and Suggestions (PQRS) system. The study adopts a mixed methodology that combines qualitative analysis of the PQRS texts using natural language processing (NLP) techniques and quantitative analysis using machine learning models.

The PQRS, traditionally used as administrative mechanisms for user service, are used in this study as an alternative source of emotional and perceptual information from students. To this end, processes of sentiment analysis, emotion detection, thematic categorization, and extraction of relevant variables were implemented using NLP and LLM.

Various predictive models were trained and compared, observing that tree-based models performed better than linear models, given the complexity of human behavior and the non-linear nature of the data. Although the explanatory capacity of the model is moderate, it was shown to have an acceptable capacity to discriminate against students with a higher probability of presenting academic loss.

The results show that it is possible to take advantage of the information contained in the PQRS to strengthen institutional early warning systems, allowing the identification of risk patterns associated with emotional, administrative, and academic factors. This approach provides a new perspective for institutional management, integrating sentiment analysis and predictive models into decision-making aimed at improving student performance and academic satisfaction.

Keywords: Sentiment analysis, Prediction models, XGBoost, Natural Language Processing (NLP), AI, ChatGPT, PQRS, Education, IES.

Resumo

Esta pesquisa tem como objetivo desenvolver um modelo preditivo para avaliar o desempenho acadêmico dos alunos do programa de gastronomia de uma instituição tecnológica com ciclos trimestrais, integrando principalmente as informações do sistema de Petições, Queixas, Reclamações e Sugestões (PQRS). O estudo adota uma metodologia mista que combina análise qualitativa dos textos das PQRS usando técnicas de processamento de linguagem natural (PLN) e análise quantitativa usando modelos de aprendizado de máquina.

As PQRS, tradicionalmente usadas como mecanismos administrativos de atendimento ao usuário, são empregadas neste estudo como uma fonte alternativa de informações emocionais e perceptivas dos alunos. Para isso, foram implementados processos de análise de sentimentos,

detecção de emoções, categorização temática e extração de variáveis relevantes por meio de PLN e LLM.

Vários modelos preditivos foram treinados e comparados, observando-se que os modelos baseados em árvores apresentaram melhor desempenho em relação aos lineares, dada a complexidade do comportamento humano e a natureza não linear dos dados. Embora a capacidade explicativa do modelo seja moderada, ele demonstrou uma capacidade aceitável de discriminar os alunos com maior probabilidade de apresentar perda acadêmica.

Os resultados mostram que é possível aproveitar as informações contidas nas PQRS para fortalecer os sistemas institucionais de alerta precoce, permitindo identificar padrões de risco associados a fatores emocionais, administrativos e acadêmicos. Essa abordagem traz uma nova perspectiva para a gestão institucional, integrando análise de sentimentos e modelos preditivos na tomada de decisões voltadas para a melhoria do desempenho estudantil e da satisfação acadêmica.

Palavras-chave: Análise de sentimentos, Modelos de previsão, XGBoost, Processamento de linguagem natural (PLN), IA, ChatGPT, PQRS, Educação, IES.

Introducción

Las Peticiones, Quejas, Reclamos y Sugerencias (PQRS) son el medio por el cual las organizaciones tienen contacto directo con los usuarios o ciudadanos a quienes prestan servicios, que suelen ser una cantidad elevada de personas, por lo que las organizaciones implementan software que ayuden a controlar este proceso. De no contar con este sistema, las entidades tanto públicas como privadas, pueden presentar problemas de satisfacción del usuario que derive en problemas de productividad, pérdidas económicas y otras consecuencias negativas para la organización.

El proceso de PQRS involucra personas, recursos físicos y tecnológicos con el fin brindar una respuesta al ciudadano dentro de los tiempos de respuesta establecidos en cada organización; dicho proceso, requiere de unos canales de comunicación que soporten la recepción de las solicitudes de los usuarios, estos canales pueden ser escritos, presenciales, verbales, por chat, correo electrónico o el sitio web. [1, pp. 32].

