



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO**

CARRERA DE COMPUTACIÓN

**ESTUDIO DEL ESTADO DEL ARTE SOBRE LA
PREDICCIÓN DE DESERCIÓN UNIVERSITARIA
USANDO MACHINE LEARNING**

Trabajo de titulación previo a la obtención del
Título de Ingeniero en Ciencias de la Computación

AUTOR: YUNGA PEDRAZA JOEL OMAR

TUTOR: JULIO RICARDO PROAÑO ORELLANA

Quito, Ecuador
2023

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Yo, Joel Omar Yunga Pedraza con documento de identificación N° 1722540703 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 28 de febrero del 2023

Atentamente,

A handwritten signature in blue ink that reads "joel yunga". The signature is written in a cursive style and is enclosed within a rectangular box formed by two horizontal lines and a vertical line on the left side.

.....
Joel Omar Yunga Pedraza
1722540703

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Joel Omar Yunga Pedraza, con documento de identificación N° 1722540703, expresé mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo Académico: “Estudio del Estado del Arte sobre la Predicción de Deserción Universitaria Usando Machine Learning.”, el cual ha sido desarrollado para optar por el título de Ingeniero en Ciencias de la Computación, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 28 de febrero del 2023

Atentamente,



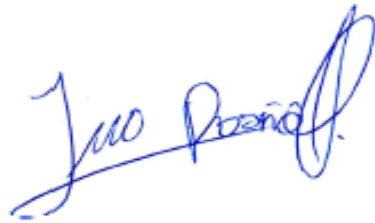
.....
Joel Omar Yunga Pedraza
1722540703

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Julio Ricador Proaño Orellana con documento de identificación N° 0103909412, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ESTUDIO DEL ESTADO DEL ARTE SOBRE LA PREDICCIÓN DE DESERCIÓN UNIVERSITARIA USANDO MACHINE LEARNING, realizado por Joel Omar Yunga Pedraza con documento de identificación N° 1722540703, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 28 de febrero del 2023

Atentamente,



Ing. Julio Ricardo Proaño Orellana, PhD
0103909412

DEDICATORIA

Dedico el presente proyecto principalmente a mi padres Magdalena y Fernando por el apoyo incondicional, en este trayecto de mi vida, por ser mi soporte y fortaleza, enseñarme que todo lo que me proponga lo puedo lograr. Así mismo dedico a mis hermanos Cristian y David , por brindarme ese apoyo moral, ser mi ejemplo y hacerme comprender que con esfuerzo todo se alcanza en la vida.

También quiero dedicar con mucho cariño a mi hijo Aaron, por que gracias a él tuve un incentivo en mi vida, y con esto servir de ejemplo para él, cada día pienso en ser su motivación de vida para convertirlo en una persona de bien y un profesional en el futuro.

A mis amigos cercanos que siempre confiaron en mi, con los que he culminado una etapa más en mi vida, con quienes compartí momentos muy gratos que me llevare conmigo siempre, así como también su apoyo incondicional.

AGRADECIMIENTO

En primera instancia agradezco a Dios por haberme brindado la vida y la salud durante todo este proceso formativo y académico, quien siempre ha caminado a mi lado en cada momento dandome fuerza para ponerme de pie y afrontar los obstáculos que se han presentado en el camino.

Agradezco de manera especial a la Universidad Politécnica Salesiana por haberme formado en la carrera de Ingeniería en Ciencias de la Computación y a todos los docentes que han sido parte de mi formación académica y así adquirir cualidades como honestidad, responsabilidad, esfuerzo y dedicación para así ponerlas en práctica en la vida profesional superando las diferentes adversidades encontradas a lo largo del camino.

A mi tutor, Ing. Julio Proaño, por ser un buen docente al compartir sus conocimientos, brindando su apoyo, experiencia y amistad, además de agradecerle por depositar su confianza en mi y ayudarme en la finalización de la investigación con éxito.

Estudio del Estado del Arte sobre la Predicción de Deserción Universitaria usando Machine Learning

1st Joel Yunga Pedraza
jyungap1@est.ups.edu.ec

2nd Julio Proaño Orellana
jproanoo@ups.edu.ec

Resumen—La deserción universitaria trae como principal consecuencia el aumento del número de estudiantes con educación superior incompleta. Por lo cual se ha implementado técnicas predictivas que han ayudado a detectar patrones que sirven para el estudio del tema. Existen varias técnicas utilizadas para el análisis predictivo como: La Regresión Logística, El Análisis Bayesiano, Árboles de Decisión, entre otras, que han logrado ser de suma importancia al momento de arrojar resultados favorables que ayuden a llevar un control estadístico sobre los casos de estudiantes desertores. Es importante señalar que el uso de técnicas predictivas como la minería de datos en donde se pueda visualizar las razones por las que los estudiantes desertan según los patrones expresados estadísticamente para que las autoridades institucionales puedan tomar decisiones basándose en esta información y disminuir la deserción de los estudiantes universitarios. Este artículo recopila información sobre los diferentes algoritmos de predicción utilizados en el tema de la deserción universitaria y analiza los datos sobre técnicas, algoritmos, datasets, usados para la predicción de la deserción universitaria, con el objetivo de encontrar la técnica de mejor rendimiento al momento de realizar el estudio mediante métricas de evaluación como son el Accuracy, Recall y F-Score.

Abstract—The main consequence of university desertion is the increase in the number of students with incomplete higher education. Therefore, predictive techniques have been implemented that have helped to detect patterns that are useful for the study of the subject. There are several techniques used for predictive analysis such as: Logistic Regression, Bayesian Analysis, Decision Trees, among others, which have become extremely important when it comes to yielding favorable results that help to keep statistical control over student cases. deserters. It is important to point out that the use of predictive techniques such as data mining where it can be visualized the reasons why students drop out according to patterns expressed statistically so that institutional authorities can make decisions based on this information and reduce the dropout rate of university students. This article collects information on the different prediction algorithms used in the subject of university dropout and analyzes the data on techniques, algorithms, datasets, used for the prediction of university dropout, with the aim of finding the technique with the best performance at the moment. to carry out the study on university desertion through evaluation metrics such as Accuracy, Recall and F-Score.

I. INTRODUCCIÓN

La deserción universitaria trae como principal consecuencia el aumento del número de estudiantes con educación superior incompleta. Por lo cual, se ha implementado técnicas predictivas que han ayudado a detectar patrones que sirven para el estudio del tema. Existen varias técnicas utilizadas para el análisis predictivo como: la Regresión Logística, el Análisis Bayesiano, Árboles de Decisión, entre otras,

que han logrado ser de suma importancia al momento de arrojar resultados favorables que ayuden a llevar un control estadístico sobre los casos de estudiantes desertores. [28]

A nivel mundial existen países entre los cuales se puede destacar los siguientes: Canadá, México, Colombia, Estados Unidos y Japón en donde se presentan la mayor cantidad de estudiantes que optan por el camino de la deserción. En los últimos 5 años se ha presentado un incremento del 55.40% de desertores universitarios según las cifras que ha dado a conocer la Organización de las Naciones Unidas [26]. Por la pandemia 1.600 millones de alumnos en más de 190 países en todos los continentes han decidido tomar el camino de la deserción para abandonar sus estudios e intentar buscar otros medios para genera dinero y así poder ser ayuda para sus familias [5]. En América Latina el problema de la deserción universitaria ha aumentado un 25.45% según estudios realizados por la Unesco entre los años 2015 y 2020 que indica que en este continente se pierda hasta \$420 millones por el tema de la deserción universitaria debido a que la mayoría de las universidades presentan un gran número de estudiantes desertores siendo la causa la problemática económica y social de los países como por ejemplo Bolivia, Perú y Ecuador [30]. En Ecuador existe una gran cantidad de universidades que han presentado los mismos problemas, durante el rango de los años 2020 y 2021, el 45.5% de estudiantes que fueron inscritos, al pasar un determinado tiempo optaron por la de deserción universitaria. [24] En territorio ecuatoriano específicamente en la región Sierra como en la Universidad Técnica de Ambato en el que se presenta el fenómeno de deserción universitaria según la Senescyt, siendo la causa el aumento de un 20% en los casos de estudiantes desertores durante los años 2019 y 2020, por lo cual las autoridades han optado por determinar los indicadores que presentan los alumnos para atacar el problema buscando soluciones que favorezcan a la comunidad educativa [13].

Segun [27], las principales causas que están dando paso a este problema son: i) Los estudiantes encuentran la oportunidad de trabajar al comienzo de su carrera, tienden a pasar más tiempo trabajando y no cuentan con el tiempo necesaria para sus actividades académicas. ii) Falta de apoyo a los estudiantes (bienestar estudiantil, becas, subsidios, etc.), los estudiantes presentan crisis económica en su círculo familiar lo cual es otra razón por la que los estudiantes eligen desertar de sus carreras universitarias. iii) Las dificultades que tienen que enfrentar los estudiantes para cumplir con los requisitos

académicos de la universidad, tales como la dosificación de programas académicos, la secuencia de asignaturas, el nivel de dificultad de las materias, la falta de preparación de los docentes, etc. iv) El cumplimiento de prerrequisitos, requisitos, créditos máximos y mínimos, exámenes frecuentes, porcentajes acumulativos, entre otras, este es el fenómeno que intimida a muchos estudiantes que encuentran la vida universitaria una carga insostenible. v) Los estudiantes tienen que aprender ciertas materias del curso que no son relevantes para su carrera ni son de su interés, por esta razón se desmotivan causando el abandono de sus estudios.

Es importante señalar que el uso de técnicas predictivas como la minería de datos en donde se pueda visualizar las razones por las que los estudiantes desierten según los patrones expresados estadísticamente para que las autoridades institucionales puedan tomar decisiones basándose en esta información y disminuir la deserción de los estudiantes universitarios. Este artículo recopila información sobre los diferentes algoritmos de predicción utilizados en el tema de la deserción universitaria y analiza los datos sobre técnicas, algoritmos, datasets, usados para la predicción de la deserción universitaria.

