

Reconocimiento de emociones en texto de estudiantes de educación secundaria rural utilizando algoritmos de clasificación

Fidel Huanco-Ramos¹, Yesenia Valentin-Ccori², Henry Shuta-Lloclla³,
Martha Yucra-Sotomayor³, Fredy Aparicio Castillo-Suaquita³

fhuanco@unsa.edu.pe; valentinyesenia2@gmail.com; henryshuta@unap.edu.pe;
myucras@unap.edu.pe; fcastillo@unap.edu.pe

¹ Universidad Nacional de San Agustín de Arequipa, Arequipa, 04001, Perú.

² Universidad Nacional de San Antonio Abad del Cusco, Puno, 21001, Perú.

³ Universidad Nacional del Altiplano, Puno, 21001, Perú.

DOI: 10.17013/risti.60.112–126

Resumen: Este estudio se centra en la aplicación de algoritmos de inteligencia artificial para el reconocimiento automático de emociones a partir de textos. El objetivo es identificar el algoritmo de clasificación más adecuado para detectar emociones en los textos que comúnmente se expresan en las instituciones de educación secundaria rural de Puno. Se recopilieron 1,150 comentarios textuales mediante una encuesta de autoevaluación emocional, los cuales fueron etiquetados manualmente por evaluadores capacitados y validados mediante consenso. Tras un preprocesamiento que incluyó tokenización, eliminación de stopwords y vectorización TF-IDF, los modelos fueron entrenados y evaluados utilizando Google Colab y la biblioteca scikit-learn. Los resultados revelaron que el algoritmo Random Forest destacó con una precisión del 73.81% y un AUC de 88.67%, superando a otros algoritmos en la identificación de emociones críticas. En conclusión, los hallazgos resaltan la importancia de detectar emociones negativas para mejorar el bienestar estudiantil y sugieren que la inteligencia artificial puede enriquecer la educación rural al identificar grupos de estudiantes con emociones similares, promoviendo así un ambiente escolar positivo y un mejor rendimiento académico.

Palabras-clave: Algoritmos de clasificación; Educación secundaria; Inteligencia artificial; Reconocimiento de emociones.

Emotion recognition in the text of rural secondary school students using classification algorithms

Abstract: This study focuses on the application of artificial intelligence algorithms for the automatic recognition of emotions from textual data. The objective is to identify the most suitable classification algorithm for detecting emotions in texts commonly expressed in rural secondary education institutions in Puno. A total

of 1,150 textual comments were collected through an emotional self-assessment survey, manually labeled by trained evaluators and validated through consensus. After preprocessing steps including tokenization, stopword removal, and TF-IDF vectorization, the models were trained and evaluated using Google Colab and the *scikit-learn* library. The results indicate that the Random Forest algorithm achieved the best performance, with a precision of 73.81% and an AUC of 88.67%, outperforming other algorithms in the identification of critical emotions. In conclusion, the findings highlight the importance of detecting negative emotions to improve student well-being and suggest that artificial intelligence can enhance rural education by identifying groups of students with similar emotional profiles, thereby promoting a positive school environment and improved academic performance.

Keywords: Artificial intelligence; Classification algorithms; Emotion recognition; Secondary education.

1. Introdução

Durante la última década, el interés por comprender las emociones ha ido en aumento dentro del ámbito educativo, en particular en aquellos espacios donde el bienestar emocional de los estudiantes se refleja directamente en su rendimiento académico (Alcocer-Sánchez et al., 2023). La habilidad para identificar y entender las emociones de los estudiantes se ha vuelto fundamental para crear entornos de aprendizaje efectivos y fomentar el desarrollo integral de los alumnos (Sagredo-Lillo et al., 2024). En las zonas rurales, esta necesidad es aún más importante debido a los retos específicos que enfrentan estas comunidades, como el aislamiento geográfico, el acceso limitado a servicios de apoyo psicológico, la escasez de recursos educativos y los factores culturales únicos que influyen en la forma en que se expresan las emociones (U. Alzubaidi, 2025).

En la región de Puno, Perú, ubicada a más de 3800 metros sobre el nivel del mar (m s.n. m.), es fundamental comprender cómo las emociones impactan en el aprendizaje y disponer de estrategias efectivas para detectarlas a tiempo (Vilca, 2016). Esta región presenta características particulares del contexto rural andino, donde factores culturales, socioeconómicos y de aislamiento geográfico influyen significativamente en las manifestaciones emocionales de los estudiantes (Zela Payi et al., 2022a). El uso de algoritmos de clasificación para el reconocimiento automático de emociones se plantea como una herramienta innovadora que puede ayudar a mejorar la interacción educativa y fortalecer el clima escolar en estas comunidades (Zhou, 2012).

