

Assessment of predictive factors for depression in students: performance and generalization of Deep Learning models

Guzmán, Marcela Susana ¹  and Saravia, Noemí Ayelén ¹ 

¹ Facultad de Ingeniería, Universidad Nacional de Jujuy (FI-UNJu), Jujuy, Argentina.
44645907@fi.unju.edu.ar ; 44815288@fi.unju.edu.ar

Abstract. Depression is one of the most significant mental health challenges among university students, affecting academic performance and well-being. This work explores the use of machine learning techniques to predict depression risk using socio-academic, personal, and lifestyle-related variables. The Knowledge Discovery in Databases (KDD) methodology was applied to a public student depression dataset, including data preprocessing, outlier treatment, class balancing through SMOTE, and predictive modeling. Deep Learning and Neural Network models were evaluated using simple validation and cross-validation schemes. The results show that the Deep Learning model achieved the best performance, reaching an accuracy of 83.68% in cross-validation and 82.44% in simple validation. Furthermore, financial stress, academic pressure, and sleep duration were identified as relevant factors associated with depression risk. These findings highlight the potential of machine learning techniques as complementary tools for the early identification of vulnerable student populations.

Keywords: student depression, data mining, Deep Learning, neural networks.

Evaluación de factores predictivos de la depresión estudiantil: rendimiento y generalización de modelos de Deep Learning

Resumen. La depresión constituye uno de los principales desafíos de salud mental en la población universitaria, afectando el rendimiento académico y el bienestar de los estudiantes. Este trabajo explora el uso de técnicas de aprendizaje automático para predecir el riesgo de depresión a partir de variables socioacadémicas, personales y relacionadas con hábitos de vida. Para ello se aplicó la metodología KDD sobre un conjunto de datos público de depresión estudiantil, incorporando etapas de preprocesamiento, tratamiento de valores atípicos, balanceo de clases mediante SMOTE y modelado predictivo. Se evaluaron modelos Deep Learning y Neural Network mediante validación simple y validación cruzada. Los resultados muestran que el modelo Deep Learning obtuvo el mejor desempeño, alcanzando una exactitud del 83,68% en validación cruzada y del 82,44% en validación simple. Además, el estrés financiero, la presión académica y la duración del sueño fueron identificados como factores relevantes asociados al riesgo de depresión. Los hallazgos evidencian el potencial de estas técnicas como herramientas complementarias para la detección temprana de estudiantes en situación de vulnerabilidad.

Palabras clave: depresión estudiantil, aprendizaje automático, Deep Learning, minería de datos, modelos predictivos.

1 Introducción

La depresión constituye uno de los trastornos de salud mental más frecuentes a nivel mundial y representa un desafío creciente para los sistemas de salud y las instituciones educativas (World Health Organization, 2023). Entre la población universitaria, factores como la presión académica, las exigencias económicas, los cambios en los hábitos de vida y las demandas sociales pueden incrementar la vulnerabilidad frente a síntomas depresivos, afectando tanto el rendimiento académico como el bienestar personal.

En los últimos años, el crecimiento de la disponibilidad de datos y el avance de las técnicas de aprendizaje automático han impulsado el desarrollo de herramientas capaces de identificar patrones complejos asociados a diferentes problemáticas de salud. En particular, la minería de datos y los modelos de aprendizaje profundo han demostrado resultados prometedores en tareas de clasificación y predicción dentro del ámbito sanitario, permitiendo analizar grandes volúmenes de información y detectar relaciones que pueden pasar desapercibidas mediante enfoques tradicionales.

La identificación temprana de estudiantes con factores de riesgo asociados a la depresión puede contribuir al diseño de estrategias preventivas y programas de acompañamiento más efectivos. En este contexto, el análisis de variables académicas, personales y socioeconómicas mediante técnicas de aprendizaje automático surge como una alternativa de interés para complementar las acciones de bienestar estudiantil.

La pregunta de investigación que guía este trabajo es: ¿es posible predecir la presencia de depresión en estudiantes universitarios utilizando variables académicas, personales y socioeconómicas mediante técnicas de aprendizaje automático?