Cabe destacar que, en el contexto de las PQRS, el análisis de sentimiento puede entender cómo se sienten los usuarios o clientes con respecto a los servicios ofrecidos, mediante el mismo, se pueden identificar las causas que más generan emociones o sentimientos en los usuarios respecto al servicio ofrecido [2]. Sin embargo, para poder realizar un adecuado análisis de sentimiento de lo manifestado por los usuarios indicado en los medios anteriormente descritos, es necesario considerar cada uno de sus componentes de las PQRS.

En función de lo expuesto, esta investigación busca proponer le implementación de un modelo predictivo para predecir la perdida académica con respecto al análisis de sentimiento de las PQRS en una institución de educación superior (IES) mediante técnicas de minería de

datos, de manera que pueda determinarse si existe una tendencia o relación entre las variables, y en función de ello la institución pueda formular estrategias para contribuir a mejorar el rendimiento académico.

Antecedentes

En esta sección se presentan los principales antecedentes divididos en cuatro ejes: (I) modelos predictivos del rendimiento académico, (II) análisis de sentimientos en contextos educativos, (III) aplicaciones instituciones relacionadas con la gestión de PQRS y (IV) el uso de tecnologías emergentes, incluyendo modelos de lenguaje de gran tamaño en el análisis de texto educativo. Esta revisión permite sustentar la pertinencia de aprovechar las PQRS como insumo para sistemas de alerta temprana y para la comprensión del éxito académico desde una perspectiva emocional y administrativa.

(I) modelos predictivos del rendimiento académico

La literatura en minería de datos educativa (Educational Data Mining, EDM) ha demostrado una evolución significativa en el uso de datos académicos históricos para la construcción de modelos capaces de predecir el desempeño de los estudiantes, identificar factores de riesgo y orientar intervenciones tempranas. Estudios como los desarrollados por UTN-FRRe [8] demostraron la viabilidad de utilizar diversas técnicas de minería de datos para anticipar dificultades académicas y apoyar la toma de decisiones docentes y administrativas. Meza Huamán [9], por su lado, ha utilizado enfoques como CRISP-DM y modelos de regresión para identificar factores asociados al rendimiento académico. De forma complementaria, Vilá Baños *et al.* [12] revisan y comparan algoritmos de clasificación y regresión aplicados a la predicción del rendimiento y del riesgo de fracaso o deserción demostrando que el rendimiento académico es un fenómeno complejo, en el cual suele alcanzarse un equilibrio entre interpretabilidad y desempeño, y donde métricas como el AUC-ROC son especialmente valoradas en sistemas de alerta temprana.

(II) análisis de sentimientos en contextos educativos

El análisis de sentimientos se ha consolidado como una herramienta clave para interpretar opiniones y percepciones en contextos educativos, especialmente a partir de comentarios abiertos en encuestas foros o plataformas virtuales. Benavides Herrera [3] en Ecuador y Castillo Landinez & Caicedo Rodríguez [5] en Colombia han utilizado técnicas de procesamiento de lenguaje natural (PLN) para analizar la percepción estudiantil sobre modalidades de enseñanza, calidad docente, recursos digitales y experiencias de aprendizaje, identificando polaridad (positiva, negativa o neutra) y emociones asociadas. Complementando lo anterior, investigaciones como las realizadas por Flores Masias *et al*. [6] evidencian que el texto generado por los estudiantes contiene información emocional valiosa, que puede ser usada para mejorar la enseñanza,

ajustar estrategias didácticas y diseñar intervenciones de apoyo.

(III) aplicaciones instituciones relacionadas con la gestión de PQRS u opiniones de usuarios

Más allá del ámbito académico, el análisis de sentimientos también ha sido aplicado en contextos administrativos y de servicio empleando técnicas de minería de datos para analizar grandes volúmenes de solicitudes, identificar técnicas, clasificar temas recurrentes y detectar incumplimientos normativos; Además, Montiel, J. & Valenzuela, J. [10] han utilizado análisis de sentimientos en redes sociales para identificar posturas, emociones y niveles de satisfacción. Estos estudios constituyen una fuente rica de información para comprender las necesidades, expectativas y problemáticas de los usuarios.