Las tecnologías de inteligencia artificial (IA) y los algoritmos de aprendizaje automático abarcan un conjunto diverso de técnicas y aplicaciones orientadas a crear sistemas capaces de llevar a cabo tareas que, por lo general, requieren de la inteligencia humana (Segura Zúñiga, 2022). La inteligencia artificial está cambiando distintos sectores, como el reconocimiento de voz, el procesamiento del lenguaje natural, la visión por computadora y la robótica (Huanco-Ramos & Apaza-Tarqui, 2024). Gracias a su capacidad para aprender a partir de grandes volúmenes de datos, estos sistemas pueden mejorar de manera constante su rendimiento (Apaza-Tarqui & Huanco-Ramos, 2025). En el campo educativo, se han creado distintas tecnologías que buscan incorporar el análisis de las emociones dentro del proceso de enseñanza-aprendizaje (López et al., 2016).

A pesar de ello, son pocos los estudios que se centran específicamente en el reconocimiento de emociones en contextos educativos rurales, incorporando los factores culturales propios que influyen en las expresiones emocionales de los estudiantes en estas regiones (Cordero García et al., 2019a). Este vacío en la literatura evidencia la necesidad de explorar cómo los algoritmos de clasificación basados en aprendizaje automático pueden ajustarse y utilizarse de forma eficaz para detectar emociones en entornos educativos rurales de gran altitud, especialmente en la región de Puno (Patiño et al., 2024; Zela Payi et al., 2022b).

Las instituciones educativas en estos contextos se enfrentan a retos importantes debido a la presencia de conductas desadaptativas en algunos estudiantes. (Velázquez-Jurado et al., 2019). Estas conductas surgen de una interacción compleja de factores, entre los que se encuentran las disfunciones familiares, las dificultades socioemocionales, los elementos propios de la cultura viva de las comunidades rurales andinas y las limitaciones en las estrategias de prevención y manejo de conflictos (Richaud & Mesurado, 2016). La identificación temprana de emociones negativas, como la tristeza y la angustia, resulta fundamental para prevenir tanto el deterioro del rendimiento académico como posibles problemas de salud mental. Esto evidencia la necesidad de implementar programas integrales que atiendan de manera holística las necesidades emocionales de los estudiantes, involucrando de manera coordinada a la familia, la escuela y la comunidad (Ruales Jurado et al., 2022a).

La investigación se centra en responder la siguiente interrogante: ¿Qué algoritmo de clasificación de aprendizaje automático es el más efectivo para identificar automáticamente las emociones en los textos escritos por estudiantes de secundaria rural en Puno? Esta cuestión resulta relevante porque, aunque se dispone de diversos algoritmos de clasificación como KNN, Random Forest, SVM y GBM, no existe un consenso definido respecto a cuál de ellos proporciona el mejor equilibrio entre precisión, capacidad de generalización y facilidad de implementación, particularmente en contextos educativos que operan con recursos tecnológicos limitados (L. Alzubaidi et al., 2021).

Elegir el algoritmo adecuado no solo implica mirar métricas de efectividad como la precisión, el recall, el F1-score y el AUC (Mehta et al., 2019). También es importante tener en cuenta cuán interpretables son los resultados y si el algoritmo puede funcionar en tiempo real con recursos computacionales limitados. Los algoritmos tradicionales de aprendizaje automático son especialmente útiles en situaciones donde hay pocos datos y requieren menos potencia de cálculo que los modelos más complejos de deep learning (Janiesch et al., 2021). Esto los convierte en una opción para entornos educativos rurales, donde los recursos tecnológicos pueden ser bastante limitados.

Se plantea la hipótesis de que existe un algoritmo de clasificación que presenta un desempeño significativamente superior a los demás en la detección de emociones a partir de los textos expresados por estudiantes de instituciones de educación secundaria rural de la región Puno, facilitando la definición de perfiles estudiantiles diferenciados. En ese sentido, el objetivo del estudio es identificar el algoritmo de clasificación más adecuado para detectar emociones en los textos que comúnmente se expresan en las instituciones de educación secundaria rural de Puno, con el fin de seleccionar un modelo que pueda

implementarse como módulo base de un sistema de monitoreo emocional educativo, aportando evidencia empírica a la inteligencia artificial aplicada a la educación y una base metodológica orientada al fortalecimiento del bienestar emocional y el rendimiento académico en contextos rurales.

2. Revision de literatura

2.1. Las emociones y la educación

Definir las emociones es un verdadero desafío conceptual, ya que son tan complejas y multidimensionales. Involucran una mezcla de procesos neurobiológicos, fisiológicos, cognitivos y socioculturales. Desde un enfoque más moderno, podemos ver las emociones como sistemas adaptativos intrincados que ayudan a las personas a interpretar su entorno, regular su comportamiento y tomar decisiones basadas en estímulos tanto internos como externos (Ekman, 1992). En este sentido, sentir significa que la persona se involucra activamente con su entorno, donde la emoción juega un papel crucial en la regulación y adaptación a las exigencias del contexto educativo y social (Pennebaker, 2004).