Para responder esta pregunta se empleó la metodología Knowledge Discovery in Databases (KDD), ampliamente utilizada en procesos de descubrimiento de conocimiento a partir de grandes volúmenes de datos (Fayyad et al., 1996). El estudio se desarrolló utilizando el conjunto de datos público *Student Depression Dataset*, el cual contiene información relacionada con factores académicos, personales y socioeconómicos asociados a la depresión estudiantil. A partir de las etapas de selección, preprocesamiento, transformación, minería de datos e interpretación de resultados, se desarrollaron modelos de clasificación basados en redes neuronales y se evaluó su capacidad predictiva mediante esquemas de validación simple y validación cruzada.

2 Metodología

2.1 Conjunto de datos

Para el desarrollo de este trabajo se utilizó el conjunto de datos público *Student Depression Dataset* (Student Depression Dataset, 2024), disponible en la plataforma Kaggle. El dataset contiene información relacionada con características demográficas, académicas, personales y socioeconómicas de estudiantes, incluyendo variables como edad, género, presión académica, presión laboral, hábitos de sueño, hábitos alimenticios, historial familiar de enfermedades mentales y nivel de estrés financiero.

La variable objetivo corresponde a la presencia o ausencia de depresión, por lo que el problema fue abordado como una tarea de clasificación supervisada binaria.

2.2 Proceso de descubrimiento de conocimiento

La metodología aplicada se basó en el proceso KDD (Knowledge Discovery in Databases), compuesto por las siguientes etapas:

- Selección de datos.
- Preprocesamiento y limpieza.
- Transformación de atributos.
- Minería de datos.
- Interpretación y evaluación de resultados.

Durante la fase de preprocesamiento se realizó el tratamiento de valores faltantes, la detección de valores atípicos y la normalización de atributos numéricos para mejorar el desempeño de los algoritmos de clasificación.

2.3 Balanceo de clases

Debido al desbalance presente en la variable objetivo, se aplicó una técnica de sobremuestreo sintético (SMOTE) con el objetivo de equilibrar la distribución de clases y evitar sesgos durante el entrenamiento de los modelos.

2.4 Modelado y validación

Para evaluar la capacidad predictiva de los modelos se implementaron dos estrategias de validación:

- Validación simple (Split Data): división del conjunto de datos en un 70% para entrenamiento y un 30% para prueba.
- Validación cruzada (Cross Validation): utilizada para obtener una estimación más robusta del rendimiento y reducir el riesgo de sobreajuste.

Se comparó el desempeño de modelos basados en redes neuronales, específicamente Deep Learning y Neural Network, utilizando como métrica principal la exactitud (Accuracy).

2.5 Evaluación del desempeño

El rendimiento de los modelos fue evaluado mediante el operador Performance (Classification) de RapidMiner. Los resultados obtenidos en ambos esquemas de validación fueron posteriormente comparados con el fin de determinar la capacidad de generalización de cada modelo y seleccionar la alternativa con mejor desempeño.

3 Resultados y Discusión

Los modelos desarrollados fueron evaluados mediante dos esquemas de validación: validación simple y validación cruzada. El objetivo de esta comparación fue analizar la capacidad de generalización de las arquitecturas de redes neuronales implementadas y determinar cuál de ellas presenta un mejor desempeño para la predicción de depresión estudiantil.

Table 1. Comparación del rendimiento de los métodos aplicados.

Modelo	Validación Cruzada (Accuracy)	Validación Simple
Deep Learning	83,68%	82,44%
Neural Network (MLP)	81,63%	80,00%

Los resultados muestran que el modelo Deep Learning alcanzó el mejor desempeño en ambos esquemas de validación. En particular, obtuvo una exactitud del 83,68% mediante validación cruzada y del 82,44% mediante validación simple. La diferencia reducida entre ambas evaluaciones sugiere una adecuada capacidad de generalización y una baja sensibilidad frente a variaciones en los datos de entrenamiento y prueba.

Por su parte, el modelo Neural Network presentó resultados inferiores, alcanzando una exactitud del 81,63% en validación cruzada y del 80,00% en validación simple. Si bien estos valores reflejan un desempeño aceptable, se observa una menor capacidad predictiva respecto al modelo Deep Learning.

Los resultados obtenidos sugieren que variables como el estrés financiero, la presión académica y la duración del sueño presentan una asociación relevante con el riesgo de depresión dentro de la población estudiada.