II. METODOLOGÍA

Para la realización del artículo, los pasos que se siguieron fueron: (1) Encontrar documentos relevantes, (2) Seleccionar y filtrar los documentos, (3) Resumir y Analizar los documentos.

Para la etapa de encontrar documentos relevantes se escogieron tres bases de datos como: IEEE Xplore, Scopus y Web of Science, en los mismos se priorizó la búsqueda principalmente de artículos en revistas.

En la segunda etapa se procedió a seleccionar palabras claves como: "Dropout", "Machine Learning", "Datasets", para formar la siguiente cadena de búsqueda: "Dropout AND Machine Learning AND Datasets OR Algorithms AND Prediction AND Results", la cual ayudó a filtrar y obtener mejores resultados en la investigación, de la misma manera se delimitó los años de publicación de los artículos con un intervalo entre 2016 hasta el 2022 con el fin de encontrar la mayor cantidad de información actual, con éste resultado se obtuvo un total de 60 artículos recopilados de las tres bases de datos.

Una vez localizados los documentos se procedió a aplicar criterios de inclusión y exclusión, para eliminar los artículos que no son relevantes para la investigación. Esta depuración se realizó de acuerdo a los siguientes criterios:

- En primer lugar, solo se consideraron estudios empíricos
- En segundo lugar, solo se consideró la investigación centrada en la deserción universitaria. Sin embargo también se incluyeron estudios que se enfocaban en programas de formación profesional.

Después de aplicar estos filtros se realizó un análisis de cada uno de los artículos tomando en cuenta el resumen y la introducción, los cuales permiten tener una idea clara del contenido del artículo, esto sirvió para clasificarlos en dos grupos: Relevantes y No Relevantes. Para ser Relevante el contenido del artículo debe contener similitud con el tema de investigación o incluir datos importantes que aporten al estudio, caso contrario si el artículo se desvía del tema central se clasifica como No Relevante; este procedimiento nos reflejó 28 artículos Relevantes y 32 No Relevantes.

Tomando en cuenta los 28 artículos se destaca lo siguiente en términos de distribución:

- Artículos por País [Figura 1]
- Artículos por Año [Figura 2]
- Artículos por Categoría [Figura 3]
- Artículos por Campo Profesional [Figura 4]
- Artículos por Nombre de Journal [Figura 5]




Figura 1. Artículos por país.




Figura 2. Artículos por Año.

Para la última etapa se continuó con el análisis de cada uno de los artículos relevantes, en base a las ideas principales se elaboró los resúmenes correspondientes para obtener información concreta que ayude a entender el contenido




Figura 3. Artículos por Categoría.




Figura 4. Artículos por Campo Profesional.

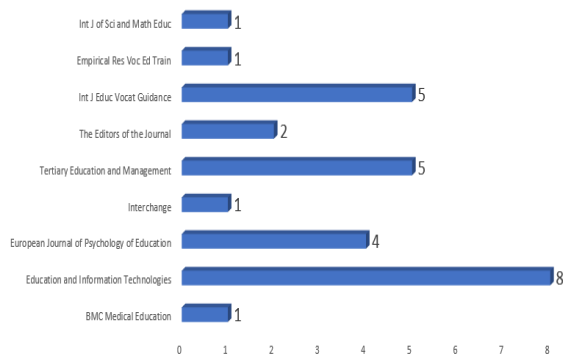


Figura 5. Artículos por Nombre de Journal.

de cada uno de estos. Luego se procedió a identificar los resúmenes con un número, el mismo que sirve para la realización de una clasificación, la cual permitió agrupar los artículos que contienen similitudes dentro de su contenido, teniendo así una mejor visión gráfica de la relación que existe entre los mismos.

III. RESULTADOS

Para la investigación se encontraron resultado(s) o medida(s) destinadas a abordar el tema de investigación. Para el análisis de los resultados se han agrupado los artículos por técnica de Machine Learning, con el fin de examinar y comparar los modelos de Aprendizaje Automático de manera más profunda y así obtener resultados favorables que nos ayude a encontrar la mejor técnica de predicción

en los estudios sobre el tema de la deserción universitaria. A continuación se detallara cada uno de los resultados por técnica usada:

1. Redes Neuronales

En el Artículo [18], se ha realizado el experimento utilizando el conjunto de datos público proporcionado por KDD Cup, los cuales contienen información de 39 cursos de la plataforma MOOC dentro de un período de tiempo. Para facilitar la verificación y las pruebas se adoptó la definición del problema de KDD Cup la cual indica que: "Si un estudiante no tiene registro de la actividad del curso dentro de los próximos 10 días, entonces se considera que abandonó el curso". En este experimento se utilizaron métricas de evaluación como: precisión recall, F1 score y el Área bajo la curva (ROC); se pudo comprobar que la proporción de "deserción" en el conjunto de datos es mucho mayor que la de "no deserción". Por lo tanto, este experimento es para resolver un problema de clasificación binaria con datos no balanceados.

Para verificar la efectividad del modelo propuesto se eligió siete modelos principales en investigaciones de minería de datos educativos como métodos de referencia, los cuales fueron: (1) Regresión Logística, (2) Naive Bayes, (3) Árbol de Decisión, (4) AdaBoost, (5) Impulso del árbol de degradado, (6) Bosque Aleatorio, (7) Máquina de vectores de soporte.

En el algoritmo se alimentó el conjunto de datos de registro DP-CNN para su procesamiento. Finalmente, se obtienen dos conjuntos de datos diferentes y luego, estos conjuntos de datos se envían a la etapa de convolución para la extracción y predicción de características. La primera capa de la etapa de convolución de DP-CNN usa 32 filtros y sesgos, y la segunda capa usa 64 filtros y sesgos. El tamaño de estos filtros es de 3x3, el paso se establece en 1, y cuando se realiza el cálculo de convolución, los límites se rellenan con "0". Luego, la primera capa genera 32 mapas de características del mismo tamaño que la entrada y la segunda capa genera 64 mapas de características del mismo tamaño que la entrada. La tercera capa tiene 128 neuronas, y algunas neuronas se eliminan aleatoriamente con una probabilidad del 50% cuando se entrena para evitar el sobreajuste. La cuarta capa genera el resultado de la predicción, y dado que el problema final a resolver es el problema de clasificación binaria, el número de neuronas en esta capa se establece en "2". Aquí, se denotó "1" como "abandono" y "0" como "no abandono".

En el proceso de entrenamiento, se utiliza el algoritmo de optimización de descenso de gradiente estocástico de mini lotes para el aprendizaje de parámetros y la tasa de aprendizaje se establece en 0,001, el tamaño del lote

se establece en 256 y el número de iteraciones es 20 000. Para la comparación experimental, se extrajeron 78 características de los registros sin procesar a través de la ingeniería de características. Estas características incluyen principalmente tres aspectos: (1) varias estadísticas de tiempo de aprendizaje; (2) varias estadísticas de diferentes eventos; y (3) estadísticas de categorías de objetos de operación. Todas las funciones se normalizan mediante una escala mínima-máxima para convertir el rango de funciones al rango de 0 a 1. Estas funciones se utilizarán para el entrenamiento y la predicción de los métodos de referencia anteriores. Para entrenar y probar estos modelos, se dividieron aleatoriamente cada conjunto de datos en un conjunto de entrenamiento y un conjunto de prueba en una proporción de 3:1. Finalmente, se realiza la implementación y comparación de varios modelos sobre Sklearn y Tensorflow. La comparación de DP-CNN con otros algoritmos de referencia no conduce a una conclusión intuitiva. Para describir con precisión las diferencias entre DP-CNN y los algoritmos de línea base, utilizaron la prueba de Friedman para analizar los resultados experimentales y para detectar si existen diferencias significativas entre los algoritmos.

En el artículo [3], se utilizó un conjunto de datos que contiene 33 características clasificadas en numéricas (17 características) y categóricas (16 características). Utilizaron una codificación en caliente para normalizar los datos. La normalización se realizó para cambiar los datos categóricos a numéricos, ya que todos los valores se colocaron dentro del rango 0-1 después de la normalización. Esto también aumentó el número de funciones a 59 funciones. Luego, el número de características debe reducirse para evitar la dimensionalidad y el desequilibrio de clases. En este estudio se resalta la utilización de varias técnicas de minería de datos para predecir el rendimiento académico de los estudiantes, dichas técnicas son: Máquina de Vectores de Soporte, Perceptrón Multicapa, Análisis de componentes principales, Redes Neuronales, Árbol de decisiones, KNN. Los estudios empíricos indicaron que el SVM logró resultados ligeramente mejores con un coeficiente de correlación de 0,96, mientras que el K-NN logró un coeficiente de correlación de 0,95. Usando regresión lineal y análisis de componentes principales (PCA), se hizo una predicción del rendimiento de los estudiantes y se descubrió que el rendimiento de la predicción de la regresión multilínea (MLR) con análisis de componentes principales (PCA) era mayor que el de la MLR sin PCA.

Al mostrar el potencial de la red neuronal artificial para predecir el rendimiento de los estudiantes se presentó un modelo de red neuronal artificial para predecir el desempeño de los estudiantes en la Facultad de Ingeniería y Tecnologías de la Información. El modelo

usó un algoritmo de propagación retroalimentada para el entrenamiento. Los factores para el modelo se obtuvieron de los registros de la matrícula de los estudiantes. El modelo fue probado y el resultado global fue del 84,6 %. Para la medida del Recall, los resultados son del 93,1 % esto significa que 605 de 650 estudiantes están correctamente clasificados del número total de casos no clasificados y correctamente clasificados y 45 estudiantes no fueron clasificados correctamente. Para la medida de precisión, los resultados son del 91,7 % esto significa que 596 de 650 estudiantes están clasificados correctamente y 54 estudiantes están clasificados incorrectamente. Para la Medida F, los resultados son 91.4 %, lo que significa que 594 de 650 estudiantes están clasificados correctamente y 56 estudiantes no están clasificados correctamente.