La emoción y la educación están interrelacionadas, ya que las emociones tienen un impacto significativo en el proceso de aprendizaje y en el entorno educativo (Gao, 2022). La investigación científica ha demostrado que las emociones afectan aspectos fundamentales como la motivación, la atención y la memoria, los cuales son esenciales para un aprendizaje efectivo. Según John D. Mayer, las emociones juegan un papel crucial en la manera en que los estudiantes procesan la información y se involucran en el aula. Además, la capacidad de los estudiantes para regular sus propias emociones influye notablemente en el éxito académico (Mayer, 2001). Además, **Daniel Goleman** sostiene que la inteligencia emocional, que incluye la capacidad para entender y manejar las propias emociones y las de los demás, es esencial para el éxito tanto académico como personal (Goleman, 1995).

¿Qué es una emoción?

El término *emoción* proviene del latín *emotio*, derivado de *motio* (movimiento), lo que remite a la idea de impulso o activación hacia la acción. Esta raíz etimológica, compartida con el concepto de *motivación*, refuerza la concepción de la emoción como un proceso dinámico que orienta la conducta del individuo frente a su entorno (Villegas, 2020). Desde esta perspectiva, las emociones no se limitan a estados subjetivos, sino que constituyen respuestas organizadas del organismo que integran componentes afectivos, cognitivos y conductuales.

Uno de los primeros enfoques científicos sobre la naturaleza de las emociones fue propuesto por Darwin, (1873). Él las vio como mecanismos adaptativos universales que compartimos tanto los humanos como otros animales, y que funcionan de manera independiente del aprendizaje cultural. Esta perspectiva evolutiva sentó las bases para investigaciones posteriores que revelaron la existencia de patrones emocionales reconocibles a través de diferentes culturas. Este enfoque es especialmente importante para los estudios actuales en la detección automática de emociones, ya que respalda la

idea de que es posible identificar regularidades emocionales a partir de manifestaciones observables, como el lenguaje escrito, incluso en contextos socioculturales específicos.

2.2. Modelos de clasificación de emociones

Son modelos teóricos que organizan y analizan las emociones humanas desde diferentes perspectivas. Los modelos empleados para la clasificación de emociones suelen ser “Categorías Emocionales” y “Dimensiones Emocionales” (Canales & Martínez-Barco, 2015). Según Scherer (2000), los modelos dimensionales se centran en los sentimientos subjetivos y se diferencian según el grado de similitud entre dimensiones. En contraste, las categorías emocionales se enfocan en la expresión motora o en patrones de comportamiento. A continuación, se presenta las principales modelos de clasificación de emociones:

Modelo de las Emociones Básicas: Paul Ekman propuso que existen seis emociones básicas universales: alegría, tristeza, ira, miedo, sorpresa y disgusto. Estas emociones son reconocidas a través de expresiones faciales universales (Ekman, 1992). Básicamente consistía en que personas de distintas nacionalidades se reconocen y se identifican de manera particular.

Modelo de las Emociones Primarias: Según Plutchik (1982) menciona que, para determinar cuáles son las emociones primarias y poder etiquetarlas, es necesario entenderlas en un marco evolutivo, aplicable tanto a animales como a humanos. Asimismo, sugiere ocho emociones: Miedo, Ira, Alegría, Tristeza, Confianza, Disgusto, Sorpresa y Anticipación.

2.3. Detección de emociones en texto

La detección de emociones en textos se apoya en técnicas de análisis de sentimientos y en el procesamiento del lenguaje natural (PLN) (Malagi et al., 2023). De manera histórica, esta tarea ha utilizado métodos de análisis léxico-semántico junto con algoritmos de aprendizaje automático para identificar y comprender las emociones que se manifiestan a través de la escritura (Pang & Lee, 2008). Las herramientas como los lexicones emocionales y el análisis semántico han hecho posible vincular palabras y expresiones con categorías emocionales específicas. (Mohammad & Turney, 2013).

En los últimos años, la detección de emociones en textos ha evolucionado gracias a modelos de aprendizaje automático y redes neuronales. Estas herramientas son capaces de captar el contexto y las relaciones semánticas del lenguaje de una manera mucho más precisa. Han demostrado ser especialmente útiles en entornos educativos digitales, donde los estudiantes comparten sus emociones a través de comentarios, mensajes o publicaciones en plataformas virtuales.