(IV) el uso de tecnologías emergentes

El desarrollo reciente de la inteligencia artificial ha permitido la integración de modelos de lenguaje de gran tamaño (LLM) en tareas de análisis de texto, clasificación semántica y extracción automatizada de información. Estas tecnologías han ampliado las capacidades del PLN, permitiendo analizar grandes volúmenes de datos no estructurados con una precisión y contextualización superiores a los métodos tradicionales basados en diccionarios o clasificadores convencionales.

Estudios como el de Orji *et al*. [11] y Hussain *et al*. [7] han evidenciado que XGBoost ofrece ventajas significativas en contextos educativos, especialmente cuando se integran variables de tipo comportamental, emocional o provenientes de plataformas de interacción institucional. Su capacidad de regularización y manejo automático de valores faltantes lo hace idóneo para sistemas de alerta temprana, donde las fuentes de información suelen ser diversas y presentan grados de ruido o inconsistencia.

Cuando se trabaja con variables asociadas a emociones o percepciones estudiantiles es común que los modelos obtengan valores modestos de explicabilidad (por ejemplo, R^2 bajos), dado que el comportamiento humano presenta alta variabilidad y efectos no lineales difíciles de modelar. Sin embargo, XGBoost suele alcanzar métricas de discriminación superiores, como un AUC aceptable, lo que lo convierte en una alternativa eficiente para identificar estudiantes con mayor probabilidad de riesgo académico [13].

La propuesta de integrar datos académicos, demográficos y emocionales derivados del análisis de PQRS junto con la elección de XGBoost, alineada con las prácticas contemporáneas en analítica educativa, permite consolidar un modelo robusto capaz de aprovechar simultáneamente información académica, administrativa y afectiva lo que justifica la pertinencia del estudio y establece bases conceptuales y metodológicas sólidas para el desarrollo de un sistema institucional de monitoreo y prevención temprana orientado a mejorar el desempeño estudiantil.

Metodología

En esta sección se detalla la metodología CRISPDM aplicada durante la investigación sobre la propuesta de usabilidad de las PQRS en el ámbito educativo utilizando modelos de PLN y tecnologías actuales de LLM como lo es ChatGPT; a continuación, se describe el proceso de aplicación:

(I) Análisis Inicial

Esta etapa crucial para el desarrollo de la investigación se inició con técnicas de procesamiento de texto aplicando generación de corpus, nubes de palabras, procesos de lematización y análisis de sentimiento. Se utilizaron herramientas tecnológicas como RStudio, también se realizó un análisis comparativo con el uso de tecnologías LLM como lo es ChatGPT encontrando diferencias significativas en análisis de texto como *"Buenas tardes, no he podido ingresar para subir los documentos para presentar la empresa donde voy hacer mis practicas, agradezco la ayuda"*

Sentimiento	Puntuación
anger	0
anticipation	2
disgust	0
fear	0
joy	0
sadness	0
surprise	0
trust	0
negative	0
positive	3

Sentimiento	Neutro
Emoción	Frustración
Categoría	Problema técnico
Deuda	No dice
Área	Administrativa
Tipo	Solicitud de ayuda
Nivel	Medio

En este análisis se evidenció que era mejor para el desarrollo de la investigación el uso de la herramienta de LLM dando importancia al prompt como se realiza la solicitud a la IA (Inteligencia Artificial).