En el artículo [6], tiene como objetivo predecir la deserción del alumno en el proceso de aprendizaje del curso, para lo cual se diseñó un modelo para clasificar y predecir el compartamiento del alumno; su interacción en el proceso de aprendizaje, incluidas las actividades del curso y recursos. Mientras se entrena el modelo, inicialmente se juega con (1) número de épocas, (2) tipo de RNN, (3) número de capas ocultas, (4) tasa de aprendizaje y (5) parámetro de regularización. La precisión es la métrica de evaluación del modelo más adecuada para trabajar, ver el tipo binario de salidas y el conjunto de datos. Por lo tanto, se eligió la precisión como la métrica para evaluar el modelo. Durante el entrenamiento se mantuvo constantes los parámetros relacionados con el optimizador de Adams. Experimentaron el modelo con muchos conjuntos de hiperparámetros con las tres arquitecturas RNN (RNN simples, GRU y LSTM) antes de concluir que los RNN simples funcionan mejor ofreciendo la mejor precisión (rendimiento y exactitud) para clasificar y predecir el comportamiento de los estudiantes y los que están en riesgo de desertar durante el proceso de aprendizaje. El principal desafío de este estudio fue la naturaleza desequilibrada del conjunto de datos en MOOC utilizado para esta primera experimentación. Además, el comportamiento del alumno o la interacción con un contenido dado no es fácil y profundamente medible, por lo cual en investigaciones futuras recomiendan desarrollar un método para medir la calidad de los comportamientos de los alumnos y también probar el modelo en otros MOOC, para así poder mejorar aún más el rendimiento del modelo de predicción.

2. Regresión Logística

En el artículo [25], se extrajo un subconjunto de la base de datos disponible públicamente de la Encuesta de Jóvenes en Egipto (SYPE), para este estudio algunas variables de la base de datos se extraen tal cual, mientras

que otras se componen en función de algunos de los atributos preexistentes. Se utilizaron principalmente datos limpios con el fin de mejorar la eficiencia del análisis de datos, en consecuencia, el conjunto de datos viable consta de 3154 registros o instancias, cada uno de ellos tiene un valor de respuesta sobre la deserción escolar, pero el conjunto de datos tiene un problema de desequilibrio de clases. El trabajo experimental de este estudio está diseñado para examinar el rendimiento del clasificador logístico antes y después de aplicar técnicas de remuestreo, entrenando el modelo con el 80 % de los datos y las pruebas con en el 20 % para evitar la fuga de datos.

Como el trabajo empírico de este estudio es extenso, se ha optado por dividirlo en secciones, las cuáles son: (1) Desempeño del clasificador logístico previo al remuestreo de datos, (2) Analizar el rendimiento después del remuestreo de datos, (3) Examinar el rendimiento de un clasificador logístico cuando se utilizan técnicas híbridas, finalmente, (4) Modelo Final. Para la primera sección antes de utilizar cualquiera de las técnicas de remuestreo, los puntajes promedio de la validación cruzada de diez veces del clasificador logístico muestran que el AUC es 0,77, que se considera satisfactorio en comparación con el desempeño de las clasificaciones sociales en general. La puntuación F es 0,27 y el error de tipo II es 0,82. Por otro lado, el rendimiento del modelo en datos no vistos es ligeramente peor con un AUC de 0,77, una puntuación F de 0,19 y un error de tipo II de 0,89. Claramente, estos resultados reflejan un rendimiento deficiente del modelo logístico cuando se trata de la clasificación del conjunto de datos de deserción escolar bajo este escenario básico.

En la segunda sección las técnicas de submuestreo consideradas, tanto las puntuaciones de validación como las de prueba muestran que el modelo logístico tiene casi los mismos valores de AUC, con la excepción de las versiones de NearMiss, Moreover, NearMiss-2 que son las técnicas que produce el error Tipo II más bajo seguido de RUSS. Por último, pero no menos importante, ENN se desempeña mejor en términos de puntaje F seguido NearMiss-3 en caso de evaluación de validación y RUSS en caso de evaluación con conjunto de datos de prueba.

La siguiente sección muestra que la combinación de técnicas de submuestreo y sobremuestreo mejora los resultados generales, especialmente en términos de error de tipo II y puntuación F. Para las puntuaciones de validación cruzada, el error de tipo II cae en promedio de 0,82 a 0,11, y la puntuación F aumenta en promedio de 0,27 a 0,47 en comparación con el rendimiento del clasificador logístico que usa el conjunto de datos original con desequilibrio de clase. Además, el rendimiento con las instancias no vistas también mejora, ya que el error de tipo II disminuye de

0,89 a 0,10 y la puntuación F aumenta de 0,19 a 0,52. la combinación de las ROS con NearMiss-3 se cree que es relativamente el mejor para ajustar el modelo logístico final en el conjunto de datos, esto se debe a que produce el error Tipo II más bajo en los procesos de validación y ocupa el segundo lugar en la evaluación de pruebas. Además, es una de las combinaciones que produce valores elevados tanto de AUC como de F-score en ambas fases de evaluación.

Finalmente para la sección del modelo final, se muestra que las puntuaciones de entrenamiento y validación cruzada convergen juntas a medida que se agregan más datos, por lo tanto, el modelo probablemente no se beneficiará al agregar más conjuntos de datos de entrenamiento. Basado en los valores absolutos de los coeficientes del modelo Logístico se puede decir que se muestra que la crónica estudiantil, el desempeño educativo representan las cinco características más importantes que afectan el problema de la deserción escolar en Egipto.

En el artículo [17], se planteó utilizar el conjunto de datos de estudiantes de secundaria que estudian en Turquía. Para que el conjunto de datos esté listo para el análisis, primero debe pasar por el proceso de preprocesamiento de datos. Por lo tanto, los datos sin procesar se transformarán en datos más significativos para usar en el modelo. Es necesario identificar datos faltantes, inconsistentes, atípicos e incorrectos en el conjunto de datos. De la misma manera se utilizaron los algoritmos de aprendizaje automático supervisado Random Forest, K-NN, Árbol de Decisión, SVM, Naive Bayes, Regresión Logística y AdaBoost para obtener los primeros resultados del modelo. En el método propuesto, se utilizó la técnica Stratified K-Fold Cross Validation para los modelos. Para observar el efecto de utilizar el método de validación cruzada, los resultados de rendimiento de los modelos se obtuvieron utilizando la validación cruzada estratificada de 10 veces. La razón para utilizar el método de validación cruzada de 10 pliegues estratificado es evitar desviaciones y errores al separar el conjunto de datos en conjuntos de datos de prueba y tren. Una comparación de las puntuaciones de rendimiento de parámetros. El modelo con mayor rendimiento antes de la optimización de parámetros es AdaBoost con una precisión del 93,2% y también se informó que el algoritmo Random Forest, que es uno de los métodos populares utilizados para predecir el rendimiento de los estudiantes, tiene una precisión inicial del 79% y se obtuvo un valor de precisión del 91% en el paso final. Para concluir en primer lugar, los resultados de rendimiento se obtuvieron cuando los modelos se evaluaron individualmente. De acuerdo con los resultados obtenidos, el uso del método Stratified K-Fold Cross Validation tuvo un efecto positivo en el desempeño de los modelos. También se

observa que realizar la optimización de hiperparámetros aumenta el rendimiento de los modelos. Por lo tanto, se puede decir que el uso de cv estratificado de 10 veces y la optimización de hiperparámetros mejora el rendimiento de los modelos de aprendizaje automático. De acuerdo a los resultados de los modelos evaluados individualmente, el modelo con mejor valor de precisión de 94.4 % es Regresión Logística. Se creó un modelo híbrido de acuerdo con el método propuesto. El modelo híbrido se creó con el método de apilamiento y se probaron diferentes algoritmos supervisados para poder predecir los desortes.

En el artículo [12], se evaluaron tres clasificadores que son perceptrón multicapa (MLP), Random Forest (RF) y regresión logística (LR) en un conjunto de datos de clasificación supervisada para ver qué clasificadores funcionarán mejor, el modelo de Machine Learning desarrollado en este estudio ayudará a las partes interesadas en la educación a predecir e identificar fácilmente a los estudiantes que corren el riesgo de abandonar la escuela para una intervención temprana. Sobre la base de los experimentos realizados, se puede concluir que Student Gender mostró la mayor contribución a la predicción de abandono escolar que otras características y la técnica de Regresión Lineal logró el mayor rendimiento predictivo. El estudio recomienda la optimización de hiperparámetros como parte del trabajo futuro para mejorar el poder predictivo.

3. Máquina de Soporte de Vectores

En el artículo [20], los datos se recopilaron de una variedad de fuentes, incluidos LMS (Sistema de Gestión de Aprendizaje), datos demográficos, preacadémicos, interacción de bibliotecas y calificaciones de evaluación. La revisión revela una amplia gama de algoritmos de aprendizaje automático que se utilizan para el análisis predictivo. Estos algoritmos difieren en varios aspectos, como sus sesgos y suposiciones inherentes, su capacidad para generalizar más allá de los datos de entrenamiento y la cantidad de datos necesarios, para entrenar los modelos. Una vez que se crean los modelos predictivos, es crucial evaluar su capacidad de generalización en nuevos datos (de prueba). Se puede usar una variedad de medidas para esta tarea, y es una buena práctica evaluar los modelos usando un conjunto de métricas de evaluación. Las métricas comunes son la precisión, la medida F, el error absoluto medio (MAE), Recall, las tasas de falsos positivos (FP) y falsos negativos (FN), y las curvas de características operativas del receptor (ROC).

La representación gráfica de datos es una consideración clave en los tableros, ya que el propósito principal de la visualización de datos es la comunicación efectiva. Cuando se diseñan correctamente, las visualizaciones

de datos pueden brindar apoyo al lector que lo necesite. Los hallazgos encontrados en el estudio revelan que los enfoques de evaluación para medir la efectividad del tablero se siguieron con un rigor variable entre los documentos revisados.