2.4. Algoritmos de clasificación

Estos son la base de los sistemas de inteligencia artificial, ya que permiten a las máquinas aprender de la experiencia (Oviedo et al., 2021). Los algoritmos de clasificación se utilizan en casos en los que el resultado es un conjunto infinito de resultados (Cruz Guerrero et al., 2017). Actualmente se utilizan diversas técnicas de aprendizaje automático para problemas de clasificación. Entre ellas, encontramos:

1. El algoritmo k-Nearest Neighbors (k-NN o k-vecinos más próximos) es un método de Machine Learning simple. En clasificación, asigna una etiqueta de clase a un punto de datos basándose en las etiquetas de clase de los k vecinos más cercanos en el conjunto de entrenamiento. Los vecinos se seleccionan según la distancia euclidiana u otra medida de distancia, y el valor de k se especifica previamente (Cunningham & Delany, 2021).
2. Random Forest es un algoritmo de aprendizaje supervisado que se utiliza tanto para clasificación y regresión (Dayananda et al., 2023a). Se basa en la creación de múltiples árboles de decisión durante el entrenamiento y realiza predicciones a partir de la votación o el promedio de las predicciones de todos los árboles individuales. Este enfoque ayuda a mejorar la precisión y a reducir el riesgo de sobreajuste (Schonlau & Zou, 2020).
3. Support Vector Machines (SVM) es un algoritmo de aprendizaje supervisado utilizado principalmente para problemas de clasificación, aunque también se adapta para regresión. SVM busca encontrar el hiperplano óptimo que separa las diferentes clases en el espacio de características, maximizando el margen entre las clases más cercanas (Brereton & Lloyd, 2010).
4. Gradient Boosting Machines (GBM) es un algoritmo de aprendizaje supervisado utilizado para problemas de clasificación y regresión. Se basa en el principio del “boosting”, que combina múltiples modelos débiles (como árboles de decisión) para crear un modelo fuerte (Biau et al., 2019). GBM ajusta los árboles de decisión de manera secuencial, corrigiendo los errores de los árboles anteriores.

2.5. Evaluación de los clasificadores

La evaluación de clasificadores es el proceso mediante el cual se mide el rendimiento de un modelo de clasificación, utiliza diversas métricas que permiten cuantificar su capacidad para predecir correctamente las categorías de datos no vistos. Este proceso es crucial para garantizar que el modelo sea robusto, generalice bien a nuevos datos y cumpla con los requisitos del problema que se está abordando.

1. **Matriz de confusión:** La matriz de confusión permite visualizar el desempeño de un algoritmo utilizado en aprendizaje supervisado. Las columnas representan el número de predicciones para cada clase, mientras que cada fila representa las instancias de la clase real.
2. **Exactitud (Accuracy):** Esta métrica indica el porcentaje de predicciones correctas respecto al total de predicciones realizadas. Es una medida general que proporciona una visión rápida del rendimiento del modelo (Friedman, 2001).

$$\text{Exactitud} = \frac{VP + VP + VP}{VP + VP + VP + FP + FP + FP + FN + FN + FN}$$

3. **Precisión (Precision):** La precisión se refiere a la proporción de verdaderos positivos entre el total de predicciones positivas realizadas. Es crucial en contextos donde es importante minimizar los falsos positivos (Pang & Lee, 2008).

$$Presicion_{A,F,T} = \frac{VP}{VP + FP}$$

4. **Recall (Sensibilidad o Tasa de Verdaderos Positivos):** El recall indica la capacidad del modelo para identificar correctamente las emociones verdaderas. Un alto valor de recall es esencial en escenarios donde la detección de emociones es crítica, minimizando los falsos negativos negativos(Bishop, 2006).

$$Recall_{A,F,T} = \frac{VP}{VP + FN}$$

5. **F1-Score:** Esta métrica combina precisión y recall en un solo valor, proporcionando un equilibrio entre ambas. Es particularmente útil cuando se busca un compromiso entre la exactitud y la exhaustividad(Goodfellow et al., 2016).

$$F1-Score_{A,F,T} = 2 * \frac{Presicion * Recall}{Presicion + Recall}$$

6. **AUC (Área bajo la curva ROC):** El AUC proporciona una medida del rendimiento del modelo en función de la tasa de verdaderos positivos frente a la tasa de falsos positivos. Un AUC cercano a 1 indica un modelo altamente efectivo, mientras que un AUC de 0.5 sugiere un rendimiento aleatorio (Hanley & McNeil, 1982).

3. Metodologia

El estudio se llevó a cabo con un diseño de investigación no experimental, de tipo transversal y con un enfoque cuantitativo. Su objetivo fue evaluar de manera comparativa el rendimiento de varios algoritmos clásicos de aprendizaje automático en la detección de emociones a partir de textos escritos por estudiantes de educación secundaria en áreas rural(Sampieri, 2014).