(II) Limpieza de datos y selección de variables

En esta etapa, se aplicó el resultado del uso de una IA especializada en LLM como fuente principal de generación del análisis del texto y un prompt que no generara tanto costo, los resultados generados no fueron estandarizados y se tuvo que generar limpieza de datos en la cual de realizaron procesos de agrupación de variables y selección de variables del SIA (Sistema de Información Academica) que no generaran una explicación mayor del modelo sobre las PQRS y no restar importancia al análisis del texto previamente realizado.

(III) Análisis exploratorio de los datos

Durante la revisión de la selección de variables se tenía que demostrar la importancia del análisis realizado de las PQRS, por tal motivo se pudo deducir: los estudiantes cuyas PQRS reflejan sentimientos negativos o

presencia de deuda presentan medianas más altas y una mayor dispersión en el porcentaje de pérdida, en contraste con quienes expresan sentimientos positivos o no registran deudas. Esto sugiere que tanto la carga emocional negativa como las dificultades financieras se asocian con un incremento del riesgo académico. De forma similar, dentro de las categorías administrativas, las solicitudes relacionadas con PQRS de tipo quejas y reclamos, así como las asociadas a servicios generales, concentraron los valores más elevados y heterogéneos, mientras que áreas como Pagos y Finanzas o Comunicación y Atención al Cliente mostraron niveles menores y más estables. Respecto al nivel académico, se observó que los grupos alto y bajo presentan mayor variabilidad y presencia de valores atípicos que el nivel medio, lo cual indica que los extremos del desempeño están vinculados a una mayor probabilidad de pérdida. En conjunto, estos resultados evidencian que factores emocionales, financieros y administrativos influyen significativamente en el comportamiento de la pérdida académica y constituyen en insumos valiosos para el desarrollo de los modelos predictivos en etapas posteriores del estudio.

Modelado

Para la fase de modelado se implementaron diferentes algoritmos, incluyendo árboles de decisión, Random Forest, XGBoost y modelos lineales como Regresión Lineal, Ridge y Lasso. Sin embargo, debido a la naturaleza de los datos, los modelos lineales no lograron un desempeño óptimo, presentando valores negativos en el coeficiente de determinación (R^2), lo que indica una baja capacidad explicativa.

Por el contrario, el modelo XGBoost mostró un mejor rendimiento, dado que, al ser un algoritmo basado en árboles potenciados por gradiente, mejora progresivamente con el entrenamiento y permite capturar relaciones no lineales entre las variables. Aun así, sin realizar ajustes de hiperparámetros, el modelo alcanzó únicamente un R^2 de 0.1295.

Modelo	error absoluto	Error Cuadrático Medio	R2
Regresión Lineal	0.349703	0.448899	-0.037367
Ridge	0.346268	0.440788	-0.00022
Lasso	0.367359	0.436995	0.016922
Árbol de Decisión	0.334802	0.463493	-0.105916
Random Forest	0.33875	0.416979	0.104917
XGBoost	0.305478	0.411209	0.129516

Resultados

En esta sección se detallan los resultados del modelo seleccionado (XGBoost) y la mejora del rendimiento aplicando hiperparámetros.

(I) Desempeño del modelo predictivo

Los modelos lineales (Regresión Lineal, Ridge y Lasso) mostraron desempeños limitados, presentando coeficientes de determinación (R^2) negativos o cercanos a cero, lo que indica que no lograban capturar la complejidad de la relación entre las variables y el rendimiento académico.

(II) Optimización del modelo mediante hiperparámetros

Para mejorar su desempeño, el modelo XGBoost fue optimizado utilizando Optuna, un framework orientado a la búsqueda eficiente de hiperparámetros mediante el uso de Tree-structured Parzen Estimators (TPE).

Tras el proceso de optimización, el modelo alcanzó:

- $R^2 = 0.1657$
- MAE = 0.2917
- RMSE = 0.3985}

(III) Evaluación del modelo

Dado que el rendimiento académico también puede interpretarse como un fenómeno binario (riesgo vs. no riesgo), se evaluó la capacidad del modelo para discriminar casos críticos mediante análisis de clasificación y curva Precision–Recall.

