



**UNIVERSIDAD CÉSAR VALLEJO**

**ESCUELA DE POSGRADO  
PROGRAMA ACADÉMICO DE MAESTRÍA EN  
INGENIERÍA DE SISTEMAS CON MENCIÓN EN  
TECNOLOGÍAS DE LA INFORMACIÓN**

**Machine learning en la autorregulación del aprendizaje de los  
estudiantes en una academia preuniversitaria privada, Lima  
2023**

**TESIS PARA OBTENER EL GRADO ACADÉMICO DE:**

**Maestro en Ingeniería de Sistemas con mención en Tecnologías de la  
Información**

**AUTOR:**

Pandal Blas, Carlos Enrique ([orcid.org/0000-0003-1488-1067](https://orcid.org/0000-0003-1488-1067))

**ASESORES:**

Dr. Vargas Huaman, Jhonatan Isaac ([orcid.org/0000-0002-1433-7494](https://orcid.org/0000-0002-1433-7494))

Dr. Pereyra Acosta, Manuel Antonio ([orcid.org/0000-0002-2593-5772](https://orcid.org/0000-0002-2593-5772))

**LÍNEA DE INVESTIGACIÓN:**

Sistemas de Información y Comunicaciones

**LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:**

Desarrollo económico, empleo y emprendimiento

LIMA — PERÚ

2023

## **Dedicatoria**

A mis seres queridos, quienes han sido mi fuerza e inspiración en este camino, les dedico mi tesis con gratitud y cariño.

### **Agradecimiento**

A la institución educativa que me permitió realizar el presente trabajo de investigación, por el apoyo y facilidades, así también porque me brindo un maravilloso espacio de aprendizaje, de desarrollo personal y de aporte a través de la educación.

## Índice de contenidos

Dedicatoria .....	ii
Agradecimiento .....	iii
Índice de contenidos .....	vi
Índice de tablas .....	vii
Índice de gráficos y figuras.....	viii
Resumen.....	ix
Abstract .....	x
I. Introducción .....	1
II. Marco Teórico.....	8
III. Metodología.....	21
3.1. Tipo y Diseño de Investigación .....	21
3.1.1. Tipo de Investigación .....	21
3.1.2. Diseño de Investigación.....	21
3.2. Variables y Operacionalización .....	22
3.3. Población, Muestra y Muestreo .....	24
3.3.1. Población .....	24
3.3.2. Muestra.....	24
3.3.3. Muestreo.....	25
3.3.4. Unidad de Análisis .....	26
3.4. Técnicas e Instrumentos de Recolección de Datos .....	26
3.5. Procedimientos .....	28
3.6. Método de Análisis de Datos.....	29
3.7. Aspectos Éticos.....	29
IV. Resultados.....	32
4.1. Análisis Descriptivo .....	32
4.2. Análisis Inferencial .....	38
V. Discusión .....	45
VI. Conclusiones.....	52
VII. Recomendaciones.....	54
Referencias .....	56
Anexos .....	65

## Índice de tablas

Tabla 1	Tabla de población .....	24
Tabla 2	Tabla de muestra estratificada proporcional.....	25
Tabla 3	Validez del Instrumento para recolectar los datos.....	27
Tabla 4	Rango alfa de Cronbach.....	27
Tabla 5	Análisis de fiabilidad .....	28
Tabla 6	Tabla descriptiva del indicador Planificación .....	32
Tabla 7	Tabla descriptiva del indicador Ejecución.....	34
Tabla 8	Tabla descriptiva del indicador Evaluación.....	36
Tabla 9	Indicador Planificación - Prueba de normalidad de Kolmogorov-Smirnov	38
Tabla 10	Prueba de normalidad de Kolmogorov-Smirnov – Indicador Ejecución..	39
Tabla 11	Prueba de normalidad de Kolmogorov-Smirnov – Indicador Evaluación	40
Tabla 12	Prueba de Wilcoxon – Indicador Planificación.....	41
Tabla 13	Prueba de Wilcoxon – Indicador Ejecución .....	42
Tabla 14	Prueba de Wilcoxon – Indicador Evaluación .....	43

## Índice de gráficos y figuras

Figura 1 Comparativo Pre-test Post-test - Planificación .....	33
Figura 2 Porcentaje aumento en Planificación .....	33
Figura 3 Comparativo Pre-test Post-test - Ejecución.....	35
Figura 4 Porcentaje aumento en Ejecución.....	35
Figura 5 Comparativo Pre-test Post-test - Evaluación.....	37
Figura 6 Porcentaje aumento en Evaluación.....	37

## Resumen

El objetivo de la presente investigación es determinar la influencia de Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

La presente investigación es del tipo aplicada, con enfoque cuantitativo y diseño pre-experimental. Se realizó un pre-test y post-test para medir la autorregulación del aprendizaje antes y después de la aplicación de machine learning a los estudiantes. Para la recolección de datos se utilizó la técnica de la encuesta y como instrumento, un cuestionario validado a nivel internacional, adaptado al contexto del presente estudio, validado por juicio de expertos y con buena confiabilidad según la prueba de Cronbach. En el análisis inferencial se utilizó la prueba de normalidad Kolmogorov-Smirnov y para las pruebas de hipótesis, la prueba de Wilcoxon.