Desde una perspectiva computacional, el experimento se llevó a cabo en Google Colab, utilizando Python y algunas bibliotecas especializadas como scikit-learn, pandas y numpy. Esto no solo aseguró que los experimentos fueran reproducibles, sino que también facilitó el acceso a recursos en la nube y mantuvo la consistencia en los resultados. El proceso metodológico se dividió en cuatro etapas: recolección de datos, preprocesamiento del texto, entrenamiento de modelos y evaluación del rendimiento. El proceso se dividió en cuatro etapas:

3.1. Recolección de datos y muestra

La población objetivo estuvo compuesta por estudiantes de secundaria de escuelas rurales en la región de Puno, Perú, que se encuentra a más de 4,000 metros sobre el nivel

del mar. Este entorno geográfico y sociocultural presenta desafíos únicos que afectan el bienestar emocional de los estudiantes.

La muestra fue seleccionada mediante un muestreo no probabilístico por conveniencia y estuvo conformada por 1 150 textos escritos recolectados a lo largo del año académico. Dichos textos fueron producidos por estudiantes que participaron de manera voluntaria en el estudio. Como criterios de inclusión se consideraron: estar matriculados en educación secundaria, pertenecer a instituciones educativas de contexto rural y presentar respuestas textuales completas y legibles.

Se excluyeron aquellos textos incompletos, irrelevantes o que no presentaban un contenido emocional claramente identificable.

Para la recolección de datos se diseñó una encuesta de autoevaluación emocional, mediante la cual se solicitó a los estudiantes que describieran libremente sus estados emocionales frente a situaciones escolares cotidianas. Las emociones analizadas fueron tristeza, angustia y felicidad, seleccionadas debido a su alta prevalencia en contextos educativos y a su relevancia en la literatura científica sobre bienestar emocional en adolescentes. Se observa en la Tabla 1.

Emoción	Características	Palabras o Frases representativas	Textos escritos (%)	Textos escritos(n)
Tristeza	Sensación de pérdida, desánimo, melancolía.	“Me siento vacío”, “Estoy muy desilusionado”, “No tengo ganas de nada.”	24.43	281
Angustia	Ansiedad, tensión, preocupación intensa	“Siento un nudo en el estómago”, “No puedo dejar de pensar en eso”, “Estoy abrumado.”	44.43	511
Felicidad	Alegría, satisfacción, bienestar emocional.	“Estoy muy contento”, “Me siento pleno”, “Todo me parece maravilloso.”	31.13	358
Total			100 %	1150

Tabla 1 – Emociones expresadas por estudiantes en textos escritos

Dado que el estudio incluye datos de menores, se aplicaron principios éticos fundamentales. La participación fue completamente voluntaria, los textos se anonimizaron antes del análisis y no se recogió información personal identificable. Los datos se usaron únicamente con fines académicos y de investigación, respetando las normas de privacidad y protección de datos, de acuerdo con las recomendaciones éticas para investigaciones educativas que utilizan inteligencia artificial.

3.2. Preprocesamiento de texto

El preprocesamiento es una etapa fundamental en las tareas de detección de emociones en texto, ya que tiene un impacto directo en el rendimiento de los modelos de clasificación. En este estudio, se llevaron a cabo los siguientes pasos estandarizados de procesamiento de lenguaje natural:

- Cambia todas las letras del texto a minúsculas, para evitar duplicidad semántica.
- Elimina dígitos y signos de puntuación
- Elimina caracteres como comas, puntos, signos de interrogación.
- Tokenización, divide los textos en palabras o frases.
- Eliminación de stopwords en español, con el fin de reducir ruido lingüístico.

Posteriormente, los textos fueron transformados en representaciones numéricas mediante técnicas de vectorización TF-IDF, ampliamente utilizadas en tareas de clasificación textual por su capacidad para ponderar términos relevantes en función de su frecuencia e importancia contextual.

3.3. Entrenamiento de algoritmos de clasificación

El conjunto de datos que se preprocesó se dividió en dos partes: un 80 % se destinó al entrenamiento y un 20 % a la prueba, utilizando la función `train_test_split` de la biblioteca `scikit-learn`. Esta estrategia es útil porque permite evaluar cómo se desempeñan los modelos con datos que no han visto durante el entrenamiento, lo que ayuda a disminuir el riesgo de sobreajuste.

Se entrenaron y compararon cuatro algoritmos clásicos de aprendizaje supervisado:

- k-Nearest Neighbors (KNN)
- Random Forest
- Support Vector Machines (SVM)
- Gradient Boosting Machines (GBM).

Cada modelo fue entrenado con el mismo conjunto de datos y las tres clases emocionales: tristeza, angustia y felicidad. Los hiperparámetros se ajustaron a través de validación cruzada, con el fin de optimizar el rendimiento de cada algoritmo y garantizar una comparación justa entre ellos.

3.4. Evaluación de modelos

El rendimiento de los modelos se evaluó utilizando el conjunto de prueba, mediante métricas estándar propias de la clasificación multiclase, tales como:

- Exactitud (*accuracy*)
- Precisión (*precision*)
- Exhaustividad (*recall*)
- F1-score
- Área bajo la curva ROC (AUC)

Además, se crearon matrices de confusión y reportes detallados de clasificación utilizando la función `classification_report` de `scikit-learn`. Esto nos permitió examinar cómo se comportaba cada algoritmo, tanto en términos generales como por cada clase emocional.