- AUC-ROC = 0.716
- Average Precision (AP) = 0.602

Este incremento en el R^2 confirma que, si bien la predicción exacta del porcentaje de pérdida es limitada, el modelo sí captura relaciones relevantes entre las variables emocionales (sentimiento, emoción, categoría), académicas y demográficas.

Adicionalmente, considerando la naturaleza del fenómeno estudiado. El desempeño indica que el modelo mantiene una precisión adecuada cuando identifica estudiantes de riesgo, aunque la precisión disminuye al intentar abarcar mayores niveles de recall, lo cual es normal en problemas donde la predicción se basa en emociones extraídas de texto.

Estos hallazgos demuestran que integrar datos no estructurados (PQRS) con datos académicos tradicionales fortalece la capacidad de las instituciones educativas para tomar decisiones informadas y diseñar estrategias orientadas al éxito estudiantil.

Conclusiones y recomendaciones

En esta sección se detalla la importancia del análisis de las PQRS en el ámbito académico y como su uso puede mejorar un sistema de alertas tempranas mediante el PLN y aplicación de modelos predictivos

(I) Conclusiones

El modelo XGBoost presentó el mejor desempeño, alcanzando un R^2 de 0.1657, un resultado esperado en predicciones basadas en comportamiento humano y emociones, donde la varianza explicada tiende a ser moderada incluso en literatura especializada.

A pesar del R^2 bajo, la evaluación con métricas de clasificación demostró que el modelo sí es útil para discriminar estudiantes en riesgo, logrando un AUC–ROC de 0.716. Esto indica una capacidad aceptable para apoyar sistemas institucionales de alerta temprana.

La curva Precision–Recall mostró un desempeño adecuado (AP = 0.602), lo cual es relevante en escenarios desbalanceados como la identificación de estudiantes con alto porcentaje de pérdida.

Este enfoque demuestra que los datos no estructurados (específicamente las PQRS) pueden convertirse en insumos estratégicos para comprender el comportamiento

académico, lo cual abre oportunidades para su uso en analítica institucional.

(II) Recomendaciones

Implementar un sistema de alerta temprana institucional, utilizando el modelo de clasificación desarrollado (AUC–ROC = 0.716) para identificar estudiantes con mayor probabilidad de presentar pérdida académica. Este sistema permitiría activar rutas de intervención como tutorías, apoyo académico, consejería o acompañamiento psicosocial.

Incluir el análisis de sentimientos como un insumo permanente en las estrategias de seguimiento estudiantil. Las emociones negativas detectadas en las PQRS pueden servir como indicadores tempranos de desmotivación, frustración o dificultades administrativas que afectan el rendimiento.

Diseñar intervenciones diferenciadas para los perfiles de riesgo identificados (por ejemplo, estudiantes con sentimientos negativos, presencia de deudas o dificultades administrativas), integrando acciones académicas, financieras y de bienestar.

Referencias

[1] D. P. Aguasaco Munevar & L. E. Gómez Luna, “Modelo de procesos para la gestión de Peticiones, Quejas, Reclamos y Sugerencias - PQRS de la Superintendencia de sociedades bajo metodología Business Process Management – BPM", Tesis de maestría, Universidad externado de Colombia, 2019 [En línea]. Disponible en: https://bdigital.uexternado.edu.co/entities/publication/c9a60d4f-8bf2-44b4-93be-0811486eda58

[2] Y. P. Ayala Alfonso, J. M. Durán Ramírez, J. A. Salamanca Bernal & E. F. González Martínez, “Análisis con Machine Learning de peticiones externas (PQRS) del Servicio Nacional de Aprendizaje - SENA para mitigación de incumplimientos normativos”, Trabajo de especialización, Universidad Los Libertadores, 2023 [En línea] Disponible en: https://repository.libertadores.edu.co/items/5bcdeecb-2f82-44b6-83db-8f40fd79170e