4. Random Forest

En el artículo [7], el uso de poblaciones experimentales pequeñas y altamente divididas en subconjuntos en trabajos anteriores es una forma en la que su capacidad de generalización es limitada. A menudo, los experimentos predictivos en los MOOC identifican una subpoblación de estudiantes sobre la que se realiza el análisis. Una segunda área donde existen brechas sustanciales en la investigación es la evaluación, comparación y replicación de los modelos predictivos del éxito de los estudiantes en los MOOC. A medida que el trabajo sobre modelado predictivo se ha expandido en todos los dominios, ha surgido una base de investigación sustancial sobre técnicas para comparar y evaluar los resultados de los experimentos de modelado predictivo. Esto también plantea preocupaciones sobre la precisión, dimensión de estos modelos, particularmente cuando se aplica a datos no vistos, para comparar y sacar inferencias sobre el desempeño de los modelos predictivos, se utilizó el rendimiento promedio de validación cruzada para evaluar y comparar el rendimiento de 31 estudios, o casi el 40 % del trabajo encuestado. Nuevamente, los problemas con este procedimiento han sido bien estudiados. Utilizando el rendimiento promedio con validación cruzada con pruebas estadísticas no ajustadas (como una prueba) hace que dicha investigación sea susceptible tanto a altas tasas de error Tipo I (probabilidad más alta que la esperada de concluir que hay una diferencia significativa en el desempeño cuando no existe) como a un bajo poder (baja capacidad para discernir verdaderas diferencias en el desempeño cuando existen).

Los avances duales en la interpretabilidad y en el ajuste del modelo, no eximen a los investigadores de considerar cuidadosamente las implicaciones éticas de los modelos de estudiantes. Por el contrario, a medida que mejoren los modelos predictivos del éxito de los estudiantes y se generalice su uso, crecerán las implicaciones éticas del uso de estos modelos y la responsabilidad de quienes los construyan.

En el artículo [2], se presenta los resultados obtenidos al usar los seis algoritmos que son: Regresión Logística, Random Forest, KNN, Naive Bayes, Máquina de vectores de soporte, Redes Neuronales. Para evaluar el rendimiento al tener un conjunto de datos pequeño, usaron una validación cruzada de diez veces (cada vez, nueve de los pliegues se usan para el entrenamiento y un pliegue se usa para probar el modelo, y el método

de retención se repite diez veces). Para las predicciones realizadas después del primer semestre de estudio, se ha seleccionado (1) Sexo, (2) Inscripción_edad, (3) Cultura, (4) Distancia, (5) Grado_sem1, (6) F_sem1, (7) Exámenes_no registrados1 y (8) Exámenes registrados_1 como predictores. Para realizar las predicciones después del segundo bimestre, en cambio se ha seleccionado, (1) Sexo, (2) Matrícula_edad, (3) Cultura, (4) Distancia, (5) grado_sem1, (6) grado_sem2, (7) F_semestre1, (8) F_semestre2, (9) Exámenes_no registrados1, (10) Exámenes_no registrados2, (11) Exámenes_registrados1 y (12) Exámenes_registrados2 como predictores.

Se puede decir que todos los algoritmos generalmente proporcionaron una buena precisión. Sin embargo, y como era de esperar, la precisión siempre es mejor cuando se realiza la predicción después del segundo semestre. También se puede notar que los modelos predicen mejor a los estudiantes “completos” (que representan la clase mayoritaria). Por ejemplo, en el caso de la Regresión Logística, la precisión, el recall y la puntuación F1 alcanzaron 0,91, 0,98 y 0,95, respectivamente, para la clase “Completado”. Por otro lado, la precisión, el recall y la puntuación F1 son 0,48, 0,14 y 0,21 para la clase “No_completado”, todos los clasificadores lograron una alta precisión excepto para las clases minoritarias, por lo cual estos resultados fueron engañosos debido a que los datos analizaron están desequilibrados. Por lo que se ha propuesto varias técnicas para resolver los problemas asociados con el aprendizaje a partir de datos desequilibrados. Esas técnicas son (i) remuestreo (sobremuestreando la clase minoritaria o submuestreando la clase mayoritaria), (ii) selección de características y (iii) aprendizaje sensible al costo. Dado que se tiene un conjunto de datos limitado y una pequeña cantidad de características, el sobremuestreo es el enfoque óptimo. El sobremuestreo simula puntos de datos para mejorar el equilibrio entre las clases. Existen varias técnicas de sobremuestreo. El estudio explora el uso de la técnica de sobremuestreo de minorías sintéticas (SMOTE) la cual sintetiza nuevas instancias minoritarias entre instancias minoritarias (reales) existentes. Como para concluir el estudio muestra que es posible predecir el rendimiento académico con gran precisión utilizando solo un pequeño número de datos, estos resultados pueden ayudar a construir un sistema de alerta temprana para evitar la deserción escolar.

En el artículo [1], indica que para este estudio, los datos se recolectaron de un sistema de libros electrónicos llamado BookRoll, para dar más detalles, el sistema BookRoll tiene varias características que incluyen marcadores rojos y amarillos para resaltar partes importantes y difíciles de un contenido, respectivamente. El estudio se basa en el análisis

de más de 65.000 datos de flujo de clics que se recopilan de 90 estudiantes registrados en un Curso de Informática Elemental en una universidad. Los datos sin procesar se pre-procesaron en cuatro pasos. En el primer paso, se extrajeron características de los datos sin procesar recopilados en la base de datos. En el segundo paso, se analizó las estadísticas descriptivas de las características. Luego, se eliminó aquellas características donde el uso de los estudiantes estaba limitado. En el tercer paso, se crearon datos semanales por la razón que sirve para comparar el rendimiento de los modelos desarrollados en diferentes conjuntos de datos para encontrar el momento óptimo para futuras intervenciones. En el cuarto y último paso, se aplicaron métodos de transformación y discretización de datos para crear tres formularios de datos diferentes para los datos de interacción de cada semana. Estas tres formas de datos son datos sin procesar, datos transformados y datos categóricos.

En esta investigación se probó el rendimiento de diferentes algoritmos en diferentes formularios de datos para encontrar el mejor modelo de predicción. Seleccionaron y compararon el rendimiento de los siguientes algoritmos en función de los resultados de investigaciones anteriores: AdaBoost, Árboles de Regresión Aditivos Bayesianos, Modelo Lineal Generalizado, KNN, Naive Bayes, Red Neuronal, Random Forest. Durante el análisis de datos, en lugar de comparar todos los algoritmos con todos los conjuntos de datos, siguieron el análisis de dos pasos. En el primer paso, el objetivo era encontrar el algoritmo de mejor rendimiento en cada forma de datos (por ejemplo, Random Forest-Datos sin procesar, etc.). En el segundo paso, se usó el algoritmo de mejor desempeño para cada formulario de datos y probaron su desempeño en los datos obtenidos en diferentes semanas del curso. El rendimiento de cada modelo se evaluó mediante una validación cruzada de 10 veces. Como se tenía un conjunto de datos balanceado, se usó la métrica de Precisión como criterio principal de rendimiento para comparar los resultados de los modelos de predicción. también se usó Kappa de Cohen como métrica secundaria. Las métricas tiene como objetivo principal evaluar el grado en que el modelo es mejor que el azar para identificar a los estudiantes de bajo y alto rendimiento. Un Kappa de 0 indica que el rendimiento está por lo cual es probable que sea un desertores, mientras que un Kappa de 1 significa el rendimiento perfecto. Se probaron el rendimiento de los 13 algoritmos en los datos tomados de la semana 14 del curso y se obtuvo como resultado que para los datos sin procesar el algoritmo de Random Forest superó a otros algoritmos en términos de métricas de precisión y Kappa. Sin embargo, con los datos transformados, el algoritmo AdaBoost funcionó mejor. Para los datos categóricos, Naive Bayes superó otros

algoritmos algoritmos. Por otro lado, casi todos los algoritmos predijeron Bajo y Alto rendimiento correctamente con una precisión entre el 72 % y el 84 %. En términos de valores de Kappa, la mayor parte del modelo produjo resultados aceptables (al menos un 50 % mejores que el azar). Para concluir los resultados revelaron que los estudiantes tanto de bajo y alto rendimiento son propensos a desertar después de la semana 14 del programa de estudios, lo cual se intenta evitar implementando planes académicos de contingencia.

En el artículo [23], se propuso un estudio de técnicas de minería de datos educativo para predecir la deserción escolar en 670 estudiantes de secundaria en Zacatecas, México. Los resultados obtuvieron una precisión entre el 75 % y el 98 % de los diez clasificadores seleccionados para este caso de estudio cuando se aplicaron en diferentes contextos en el mismo experimento. Los algoritmos utilizados en este estudio fueron: Árbol de decisión, KNN, Red Neuronal, Máquina de Vectores de Soporte, Naive Bayes y Random Forest, La diferencia en la precisión de los algoritmos utilizados está directamente relacionada con la cantidad de materias presentadas en cada semestre, tercer semestre del programa Ingeniería Informática, que actualmente tiene 6 cursos, mostró la precisión más baja, mientras que el cuarto semestre, que tiene solo 4 materias, tuvo una precisión más alta. Esto apunta al hecho de que un mayor número de cursos puede conducir a una disminución en el desempeño de los estudiantes y a la deserción. La menor precisión para el programa de Ciencias de la Computación se presenta en los primeros 3 semestres. Esto puede estar relacionado con el hecho de que esta especialización tiene diferentes grupos de materias que se toman todas a la vez (matemáticas, informática, electrónica, ...) al comienzo del programa y es posible que no todos los estudiantes estén preparados para eso. También se puede decir que la precisión fue la más baja en el segundo semestre para el programa de Sistema de Información. Esto puede explicarse por el hecho de que muchas materias de matemáticas y lógica son introducidas y estudiadas en conjunto. En el tercer, cuarto y sexto semestre, la precisión tiene una tendencia al alza, lo que puede indicar que los estudiantes se sienten más cómodos con las materias técnicas. Para concluir este artículo presentó el análisis de diferentes técnicas de aprendizaje supervisado en el contexto de la minería de datos educativos para evitar la deserción de estudiantes universitarios. Se encontró que los estudiantes abandonaron sus respectivos programas con mayor frecuencia en el 4° semestre para los programas de Ciencia de la Computación e Ingeniería Informática, y en el 6° semestre para el de Sistema de Información ya que esos fueron los semestres donde los algoritmos tuvieron sus mejores resultados.