Esta evaluación completa ayudó a identificar cuál modelo tenía el mejor rendimiento y a entender las dificultades que surgen al clasificar automáticamente emociones a partir de textos breves en contextos educativos rurales.

4. Resultados y discusion

4.1. Resultados

4.1.1. Evaluación de algoritmos de clasificación según las métricas

En la Figura 1 se presenta la evaluación de los algoritmos de clasificación mediante una matriz de confusión multiclase, a partir de métricas como accuracy, precision, recall y F1-score. Tras el entrenamiento de KNN, Random Forest, SVM y GBM con datos de estudiantes rurales de Puno, el modelo Random Forest mostró el mejor desempeño, destacando especialmente en la detección de la emoción de angustia, seguido de felicidad y tristeza.




Figura 1 – Matriz de Confusión multi-clase para tres (03) emociones del Modelo Random Forest para la Detección de Emociones.

Algoritmos	Accuracy	Precision	Recall	F1-Score	AUC
KNN	66.9565%	67.4368%	66.9565%	66.8495%	82.2629%
Random Forest	72.6087%	73.8145%	72.6087%	72.5735%	88.6749%
SVM	71.3043%	72.4236%	71.3043%	70.8757%	84.0898%
GBM	66.9565%	68.0091%	66.9565%	66.6073%	85.9492%

Tabla 2 – Rendimiento de Modelos: Exactitud, Precisión, Recall, F1-Score y AUC

El algoritmo Random Forest presenta el mejor desempeño en la detección de emociones en textos estudiantiles, alcanzando un Accuracy de 72.61%, Precision de 73.81% y un AUC de 88.67%. Su equilibrio entre precisión y recall lo posiciona como la opción más

robusta frente a SVM, KNN y GBM, recomendándose su optimización y validación en conjuntos de datos más amplios.

En la Figura 2 se visualiza el desempeño de diversos algoritmos de clasificación (KNN, Random Forest, SVM, GBM), utilizando métricas como accuracy, precisión, recall, F1-score y AUC. En consecuencia, el modelo de Random Forest demostró el mejor rendimiento en las métricas claves como el F1-score y AUC.




Figura 2 – Matriz de confusión para la clasificación de las emociones: KNN, Random Forest, SMV, GBM

4.1.2. Reconocimiento de emociones en texto por categoría

En la Tabla 3 se muestran las métricas de desempeño del modelo (precision, recall, F1-score y support). Los resultados indican que la clase **tristeza** presenta la mayor precisión (83%), lo que sugiere que el modelo identifica de manera adecuada la mayoría de los textos asociados con esta emoción. Por otro lado, la clase **angustia** sobresale por alcanzar un recall del 80% y un F1-score del 75%, lo que refleja una buena capacidad para detectar correctamente los casos positivos.

Emociones	Precision	Recall	F1-Score	support
Tristeza	83%	65%	73%	62
Angustia	70%	80%	75%	98
Felicidad	68%	69%	68%	70

Tabla 3 – Resultados de clasificación de emociones

De forma general, el algoritmo tiene un mejor desempeño al identificar emociones negativas, como la tristeza y la angustia, en comparación con emociones positivas

como la felicidad. Este comportamiento podría estar relacionado con el contexto de los estudiantes de educación secundaria en zonas rurales, donde aspectos como las limitaciones educativas, la falta de apoyo psicológico y el aislamiento social influyen de manera significativa en su estado emocional y, en consecuencia, en su rendimiento académico.

4.2. Discusion

Este estudio ha demostrado que el uso de algoritmos de clasificación como KNN, Random Forest, SVM y GBM resultan apropiados para el reconocimiento automático de emociones en textos producidos por estudiantes de educación secundaria del sector rural. Estos hallazgos coinciden con investigaciones previas que destacan la efectividad del aprendizaje automático en tareas de clasificación textual (Dayananda et al., 2023), particularmente cuando se trabaja con datos limitados y recursos tecnológicos restringidos, condiciones características de los entornos educativos rurales.

El análisis de sentimientos y emociones permite identificar tanto emociones positivas como negativas, aunque con diferentes niveles de efectividad. La identificación precisa de emociones, especialmente emociones negativas como la tristeza y la angustia, resulta esencial para comprender el estado emocional de los estudiantes y desarrollar estrategias de intervención que promuevan su bienestar (Ruales Jurado et al., 2022b). Esto subraya la importancia de aplicar modelos de clasificación adaptados a entornos educativos rurales, contribuyendo así a un aprendizaje más inclusivo y emocionalmente consciente, tal como sugieren (Sagredo-Lillo et al., 2024) al enfatizar la necesidad de considerar las particularidades contextuales en las intervenciones educativas.