[3] C. Benavides Morales & B. Herrera Flores, “Educational Data Mining: análisis de sentimientos en un dominio universitario durante la pandemia. Chasqui”, *Revista Latinoamericana de Comunicación*, *no*. 151, pp. 217-236, 2022 [En línea]. Disponible en: https://dialnet.unirioja.es/servlet/articulo?codigo=8822181

[4] D. Buenaño Fernández, “Propuesta de un conjunto de herramientas de minería de datos para evaluar el desempeño de los estudiantes y los procesos de enseñanza-aprendizaje en el ámbito de la educación en ingeniería”, Tesis de Doctorado, Universidad de Alicante, 2020 [En

línea]. Disponible en: https://rua.ua.es/dspace/handle/10045/114335

[5] S. P. Castillo Landinez & P. E. Caicedo Rodríguez, "Análisis de sentimientos, una herramienta para valorar la actitud del estudiante frente a un curso". *Encuentro Internacional de Educación en Ingeniería ACOFI, ago. 2019.* [En línea]. Disponible en: https://acofipapers.org/index.php/eiei/article/view/141

[6] E. J. Flores Masias, J. H. Livia Segovia, A. García Casique & M. E. Dávila Díaz, "Análisis de sentimientos con inteligencia artificial para mejorar el proceso enseñanza-aprendizaje en el aula virtual" *Publicaciones*, vol. *53, no.* 2, pp. 185–216, 2023. [En línea]. Disponible en: https://doi.org/10.30827/publicaciones.v53i2.26825

[7] M. Hussain, W. Zhu, W. Zhang & S. M. R. Abidi, "Student engagement predictions in an e-learning system and their impact on student course outcomes using deep learning techniques" Computational Intelligence and Neuroscience, 2018. [En línea]. Disponible en: https://onlinelibrary.wiley.com/doi/10.1155/2018/6347186

[8] D. La Red Martínez, M. Karanik, M. Giovannini & R. Scappini "Hacia un modelo predictivo de rendimiento académico utilizando minería de datos en la UTN – FRRe" *XVIII Workshop de Investigadores en Ciencias de la Computación (WICC 2016, Entre Ríos, Argentina)*, *Red de Universidades con Carreras en Informática (RedUNCI), 940-944, 2016.* [En línea]. Disponible: https://sedici.unlp.edu.ar/handle/10915/53320

[9] J. A. Meza Huamán, "Factores que inciden en el rendimiento académico de los estudiantes de la Universidad Nacional de Cajamarca, aplicando técnicas de minería de datos" Tesis de doctorado, Universidad Nacional de Piura, 2022. [En línea]. Disponible en: https://repositorio.unp.edu.pe/items/98ab422a-d36f-4850-a64b-061ff09dc2c9

[10] J. C. Montiel Flores & J. P. Valenzuela, "Minería de datos para un análisis de sentimientos: un estudio de caso", *New Trends in Qualitative Research,* vol. 19, pp. 1-13, 2023. [En línea]. Disponible en: https://dialnet.unirioja.es/servlet/articulo?codigo=9285301

[11] F. Orji & j. Vassileva, "Machine Learning approach for predicting

students academic performance and study strategies based on their motivation", eprint arXiv:2210.08186, 2022. [En línea]. Disponible en: https://arxiv.org/abs/2210.08186

[12] R. Vilá Baños, B. Palou Julián & M. H. Rubio Hurtado, "Análisis de sentimiento de integración de la juventud de origen magrebí en Cataluña mediante la técnica de los árboles de decisión", *Pulso*, vol. 42, pp. 107–125, 2019. [En línea]. Disponible en: https://redined.educacion.gob.es/xmlui/handle/11162/193451

[13] Y. Zhang, Y. Wang, & T. Li, "Early warning of academic risk using machine learning techniques", *Computers & Education*, vol. 176, pp. 104354, 2022. [En línea]. Disponible en: https://doi.org/10.1016/j.compedu.2021.104354