En el artículo [29], se utilizaron modelos Gradient Boosting, Random Forest, SVM y Ensemble para predecir la deserción en diferentes etapas de los estudios universitarios, antes de la inscripción y al final de cada semestre durante los dos primeros años. Además de los datos académicos, los modelos también tomaron en consideración los datos personales de los estudiantes, su familia y entorno, y su interactividad con las herramientas de aprendizaje en línea. De acuerdo con los resultados, es posible detectar la deserción con una precisión del 82,91 % al finalizar el primer semestre. La precisión aumenta a 91,5 % al final del cuarto semestre, también logró una precisión de predicción de deserción comparable entre 77 y 93 %. El conjunto de datos contenía datos de cuatro años académicos y se utilizó para entrenar modelos de clasificación como Regresión Logística, Árbol de Decisión, Random Forest, Naive Bayes y SVM. Las cinco características del conjunto de datos incluyeron el número de vistas del curso, puntajes de tareas, pruebas, exámenes y proyectos. Como resultado, se podía confiar en los modelos para predecir la probabilidad de abandono escolar al final de un solo semestre con una precisión satisfactoria. Al final, se alcanzó una precisión de predicción alta, con un porcentaje del 90 % y una puntuación F1 de 0,85, lo que indica que el modelo funciona bien y los resultados de las predicciones son fiables.

En el artículo [14], se llevan a cabo dos esquemas de aprendizaje conjunto, el primero se combina con SMOTE (SEL) y el otro se hace sin SMOTE (EL). El SEL de rendimiento se evalúa utilizando tres métricas apropiadas para un conjunto de datos de desequilibrio: precisión, recall y medida F. Estos resultados se comparan luego con el resultado obtenido con EL y cada método base. Los datos utilizados para este estudio provienen de los datos públicos de KDDCUP 2015, además se centró en optimizar la predicción de la deserción de los estudiantes de MOOC a través de la combinación de SMOTE y aprendizaje conjunto (SEL). Los tres métodos básicos de aprendizaje automático utilizados son Random Forest, KNN y Regresión Logística. La medida F máxima en ambos esquemas (con o sin SMOTE) se obtiene en el curso E que contiene las instancias más pequeñas pero la porción más alta de estudiantes que desertaron. De lo contrario, el resultado más bajo sucede en el curso D con la porción más baja de la clase 1. Los resultados del experimento validan la superioridad del método propuesto. Con el recall más alto, se ha demostrado que SEL es el más confiable y preciso. El método propuesto optimiza el rendimiento de la predicción con una mejora media de la puntuación F1: 7,74 % en comparación con el otro método.

En el artículo [8], El conjunto de datos utilizado en el

artículo se obtuvo de los MOOC de la Universidad de Harvard en colaboración con el Instituto Tecnológico de Massachusetts. se utilizan varios modelos de Machine Learning como: Naive Bayes, Random Forest, Árbol de Decisión y Máquina de Vector de Soporte, éstos se ejecutan en Weka dandonos una comparación del porcentaje de precisión entre modelos junto con instancias correctamente clasificadas e incorrectamente clasificadas. Los resultados muestran que Random Forest funciona mejor para el conjunto de datos, sobre la clasificación de si un estudiante abandonará o no con una precisión de 0.9986, mientras que otros modelos Árbol de Decisión, SVM y Naïve Bayes dan resultados más bajos pero convincentes, con una precisión de 0.9981, 0.9974 y 0.9825 respectivamente. Esto se debe a la forma no lineal de relación entre las características del conjunto de datos y la característica objetivo (certificada). Las técnicas de aprendizaje automático se pueden utilizar para predecir la deserción de los estudiantes, lo que puede ayudar a los instructores a modelar su curso en consecuencia. El conjunto de datos de los MOOC se puede usar para entrenar en diferentes modelos de clasificación y, al examinar su precisión, se pueden seleccionar modelos para usarlos en predicción en tiempo real de la deserción de los estudiantes en el curso.

En el artículo [11], se detalló que el experimento se realizó en el clúster denominado SuperNode XP, que es un clúster heterogéneo con 24 nodos de cómputo. Hay 2 zócalos de CPU, 2 tarjetas Intel y 128 GB de RAM por nodo. El clúster de Spark en este documento se basa en 4 nodos: 1 maestro y 3 trabajadores. Para estudiantes universitarios, el conjunto de datos se divide por separado en grupos para entrenar y probar el modelo de predicción. Concretamente, hay 2 casos de estudio:

- a) Solo se usaron los datos de una facultad en específico para entrenar y probar la predicción para esa facultad.
- b) Se usaron los datos de toda la universidad para entrenar y probar la predicción para estudiantes en una facultad

Se ajustó los modelos utilizando los conjuntos de entrenamiento, luego se calculó el error cuadrático medio (RMSE), el error cuadrático medio (MSE), el error absoluto medio (MAE) de las predicciones en el conjunto de prueba. Los puntajes de RMSE y MSE mostraron si hay errores inusualmente altos en algunas predicciones. Mientras tanto, la puntuación MAE da un error promedio en el experimento. Cada método se ejecuta y se prueba 10 veces, con el conjunto de entrenamiento y el conjunto de prueba se aleatoriza nuevamente después de cada vez. Luego se obtuvo el promedio de los resultados finales. Concretamente,

se utilizaron siete algoritmos para el modelo de predicción: Random Forest, Regresión Logística, Naive Bayes, Máquina de Vectores de Soporte, KNN, Redes Neuronales, Árbol de Decisión. Para concluir se puede destacar que el estudio analiza y compara varias técnicas de Machine Learning mostrando que hay poca diferencia en el rendimiento entre las diferentes técnicas, pero con una diferencia mínima del modelo de Random Forest teniendo una precisión del 0.815 al momento de predecir los estudiantes que abandonan la facultad.

En el artículo [21], el conjunto de datos contenía 4424 registros con 35 atributos, donde cada registro representa a un estudiante individual y se puede usar para comparar el rendimiento de diferentes algoritmos para resolver el mismo tipo de problema y para entrenar en el área de aprendizaje automático. La clase mayoritaria, Graduados, representa el 50% de los registros (2209 de 4424) y Deserción representa el 32% del total de registros (1421 de 4424), mientras que la clase minoritaria, Matriculados, representa el 18% del total de registros (794 de 4424). Esto podría resultar en una alta precisión de predicción impulsada por la clase mayoritaria a expensas de un desempeño deficiente de la clase minoritaria. Por lo tanto, cualquier persona que use este conjunto de datos debe prestar atención a este problema y abordarlo con un enfoque a nivel de datos o con un enfoque a nivel de algoritmo. En el enfoque a nivel de datos, se utilizó una técnica de muestreo como la técnica de muestreo de minorías sintéticas (SMOTE) o el enfoque de muestreo sintético adaptativo (ADASYN) o cualquiera de sus variantes. En el enfoque de nivel de algoritmo, se debe usar un algoritmo de aprendizaje automático que ya incorpore pasos de equilibrio, como Random Forest. Los cursos más exitosos son Enfermería y Servicio Social, con 72% y 70% de los estudiantes, respectivamente, recibiendo su título dentro de la duración normal del curso. En el lado opuesto, el campo de las tecnologías con las carreras de Tecnologías de Producción de Biocombustibles e Ingeniería Informática presenta los resultados más desafortunados, con solo el 8% de los estudiantes obteniendo su título dentro de la duración normal de la carrera. La deserción también es mayor en estos dos cursos (67% y 54%, respectivamente), junto con el curso de Equinicultura con un 55% de deserción. también se muestra que las mujeres son las más exitosas, así como los estudiantes que tienen una beca y tienen sus tasas de matrícula al día.

En el artículo [4], estimaron los estudiantes en riesgo completando un cuestionario dos veces (al comienzo del programa y después del primer período). Los maestros también proporcionaron sus años de experiencia y edad, y se les pidió varias observaciones, sentimientos

o corazonadas posibles (en una escala de Likert de cinco puntos) si los usaban para hacer sus estimaciones. Luego, los maestros hicieron, por alumno, una estimación eligiendo una categoría (éxito/abandono/No enseño a este alumno) y una puntuación de certeza que resultó en seis categorías: (1) alta confianza en la predicción de “deserción”, (2) deserción con alto riesgo (3) deserción con menor riesgo, (4) exitosa con alto riesgo de deserción, (5) exitosa con menor riesgo de deserción y (6) alta confianza en la predicción “exitosa”. Dado que las predicciones del maestro y del modelo están en diferentes escalas, las medidas paramétricas de asociación son inapropiadas. Como medida de precisión de la predicción, calculamos la correlación de rango de Kendall no paramétrica, también conocida como T de Kendall entre las predicciones y el resultado. El porcentaje de estudiantes en riesgo que los maestros predijeron al principio del programa estuvo entre el 13% (7 de los 54 alumnos) y el 32% (30 de los 95 alumnos), y el porcentaje real de deserción estudiantil fue del 25% (24 de los 95 alumnos). El maestro compuesto y el Random Forest funcionan mejor en términos de precisión: (1) la línea de precisión es la más alta y (2) no hay caídas repentinas en el rendimiento de la precisión. El panel de precisión al comienzo del programa muestra que los maestros tienen 100% de razón sobre el primer 6% de los estudiantes que abandonaron. Hay así un grupo de alumnos con muy pocas posibilidades de éxito que son identificados con precisión por los profesores pero no por los modelos. Después del período 1, el SVM se desempeña mejor con el primer 9% de los estudiantes pronosticados con un 100% de corrección. El aprendizaje automático podría ayudar a avanzar en el uso de un conjunto diverso de evidencia para tomar decisiones y predicciones. La respuesta a la pregunta de quién predice mejor la deserción: la computadora o el maestro, no parece ser una cuestión de elección, pero que el rendimiento de la predicción se puede aumentar mediante la combinación de computadora con profesor.