Entre los algoritmos evaluados, Random Forest se destacó por obtener los mejores resultados, presentando un balance óptimo en términos de exactitud (72.61%), precisión (73.81%), recall (72.61%), F1-score (72.57%) y AUC (88.67%). Este hallazgo es consistente con estudios previos que han demostrado la superioridad de Random Forest en tareas de clasificación complejas debido a su capacidad para manejar datos multidimensionales y reducir el sobreajuste (Schonlau & Zou, 2020). La robustez de este algoritmo sugiere que es el más adecuado para la detección de emociones en textos dentro de contextos educativos rurales específicos, donde factores culturales y sociolingüísticos particulares influyen en las expresiones emocionales. (Berné Manero et al., 2013; Cordero García et al., 2019b)

Los resultados obtenidos revelan que las emociones negativas, particularmente la angustia (recall del 80%), fueron detectadas con mayor efectividad que las emociones positivas como la felicidad (F1-Score del 68%). Este patrón puede estar relacionado con la mayor intensidad expresiva de las emociones negativas en el lenguaje escrito, como han señalado Canales y Martínez-Barco (2015), así como con el contexto socioemocional de los estudiantes rurales de Puno, quienes enfrentan desafíos particulares relacionados con el aislamiento geográfico, la limitada disponibilidad de apoyo psicológico y las condiciones socioeconómicas adversas (Zela Payi et al., 2022a).

La detección temprana de emociones negativas en estudiantes rurales adquiere especial relevancia considerando que la región de Puno presenta características únicas del contexto andino, donde factores de altitud (más de 3,800 m.s.n.m.), culturales y de

aislamiento geográfico influyen significativamente en las manifestaciones emocionales (Vilca, 2016). La implementación de sistemas automatizados de monitoreo emocional puede compensar parcialmente la escasez de recursos de apoyo psicológico en estas comunidades, permitiendo identificar estudiantes en riesgo de manera oportuna.

5. Conclusion

Este estudio demuestra que algoritmos de clasificación como KNN, Random Forest, SVM y GBM pueden convertirse en aliados valiosos para comprender las emociones de estudiantes de educación secundaria en contextos rurales. A través del análisis de sentimientos y emociones, fue posible reconocer tanto estados emocionales positivos como negativos, aunque con distintos niveles de efectividad. En particular, la identificación de emociones negativas —como la tristeza y la angustia— cobra especial relevancia, ya que permite entender mejor el estado emocional de los estudiantes y orientar acciones de apoyo que contribuyan a su bienestar integral.

Entre los modelos evaluados, Random Forest destacó por su mejor desempeño, alcanzando una exactitud del 72.61%, una precisión del 73.81%, un recall del 72.61%, un F1-score del 72.57% y un AUC del 88.67%. Estos resultados indican que este algoritmo es especialmente eficaz para detectar emociones a partir de textos en entornos educativos rurales, donde comprender la realidad emocional de los estudiantes resulta clave.

Sin embargo, el estudio presenta algunas limitaciones que deben considerarse. La muestra analizada proviene de un contexto geográfico específico, se enfocó únicamente en tres emociones y utilizó una sola plataforma social como fuente de datos. Por ello, los hallazgos deben interpretarse con cautela y no pueden generalizarse de manera automática a otros escenarios educativos o regiones.

De cara al futuro, se sugiere ampliar el tamaño y la diversidad de la muestra, incorporar un mayor número de categorías emocionales y comparar el desempeño de los algoritmos en distintas plataformas digitales. La aplicación de herramientas de inteligencia artificial en contextos educativos rurales ofrece un gran potencial para detectar de manera temprana las necesidades emocionales de los estudiantes, mejorar el clima escolar y favorecer su rendimiento académico, promoviendo así un aprendizaje más inclusivo y sensible a la dimensión socioemocional.

Referencias

- Apaza-Tarqui, A., & Huanco-Ramos, F. (2025). Models of automatic recognition of collaborative emotions in rural secondary education institutions in Puno, 2024. *Journal of International Crisis and Risk Communication Research*, 3306–3325. <https://doi.org/10.63278/JICRCR.VI.2615>
- Canales, L., & Martínez-Barco, P. (2015). *Emotion Detection from text: A Survey*. <https://doi.org/10.3115/v1/w14-6905>