En conjunto, los hallazgos obtenidos sugieren que las técnicas de aprendizaje profundo pueden constituir herramientas de apoyo valiosas para la detección temprana de estudiantes potencialmente vulnerables. No obstante, los resultados deben interpretarse como asociaciones estadísticas derivadas de los datos analizados y no como relaciones causales o diagnósticos clínicos.

4 Limitaciones del Estudio

Si bien los resultados obtenidos evidencian el potencial de las técnicas de aprendizaje automático para la identificación de patrones asociados a la depresión estudiantil, este trabajo presenta algunas limitaciones que deben considerarse al interpretar los hallazgos.

En primer lugar, el estudio se basa en un conjunto de datos público obtenido de Kaggle, cuya metodología de recolección y representatividad de la muestra se encuentran fuera del control de los autores. Por lo tanto, pueden existir sesgos inherentes a los datos que afecten la capacidad de generalización de los modelos desarrollados.

Asimismo, las variables analizadas corresponden a factores académicos, personales y socioeconómicos reportados dentro del conjunto de datos, por lo que no contemplan la totalidad de los elementos psicológicos, clínicos o contextuales que pueden influir en la aparición de síntomas depresivos.

Otra limitación importante es que los modelos desarrollados identifican patrones estadísticos asociados a la variable objetivo, pero no permiten establecer relaciones causales entre los factores analizados y la depresión. En consecuencia, los resultados no deben interpretarse como diagnósticos clínicos ni sustituir la evaluación realizada por profesionales de la salud mental.

Finalmente, la validación del modelo fue realizada exclusivamente sobre el conjunto de datos utilizado en la investigación. Como trabajo futuro, sería deseable evaluar el

desempeño de los modelos utilizando datos provenientes de instituciones educativas reales y poblaciones estudiantiles de diferentes contextos geográficos y socioculturales.

5 Conclusiones

En este trabajo se aplicó la metodología KDD para el análisis de factores asociados a la depresión estudiantil mediante técnicas de aprendizaje automático. A partir de un conjunto de datos público y utilizando procesos de preprocesamiento, balanceo de clases y modelado predictivo, fue posible desarrollar modelos capaces de identificar patrones relacionados con el riesgo de depresión.

Los resultados obtenidos muestran que el modelo Deep Learning presentó el mejor desempeño, alcanzando una exactitud del 83,68% en validación cruzada y del 82,44% en validación simple. Estos valores evidencian una adecuada capacidad de generalización y sugieren que las redes neuronales profundas constituyen una alternativa prometedora para tareas de clasificación vinculadas al análisis de salud mental.

Asimismo, el estudio permitió identificar que factores como el estrés financiero, la presión académica y la duración del sueño presentan una relevancia significativa dentro del proceso de predicción, reforzando la importancia de estos aspectos en el bienestar estudiantil.

Los hallazgos obtenidos respaldan el potencial de las técnicas de aprendizaje automático como herramientas complementarias para la detección temprana de estudiantes en situación de vulnerabilidad. Como líneas futuras de investigación se propone incorporar métricas adicionales de evaluación, explorar técnicas avanzadas de interpretabilidad de modelos y comparar el desempeño de otras técnicas de clasificación con el objetivo de fortalecer la robustez y aplicabilidad de los resultados obtenidos.

Declaración de uso de Inteligencia Artificial

Durante la preparación de este trabajo, los autores utilizaron NotebookLM con el fin de mejorar el lenguaje y la legibilidad del manuscrito. Tras utilizar esta herramienta, los autores revisaron y editaron el contenido según fuera necesario y asumen plena responsabilidad por el contenido de la publicación

Referencias

- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI Magazine*, 17(3), 37–54.
<https://www.kdnuggets.com/gpspubs/aimag-kdd-overview-1996-Fayyad.pdf>
- Hotz, N. (2024). KDD and Data Mining. Data Science PM. <https://www.datascience-pm.com/kdd-and-data-mining/>
- Student Depression Dataset. (2024). Kaggle. <https://www.kaggle.com/datasets/hopesb/student-depression-dataset>
- World Health Organization. (2023). Depression. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/depression>