Finalmente se puede concluir que no todos los maestros eran igualmente buenos para hacer predicciones. Si estas diferencias son atribuibles a la capacidad de predecir o si las diferencias pueden explicarse por la variación aleatoria tendrá que ser investigado en futuras investigaciones.

En el artículo [15], se ha realizado una comparación entre los algoritmos de Regresión Logística y Árbol de Decisión para predecir la deserción de los estudiantes universitarios. Ambos clasificadores producen altas precisiones con una ventaja para el árbol de decisión. Los datos se recopilaron de un instituto de educación superior en Alemania (KIT) y se concentran en diferentes factores como el rendimiento en los exámenes, la situación financiera, la motivación,

la salud y los problemas familiares. Después del primer semestre, la precisión alcanzó el 83%, después del tercer semestre alcanzó el 95%. Para poder autoajustar los resultados en un programa orientado a la titulación e-learning, los autores propusieron técnicas de clasificación basadas en reglas JRip (JR), PART (PA), OneR (OR) y Ridor (RI) para enfatizar los factores provocando la deserción de los estudiantes en diferentes momentos. Se utilizan tres técnicas de clasificación de minería de datos para proporcionar una predicción de la deserción de los estudiantes universitarios. Los algoritmos están basados en aprendizaje automático, algoritmos NDTREE y algoritmos de aprendizaje automático mejorado (EMLA). Los datos se componen de 407 instancias con 5 características y dieron las siguientes precisiones en orden 78,3%, 70% y 30,7%. Los autores implementaron un modelo predictivo de desempeño académico en instituciones privadas de educación superior. Compararon los resultados de los algoritmos: redes neuronales artificiales (ANN), eXtreme GBoost, regresión lineal, Support Vector Machine, Naïve Bayes y Random Forest. Los modelos se ajustaron con datos compuestos por 10 características que incluyen calificaciones, situación financiera, horas de estudio por semana y dominio del inglés. La precisión muestra que ANN se desempeñó mejor que los otros cinco algoritmos en términos de clasificación de los estudiantes en dos categorías: los que probablemente aprobarán y los que se predice que reprobarán. El 58% de las deserciones notadas nunca han reprobado un curso, por lo que hay otros predictores. Para identificarlos, los autores emplearon tres algoritmos de aprendizaje automático: regresión logística, redes neuronales y árbol de decisión. Clasifican a las deserciones sin razones académicas claras como deserciones existenciales, y analizaron los datos de 45752 estudiantes entre 2003 y 2015. Las variables contienen estatus socioeconómico, rendimiento demográfico, de la escuela secundaria y otros predictores no académicos y no académicos. Los modelos han predicho con éxito los graduados; sin embargo, los abandonos existenciales siguen siendo un enigma que incluso los predictores de rendimiento preuniversitarios no académicos no lograron predecir los estudiantes desertores.

5. Árbol de Decisiones

En el artículo [16], se tiene un conjunto de datos proporcionado por el Centro de Evaluación e Investigación Social de la Universidad Estatal de Luisiana, subcontratado por el Departamento de Educación de Luisiana, que contiene datos disciplinarios y de matrícula para estudiantes en las escuelas públicas de Luisiana en cada año escolar, por lo que se utilizaron

tres clasificadores estándar, que son el árbol de decisión único, los árboles de embolsado y la red neuronal. En el estudio primeramente se entreo un modelo de árbol de decisión único a través del algoritmo CART que tiene dos pasos principales: 1) Hacer crecer un árbol completo y (2) Aplicar la poda de complejidad en el árbol completamente desarrollado, por está razón se ajusto el parámetro de complejidad para encontrar el mejor árbol podado.

En el método de árboles de embolsado se combina modelos para reducir la varianza y por lo tanto mejorar la predicción. por lo que se recomienda usar embolsado con modelos inestables para este punto se ajusto el número de muestreos de arranque para obtener el modelo de mayor rendimiento. Para la técnica de Red Neuronal se implementó un avance con una sola capa oculta y los enlaces ponderados a la neurona, de la misma manera se ajustaron dos parámetros en el algoritmo de la red neuronal implementada. Como método de evaluación se usaron las métricas de Precisión, Recall y Medida F, al comparar estas métricas en cada uno de las técnicas de predicción utilizadas en este estudio se puede ver que los tres clasificadores presentan un recall sumamente bajo, esto indica que no funcionan bien para detectar los estudiantes que abandonaron la escuela. Solo el 4% del conjunto de datos contenía estudiantes que abandonaron la escuela. Esto creó el problema de la clasificación desequilibrada, es decir, los clasificadores estándar no pueden detectar la clase rara. Para abordar este problema, se estudiaron las técnicas de aprendizaje desequilibrado, como el muestreo, la ponderación de casos y el aprendizaje sensible a los costos, para mejorar el rendimiento de la predicción. El valor del recall más alto lo obtiene el árbol de decisión único (91,6%), seguido de la red neuronal entrenada en los datos ponderados por caso (91%) y los árboles de decisión de embolsado (90,9%), esto indica la eficacia de los métodos de conjunto en la clasificación de desequilibrios.

6. K-Nearest-Neighbor

En el artículo [22], los datos han sido captados mediante la organización de la encuesta a estudiantes de grado presentes en la universidad, en la que han participado cerca de 1.243 estudiantes. Esta encuesta puede mostrar específicamente el estado de deserción con la especificación de género. La evaluación de la predicción de la deserción de los estudiantes utilizando el algoritmo PCA-SMOTE en varios modelos de ML, como Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), Regresión Logística (LR) y KNN. Este experimento se lleva a cabo utilizando Python, que tiene numerosas bibliotecas esenciales como scipy, numpy, scikit-learn y tensorflow, que

los programadores utilizan para construir técnicas de minería de datos. En estas bibliotecas se proporcionan características integradas de categorización y toma de decisiones. El conteo de muestras tomado del conjunto de datos describe 804 para entrenamiento y 359 para prueba. Los parámetros de la matriz de confusión, como la exactitud, la precisión, el recall, la sensibilidad y la especificidad de los modelos de Machine Learning respectivos, se tratan con los valores de Verdadero positivo (TP), Verdadero negativo (TN), Falso Positivo (FP) y Falso Negativo (FN). El algoritmo PCA-SMOTE con KNN ha generado una mayor precisión de 97,6% en comparación con otro modelo de aprendizaje automático para predecir la deserción de los estudiantes en la encuesta realizada. Del mismo modo, la sensibilidad y el recall de KNN_SMOTE son tan altas como 0,987 en comparación con otros modelos PCA-SMOTE. Además, la especificidad de KNN_SMOTE es 0,956, que es la más baja que otros modelos de Machine Learning considerados en este experimento, lo que explica que la predicción de falsos positivos de la deserción de los estudiantes usando PCA-SMOTE con el modelo KNN es mejor en comparación con otros modelos PCA-SMOTE ML, así como sin ellos.

En el artículo [10], se estudió el rendimiento de los modelos de Machine Learning para la predicción temprana de estudiantes en riesgo de reprobar y desertar utilizando un pequeño conjunto de datos. Se implementaron un total de 14 modelos de clasificación para cada SL. Los clasificadores fueron: Regresión Logística, Árbol de Decisión, SVM, Naive Bayes, Radial Basis function kernel, GPC, MLP, Ridge, Random Forest, Ada Boost, Extra Trees, LightGBM and CatBoost. Los resultados muestran que, incluso en esta circunstancia, es posible realizar la tarea con una precisión media del 78% con datos de la primera semana del curso, que está cerca de otros estudios que realizaron predicciones tempranas pero con conjuntos de datos significativamente más grandes. Los modelos, para cada combinación de semana y SL, se clasificaron según la precisión media obtenida en el k-fold en el conjunto de entrenamiento. Luego se seleccionaron los 4 primeros, se implementaron y evaluaron un total de 84 modelos y 6 conjuntos divididos en 14 modelos para la semana 1, 28 para la semana 2 y 42 para la semana 3. En la semana 1, AdaBoost presenta el mejor rendimiento en la fase de selección del modelo, pero el peor en la fase de evaluación del modelo. Por otro lado, el conjunto presentó un desempeño intermedio entre lo mejor y lo peor en la fase de evaluación, lo que sugiere que puede ser la alternativa más prometedora para la predicción temprana sobre los datos de la semana 1. En la Semana 2, no se observó ninguna mejora en la selección del modelo ni en los

resultados de la evaluación. Además, el desempeño de los clasificadores fue bastante similar en las 2 ventanas de tiempo deslizantes ensambladas. En la semana 3, los 4 mejores clasificadores basados en SLI se desempeñaron por igual, con valores de precisión y F1 Score iguales, lo que sugiere un sobreajuste. Sin embargo, los clasificadores SL1 también presentaron un rendimiento superior sobre SLO y SL2 cuando se presentaron a datos no vistos. En la fase de evaluación, los resultados se observan mucho entre los clasificadores implementados con SL1, por lo que no hay suficiente evidencia que sugiera que cualquiera de los cuatro clasificadores o el conjunto de votos principal sea una mejor opción sobre los demás. Este resultado sugiere que es posible identificar estudiantes en riesgo de reprobación y deserción incluso en un curso que cuenta solo con datos de un número pequeño de estudiantes anteriores. Esta situación puede ocurrir cuando se lanza un nuevo curso, así como cuando se cambia el enfoque o la metodología de aprendizaje de manera que los datos anteriores se vuelven inadecuados para el reconocimiento de patrones en las nuevas clases.