- Cordero García, S. P., Chinome Alba, C. P., & Garzón Bautista, A. del P. (2019). Emociones y habilidades comunicativas en la convivencia escolar en la IE Rural del Sur de Tunja. *Educación y Ciencia*, 22. <https://doi.org/10.19053/0120-7105.eyc.2019.22.e10047>
- Cruz Guerrero, R., Alonso Lavernia, Ma. de los Á., Franco Arcega, A., & Simón Marmolejo, I. (2017). Estudio del comportamiento de algoritmos de clasificación según la naturaleza de los datos. *Revista de Tecnología Informática*, 1(2), 9-18.
- Darwin, C. (1873). The Expression of the Emotions in Man and Animals. *The Journal of the Anthropological Institute of Great Britain and Ireland*, 2(2), 444-446. <https://doi.org/10.2307/2841467>
- Ekman, P. (1992). Facial expressions of emotion: an old controversy and new findings. *Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences*, 335(1273), 63-69. <https://doi.org/10.1098/RSTB.1992.0008>
- Huanco-Ramos, F., & Apaza-Tarqui, A. (2024). Covid 19 identification model using Deep Learning techniques from thorax of lung X-ray images. *Proceedings of the LACCEI International Multi-Conference for Engineering, Education and Technology*. <https://doi.org/10.18687/LACCEI2024.1.1.1491>
- López, M. B., Montes, A. J. H., Ramírez, R. V., Hernández, G. A., Cabada, R. Z., & Estrada, M. L. B. (2016). EmoRemSys: Sistema de recomendación de recursos educativos basado en detección de emociones. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, (17), 80-95. <https://doi.org/10.17013/risti.17.80-95>
- Mohammad, S. M., & Turney, P. D. (2013). Crowdsourcing a word-emotion association lexicon. *Computational Intelligence*, 29(3), 436-465. <https://doi.org/10.1111/j.1467-8640.2012.00460.x>
- Oviedo, B., Jorge, B., Fajardo, G., & Gómez-Gómez, J. (2021). Utilización de algoritmos de clasificación para la predicción de los delitos que afectan la seguridad ciudadana. *Centro Sur*.
- Pang, B., & Lee, L. (2008). Opinion mining and sentiment analysis. *Foundations and Trends in Information Retrieval*, 2(1-2), 1-135. <https://doi.org/10.1561/15000000011>
- Patiño, M. M., Pérez, E. C., & Sanchez, S. S. (2024). Detección temprana de cáncer de mama: clasificación de mastografías mediante un modelo de aprendizaje profundo. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (55), 21-37. <https://doi.org/10.17013/risti.55.21-37>
- Plutchik, R. (1982). Apsychoevolutionary theory of emotions. *Social Science Information*, 21(4-5), 529-553. <https://doi.org/10.1177/053901882021004003>
- Richaud, M. C., & Mesurado, B. (2016). Las emociones positivas y la empatía como promotores de las conductas prosociales e inhibidores de las conductas agresivas. *Acción Psicológica*, 13(2), 31-42. <https://doi.org/10.5944/ap.13.2.17808>

- Ruales Jurado, R. E., Lucero Revelo, S. E., & Gómez Rosero, Á. H. (2022). La autorregulación emocional desde una perspectiva educativa. *Fedumar Pedagogía y Educación*, 9(1), 64–73. <https://doi.org/10.31948/rev.fedumar9-1.art-4>
- Sagredo-Lillo, E., Zapata, J., & Salamanca-Garay, I. (2024). Inclusión de estudiantes con altas capacidades en la escuela: centrándose en el aprendizaje de la matemática, la docencia universitaria y el trabajo colaborativo tanto en entornos presenciales como virtuales. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (56), 21-34. <https://doi.org/10.17013/risti.56.21-34>
- Sampieri, undefined H. (2014). *Metodología de la investigación*. 6 (metodologia de la investigacion). <https://www.mendeley.com/catalogue/41b023b1-ca08-3166-a338-3b2d45e3b313/>
- Scherer, K. R. (2000). Psychological Models of Emotion. In *The Neuropsychology of Emotion*.
- Segura Zúñiga, L. (2022). Inteligencia artificial en las organizaciones. *InvestigaTEC*.
- Velázquez-Jurado, H., Niño-Tamayo, D., Castro, C. G., Flores Torres, A., & Briseño González, O. (2019). Identification of emotional schemes and their association with symptoms of anxiety and depression in Mexican adults. *Revista Latinoamericana de Medicina Conductual/Latin American Journal of Behavioral Medicine*, 9(2).
- Vilca, A. (2016). Clima socio familiar y habilidades sociales de los estudiantes de la institución educativa secundaria San Andrés del distrito de Atuncolla - Puno, 2015. *Universidad Nacional Del Altiplano*.
- Zela Payi, N. O., Chambi Condori, N., Ticona Arapa, H. C., & Barrionuevo Valero, J. F. (2022b). Nivel de inteligencia emocional en niños y niñas del II ciclo de instituciones educativas de la zona rural durante la pandemia-Puno 2021. *Horizontes. Revista de Investigación En Ciencias de La Educación*, 6(22), 35–47. <https://doi.org/10.33996/revistahorizontes.v6i22.312>
- Zhou, Z. H. (2012). Ensemble methods: Foundations and algorithms. In *Ensemble Methods: Foundations and Algorithms*. <https://doi.org/10.1201/b12207>