En el artículo [9], el conjunto de datos se construyó a partir de encuestas pedagógicas en portugués IES. Los datos recopilados abarcan: (i) dos semestres; (ii) ocho años académicos consecutivos (2013/2014 a 2020/2021); (iii) cuatro cursos (de 3 o 4 años); y (iv) tres departamentos diferentes. El conjunto de datos contiene 87.752 respuestas válidas a ocho preguntas de dos categorías. Los modelos utilizados en este estudio son: Random Forest, KNN, Naive Bayes, por lo cual los resultados obtenidos son consistentes en la mayoría de los casos para todos los clasificadores, aumentando la precisión según el conjunto utilizado. Además, la solución propuesta proporciona resultados prometedores con la diferenciación de cursos con distintas cantidades de estudiantes. El método propuesto se evaluó utilizando métricas de clasificación estándar, logrando una precisión de clasificación del 98 % y una F-medida del mismo valor. Este resultado muestra que es posible explicar y clasificar el desempeño de los estudiantes utilizando cuestionarios pedagógicos. El método propuesto permite tomar acciones preventivas y evitar cancelaciones anticipadas o abandonos. En concreto, el método propuesto proporciona explicaciones que ayudan a comprender las razones del éxito o fracaso de cada unidad curricular. Con este conocimiento se puede adaptar la unidad curricular para evitar reprobaciones, cancelaciones anticipadas o deserciones. Las explicaciones brindan información a ambos niveles, unidad curricular y esfuerzo de los estudiantes siendo un punto de partida para mejorar el método pedagógico en el próximo curso escolar. Además, la solución propuesta tiene como objetivo apoyar los tres pilares de la sostenibilidad, es decir, económico, social y

ambiental.

En el artículo [19], los datos utilizados en este trabajo fueron proporcionados por la Administración Nacional de Educación Pública (ANEP) y recolectados de nueve diferentes sistemas de gestión educativa. Las diferentes bases de datos recopiladas para este proyecto fueron preprocesadas y transformadas para generar tres conjuntos de datos principales utilizados para la generación del modelo: (1) la base de datos de Educación Primaria (PE), (2) la base de datos de Educación Secundaria Regular (CES), y (3) la base de datos de Educación Secundaria Técnica (UTU). La preparación de datos se realizó utilizando el lenguaje de programación Python y las siguientes bibliotecas principales: NumPY, Pandas y Scikit-learn. Este paso incluyó la integración de datos, la limpieza de datos, la derivación de nuevas funciones y la selección de datos. La etapa de generación de modelos predictivos involucra una serie de aspectos diferentes, tales como pruebas con diferentes algoritmos, selección de los algoritmos a utilizar, filtrado de los datos considerando sus características y contribución al desempeño de los modelos, y configuración de los hiperparámetros. El primer paso para la generación de los modelos fue la selección de algoritmos que pudieran cumplir con los requisitos establecidos por el manual de IA y que presentó un buen desempeño. Los algoritmos que presentaron los mejores resultados fueron random forest y MLP (Perceptrón Multicapa), mostrando ambos rendimientos muy similares. También se realizaron algunas pruebas con algoritmos de conjunto más avanzados, como el aumento de gradiente y XGBoost, pero ambos fueron descartados por no presentar rendimientos significativamente superiores a los anteriores. Para la evaluación se utilizaron tres métricas: F1-Macro, F1-Micro y AUROC. Los resultados muestran que los modelos tenían puntuaciones F1-macro y AUROC superiores a 0,87. También muestran que el enfoque de crear una vida útil de datos CES fue satisfactorio. A través de este enfoque, los modelos pudieron alcanzar una discriminación sobresaliente (AUC mayor a 0.90) para los cuatro escenarios de los datos CES. En el peor de los casos, los modelos pudieron identificar correctamente los estados finales de los estudiantes en el 91 % de los casos. Mientras que los resultados del modelo UTU presentó los peores resultados, con F1-Macro y AUCROC de 0,68. Sin embargo, a partir del segundo modelo (M2G1-UTU), el rendimiento creció, con resultados superiores a 0,93 (F1-macro) y 0,95 (AUCROC). Por lo tanto se puede concluir que es posible generar modelos predictivos que pueden ayudar en la identificación de estudiantes con tendencia a enfrentar algunos problemas (deserción o reprobación) durante la escuela secundaria. Sin embargo, estos modelos necesitan ser entrenados

anualmente con nuevos datos que puedan representar los cambios que se están produciendo en la población estudiantil. Esto puede generar una situación compleja, ya que estos modelos utilizan datos anteriores a la pandemia de COVID-19 y pueden no presentar buenos resultados con datos del período de la pandemia. Se entiende que los nuevos escenarios educativos surgidos de la pandemia posiblemente requerirán futuras adaptaciones en los modelos predictivos.

IV. DISCUSIÓN

La deserción estudiantil ha sido continúa siendo uno de los problemas más importantes que enfrenta la comunidad de educación superior. El propósito de este estudio fue proporcionar un mejor análisis de las diferentes técnicas, algoritmos, datasets que se han utilizado en los diferentes estudios, para realizar una comparación y encontrar el más óptimo al momento de resolver la presente problemática de la deserción universitaria. En esta sección, se resumió e interpretó los hallazgos principales, destacando brevemente las técnicas, algoritmos, datasets con el fin de poder terminar considerándolos para futuras investigaciones sobre la deserción universitaria.

Como principales hallazgos podemos decir que en el artículo [18], se puede concluir que: (1) El modelo DP-CNN propuesto es efectivo para resolver el problema de predicción de abandono en MOOC con una gran cantidad de datos y logra mejores resultados que los métodos de referencia. (2) En la etapa de transformación, las ventanas de tiempo de diferentes escalas tienen cierto impacto en el efecto de predicción de todo el método, y es mejor establecer el tamaño de las ventanas de tiempo de acuerdo con el problema a resolver.

De la misma manera en el artículo [3], se puede concluir que al utilizar un algoritmo híbrido de clasificador de votación ponderado (WVC) junto con validación cruzada de 10 veces (10-CV) y cinco algoritmos de aprendizaje automático, se puede evaluar el conjunto de datos de predicción de calificaciones de los estudiantes tomado de Kaggle y tener como resultado que a partir de la precisión del 97,6% lograda, el modelo propuesto pudo identificar a 634 estudiantes de 650 como (Regular, Bueno y Excelente). Por lo tanto, los planificadores académicos deben implementar los resultados de este estudio y tomar decisiones estratégicas para evitar la deserción de los estudiantes.

Por otro lado en el artículo [25], con los resultados, se puede concluir que las deficiencias del estudio actual es que el conjunto de datos es relativamente antiguo; sin embargo, hasta donde saben los investigadores, es la encuesta nacional más reciente que cubre el tema de la deserción escolar y para mejorar aún más el rendimiento de la clasificación de los desertores escolares, existen algunas opciones adicionales que podrían investigarse en investigaciones futuras, como un mayor ajuste de los parámetros del modelo e implementar otras técnicas de clasificación como árboles de decisión y máquinas de vectores de soporte que ayuden a predecir la

deserción escolar.

En el artículo [20], la mayoría de los estudios no mencionaron ningún criterio de evaluación ni realizaron ninguna evaluación. Del resto de estudios, la mayoría utilizó métodos mixtos que combinaron métodos cualitativos y cuantitativos para evaluar la utilidad de los cuadros de mando. Un estudio realizó un enfoque cualitativo evaluando aspectos generales como la usabilidad de LAD investigando las percepciones de los usuarios sobre su interacción con la herramienta.

La investigación muestra que, hasta ahora, solo una cantidad limitada de tableros han incorporado análisis predictivos. Sin embargo, la tendencia es creciente. Los pocos que han implementado y evaluado esta tecnología en su mayoría han reportado efectos positivos. Indudablemente, una proporción de los efectos positivos se puede atribuir a las intervenciones asociadas iniciadas con estudiantes en riesgo, planteadas por las alertas tempranas de los modelos predictivos. Por lo tanto, además de predicciones precisas, parece importante considerar cómo se presentan la mecánica de predicción y los resultados del modelo como consejos para los estudiantes en riesgo de abandono escolar.

Finalmente, en el artículo [7], los investigadores de análisis de aprendizaje y minería de datos educativos deben considerar y abogar por el uso de modelos de éxito de los estudiantes de manera que promuevan la justicia, la equidad y la reducción de las brechas de rendimiento entre los grupos de estudiantes. Esto incluye considerar los datos de entrenamiento en sí mismos y cómo los modelos basados en estos datos podrían transferirse para hacer predicciones sobre la deserción de estudiantes.

Para evaluar los algoritmos de predicción de Machine Learning de todos los artículos se utilizaron métricas de evaluación como: Precisión, Recall y Medida F, las mismas que nos sirven para comparar y encontrar el algoritmo más óptimo al momento de predecir los desertores universitarios. A continuación en la Figura 6 y en la Figura 7 se detalla los hallazgos de cada uno de los artículos:

Algoritmo	Precisión	Recall	Medida F	
Redes Neuronales				
Artículo N° 1	0.83	0.86	0.84	
Artículo N° 7	0.65	0.73	0.64	
Artículo N° 14	0.73	0.86	0.76	
Regresión Logística				
Artículo N° 2	0.83	0.85	0.84	
Artículo N° 12	0.75	0.81	0.74	
n	Artículo N° 16	0.88	0.94	0.89
Máquina de Soporte de Vectores				
Artículo N° 4	0.76	0.80	0.77	
Artículo N° 27	0.63	0.72	0.60	
Artículo N° 28	0.71	0.91	0.74	

Figura 6. Tabla de Comparación de Algoritmos de Machine Learning.

Para explicar de mejor manera la Figura 6 y la 7, se tiene

Random Forest				
	Artículo N° 8	0.81	0.86	0.86
	Artículo N° 10	0.83	0.88	0.90
	Artículo N° 11	0.87	0.86	0.83
	Artículo N° 13	0.94	0.87	0.80
	Artículo N° 18	0.89	0.89	0.87
	Artículo N° 19	0.96	0.84	0.92
	Artículo N° 22	0.81	0.80	0.80
	Artículo N° 23	0.98	0.84	0.89
	Artículo N° 3	0.84	0.89	0.93
	Artículo N° 5	0.85	0.85	0.89
	Artículo N° 6	0.82	0.92	0.85
Árbol de Decisiones				
	Artículo N° 9	0.91	0.70	0.91
	Artículo N° 24	0.52	0.74	0.85
	Artículo N° 25	0.82	0.71	0.82
	Artículo N° 26	0.75	0.65	0.65
K-Nearest-Neighbor				
	Artículo N° 15	0.45	0.84	0.62
	Artículo N° 17	0.56	0.64	0.51
	Artículo N° 20	0.66	0.76	0.62
	Artículo N° 21	0.75	0.84	0.61

Figura 7. Continuación de Tabla de Comparación de Algoritmos.

los artículos agrupados por algoritmos de Machine Learning con su respectiva métrica de evaluación. Por lo que se puede concluir que el algoritmo de Random Forest es el más óptimo y el más utilizado en los 28 artículos analizados, al momento de construir un modelo de predicción sobre el tema de la deserción universitaria dicho algoritmo ha resaltado como el más común y el mejor teniendo resultados favorables con todo tipo de características en los conjuntos de datos. Esto se puede comprobar al mostrar que todas las métricas: Precisión, Recall y Medida F, del algoritmo del Random Forest pasan del umbral 0.80, que es el necesario para denominar al algoritmo como el de mejor rendimiento.

V. CONCLUSIONES

Esta revisión mejora el trabajo previo y llena un vacío en el conocimiento sobre las diferentes medidas y técnicas utilizadas en los estudios sobre el abandono universitario. La novedad de este artículo es que puede servir de base para prácticas futuras de prevención del abandono universitario en los diferentes programas de formación profesional. No se deben extraer inferencias sólidas de los resultados del análisis, y los lectores deben tener cuidado al interpretar y aplicar las conclusiones de la revisión. Cabe señalar el hecho de que se tomó estudios de contextos muy diferentes (con diferencias perspectivas en los programas profesionales que analizan el fenómeno de la deserción en sí) y se los ha considerado el mismo lente. Además, se agrupó los estudios que tenían como objetivo analizar la efectividad de varias técnicas con estudios que no tenían este objetivo y más bien sugerían algunas ideas de cómo enfrentar el problema de la deserción como una reflexión final, no como medidas precisas. Sin embargo, la rigurosidad de nuestra metodología para buscar, encontrar, acceder y analizar documentos, compensa estas

carencias.

La revisión literaria propuesta encuentra adaptativamente un conjunto adecuado de características y el mejor algoritmo para predecir la deserción universitaria en los diferentes programas de educación profesional. El algoritmo de Random Forest se selecciona como el mejor algoritmo de Aprendizaje Automático con el mejor rendimiento evaluado con las métricas de Precisión, Recall y Medida F. En trabajos futuros, este modelo se puede probar para resolver otros conjuntos de datos educativos una vez que haya uno disponible para garantizar que el procedimiento utilizado pueda generalizarse para resolver de manera eficiente otros problemas similares.

REFERENCIAS

- [1] Gökhan Akçapınar, Mohammad Nehal Hasnine, Rwitajit Majumdar, Brendan Flanagan, and Hiroaki Ogata. Developing an early-warning system for spotting at-risk students by using ebook interaction logs. *Smart Learning Environments*, 6, 12 2019.
- [2] Sarah Alturki, Ioana Hulpuş, and Heiner Stuckenschmidt. Predicting academic outcomes: A survey from 2007 till 2018. *Technology, Knowledge and Learning*, 27:275–307, 3 2022.
- [3] Roselyne Ayienda, Richard Rimiru, and Wilson Cheruiyot. Predicting students academic performance using a hybrid of machine learning algorithms. volume 2021-September. Institute of Electrical and Electronics Engineers Inc., 9 2021.
- [4] Irene Eegdeman, Ilja Cornelisz, Chris van Klaveren, and Martijn Meeter. Computer or teacher: Who predicts dropout best? *Frontiers in Education*, 7, 11 2022.
- [5] María Del Rosario Fernández-Hileman, Ángela Corengia, and Julio Durand. Deserción y retención universitaria: una discusión bibliográfica. *Pensando Psicología*, 10:85–96, 12 2014.
- [6] Jose Edmond Meku Fotso, Bernabe Batchakui, Roger Nkambou, and George Okereke. Algorithms for the development of deep learning models for classification and prediction of behaviour in moocs. pages 180–184. Institute of Electrical and Electronics Engineers Inc., 9 2020.
- [7] Josh Gardner and Christopher Brooks. Student success prediction in moocs. *User Modeling and User-Adapted Interaction*, 28:127–203, 6 2018.
- [8] Avinash Kashyap and Ashalatha Nayak. Different machine learning models to predict dropouts in moocs; different machine learning models to predict dropouts in moocs, 2018.
- [9] Fátima Leal, Bruno Veloso, Carla Santos Pereira, Fernando Moreira, Natércia Durão, and Natacha Jesus Silva. Interpretable success prediction in higher education institutions using pedagogical surveys. *Sustainability (Switzerland)*, 14, 10 2022.
- [10] Denis Leite, Edson Filho, Joao F.L. De Oliveira, Rodrigo E. Carneiro, and Alexandre Maciel. Early detection of students at risk of failure from a small dataset. pages 42–46. Institute of Electrical and Electronics Engineers Inc., 7 2021.
- [11] Thong Le Mai, Phat Thanh Do, Minh Thanh Chung, and Nam Thoai. An apache spark-based platform for predicting the performance of undergraduate students. pages 191–199. Institute of Electrical and Electronics Engineers Inc., 8 2019.
- [12] Neema Mduma and Dina Machuve. Machine learning model for predicting student dropout: A case of tanzania, kenya and uganda. volume 2021-September. Institute of Electrical and Electronics Engineers Inc., 9 2021.
- [13] Mariana Mena, William Godoy, and Santiago Tisalema. Analysis of causes of early dropout of students higher education. *Minerva*, 2:79–89, 11 2021.
- [14] Eko Mulyani, Indriana Hidayah, and Silmi Fauziati. Dropout prediction optimization through smote and ensemble learning; dropout prediction optimization through smote and ensemble learning, 2019.
- [15] Khalid Oqaidi, Sarah Aouhassi, and Khalifa Mansouri. Towards a students' dropout prediction model in higher education institutions using machine learning algorithms. *International Journal of Emerging Technologies in Learning*, 17:103–117, 2022.

- [16] Marmar Orooji and Jianhua Chen. Predicting louisiana public high school dropout through imbalanced learning techniques. pages 456–461. Institute of Electrical and Electronics Engineers Inc., 12 2019.
- [17] Reyhan Zeynep Pek, Sibel Tariyan Ozyer, Tarek Elhage, Tansel Ozyer, and Reda Alhajj. The role of machine learning in identifying students at-risk and minimizing failure. *IEEE Access*, 11:1224–1243, 2023.
- [18] Lin Qiu, Yanshen Liu, Quan Hu, and Yi Liu. Student dropout prediction in massive open online courses by convolutional neural networks. *Soft Computing*, 23:10287–10301, 10 2019.
- [19] Emanuel Marques Queiroga, Matheus Francisco Batista Machado, Virginia Rodés Paragarino, Tiago Thompsen Primo, and Cristian Cechinel. Early prediction of at-risk students in secondary education: A countrywide k-12 learning analytics initiative in uruguay. *Information (Switzerland)*, 13, 9 2022.
- [20] Gomathy Ramaswami, Teo Susnjak, Anuradha Mathrani, and Rahila Umer. Use of predictive analytics within learning analytics dashboards: A review of case studies. *Technology, Knowledge and Learning*, 2022.
- [21] Valentim Realinho, Jorge Machado, Luís Baptista, and Mónica V. Martins. Predicting student dropout and academic success. *Data*, 7:146, 10 2022.
- [22] M. Revathy, S. Kamalakkannan, and P. Kavitha. Machine learning based prediction of dropout students from the education university using smote. pages 1750–1758. Institute of Electrical and Electronics Engineers (IEEE), 2 2022.
- [23] Kelly J.O. De Santos, Angelo G. Menezes, Andre B. De Carvalho, and Carlos A.E. Montesco. Supervised learning in the context of educational data mining to avoid university students dropout. pages 207–208. Institute of Electrical and Electronics Engineers Inc., 7 2019.
- [24] Anne Scheunemann, Theresa Schnettler, Julia Bobe, Stefan Fries, and Carola Grunschel. A longitudinal analysis of the reciprocal relationship between academic procrastination, study satisfaction, and dropout intentions in higher education. *European Journal of Psychology of Education*, 2021.
- [25] Kamal Samy Selim and Sahar Saeed Rezk. On predicting school dropouts in egypt: A machine learning approach. *Education and Information Technologies*, 1 2023.
- [26] Universidad Y Sociedad, Roberto Carlos, Dávila Morán, Eucaris Del Carmen, Agüero Corzo, Héctor Portillo Rios, Omar Rolando, and Quimbita Chiluisa. Volumen 14| número 2 | marzo-abril. 2022.
- [27] Sakshi Sood and Munish Saini. Hybridization of cluster-based lda and ann for student performance prediction and comments evaluation. *Education and Information Technologies*, 26:2863–2878, 5 2021.
- [28] Shuo Chang Tsai, Cheng Huan Chen, Yi Tzone Shiao, Jin Shuei Ciou, and Trong Neng Wu. Precision education with statistical learning and deep learning: a case study in taiwan. *International Journal of Educational Technology in Higher Education*, 17, 12 2020.
- [29] Berat Ujkani, Daniela Minkovska, and Lyudmila Stoyanova. Application of logistic regression technique for predicting student dropout. pages 1–4. Institute of Electrical and Electronics Engineers (IEEE), 11 2022.
- [30] UNESCO. *Repitencia universitaria en América Latina*. Centro Universitario de Desarrollo, 2006.