Los resultados del análisis descriptivo e inferencial muestran que los tres indicadores de la autorregulación del aprendizaje presentaron incrementos significativos del 9,69% en Planificación, del 9,95% en Ejecución y 9,28% en Evaluación, y las pruebas de Wilcoxon correspondientes obtuvieron  $p < 0.05$ . Por lo tanto, se concluye que Machine Learning influye significativamente en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

**Palabras clave:** Machine learning, autorregulación del aprendizaje, inteligencia artificial, aplicación informática, autoaprendizaje

## Abstract

The objective of this research is to determine the influence of Machine Learning on the self-regulation of student learning in a private pre-university academy, Lima 2023.

This research is of the applied type, with a quantitative approach and pre-experimental design. A pre-test and post-test were carried out to measure the self-regulation of learning before and after the application of machine learning to the students. For data collection, the survey technique was used and as an instrument, an internationally validated questionnaire, adapted to the context of this study, validated by expert judgment and with good reliability according to Cronbach's test. The Kolmogorov-Smirnov normality test was used for the inferential analysis and the Wilcoxon test for hypothesis tests.

The results of the descriptive and inferential analysis show that the three indicators of self-regulation of learning presented significant increases of 9.69% in Planning, 9.95% in Execution and 9.28% in Evaluation, and the corresponding Wilcoxon tests obtained  $p < 0.05$ . Therefore, it is concluded that Machine Learning significantly influences the self-regulation of student learning in a private pre-university academy, Lima 2023.

**Keywords:** Machine learning, self-regulated learning, artificial intelligence, computer applications, self instruction



# I INTRODUCCIÓN

## I. Introducción

Actualmente las academias preuniversitarias privadas que preparan estudiantes para postular a las universidades nacionales afrontan uno de sus principales problemas relacionado con la Autorregulación de los Aprendizaje de los estudiantes, debido a que su avance académico y el éxito en el examen de admisión depende principalmente del esfuerzo y motivación del mismo estudiante, debiendo planificar, ejecutar y evaluar estratégicamente su autoaprendizaje. La academia brinda orientación, enseñanza y evaluación a los estudiantes en los cursos y temas establecidos en el prospecto de admisión, en un período de tiempo reducido, pero no es suficiente sino se promueve la Autorregulación de los Aprendizaje de los estudiantes, considerando que, a cada proceso de admisión de las universidades nacionales, se presentan cientos de postulantes por un número reducido de vacantes.

A nivel internacional, Pichel (2017) menciona que el modelo educativo finlandés es reconocido como un éxito, tal como lo demuestra el estudio internacional PISA, continúa innovando en su sistema educativo y busca promover que las instituciones educativas se ajusten a las necesidades individuales de cada estudiante, permitiéndoles asumir la responsabilidad de su propio proceso de aprendizaje, desarrollando su capacidad de Autorregulación de Aprendizaje. Por otro lado, Ministerio de Educación (2022) menciona que todos los países latinoamericanos que participaron en la prueba PISA 2018 presentan limitaciones en su Aprendizaje obteniendo puntuaciones inferiores al promedio de los países que participaron de la Organización para la Cooperación y el Desarrollo Económicos (OCDE) en todas las áreas evaluadas correspondientes a lectura, matemática y ciencias. En relación a esto, Pacheco (2020), menciona que el representante máximo de la Organización de Estados Iberoamericanos planteó la necesidad de abandonar el enfoque tradicional orientado hacia el procesamiento de información y la retención memorística, y adoptar enfoques basados en la participación activa que fomenten el Aprendizaje Autodirigido, la habilidad de regular y controlar el

proceso de aprendizaje de uno mismo, la colaboración y la cooperación entre estudiantes.

A nivel nacional, uno de los principales desafíos que la educación básica y preuniversitaria debe afrontar consiste en fomentar el aprendizaje autorregulado, en ese sentido Cordero (2020) menciona que es necesario crear comunidades de trabajo colaborativo, y promover en los estudiantes el aprendizaje autorregulado a través de la evaluación formativa y continua. Al respecto, Ministerio de Educación (2016), en el currículo nacional aún vigente al 2023, fomenta el desarrollo del aprendizaje del estudiante y su capacidad para hacer seguimiento de su propio progreso hacia las metas, demostrando confianza y habilidad para autorregularse. Sin embargo, el Ministerio de Educación (2022) menciona que en la prueba PISA 2018, más del 50% de los estudiantes peruanos que participaron (54,4% en Lectura, 60,3% en Matemática y 54,5% en Ciencias) obtuvieron resultados por debajo del nivel básico y esta dificultad se manifiesta también durante su preparación preuniversitaria.

A nivel local, Álvarez et al. (2020), evidenció que los estudiantes preuniversitarios presentan limitaciones en la regulación de sus Aprendizajes sobre los temas que requieren para postular a las universidades, en su estudio realizado sobre la situación académica de aspirantes a la Universidad Nacional Mayor de San Marcos (UNMSM) 2019II, en un simulacro al que participaron más de 15,965 postulantes, determinó que solo el 39.63% de respuestas fueron correctas mientras que el 35.22% fueron incorrectas y el 25.16% fueron en blanco o nulas, donde el 60% de repuestas no correctas muestra limitaciones académicas y de la regulación de su aprendizaje.

La presente investigación se desarrollará en una Academia Preuniversitaria Privada de Lima, que prepara estudiantes para postular y rendir exitosamente la evaluación de ingreso a la UNMSM, considerando los ciclos regulares Ciclo A y Ciclo B de una de sus sedes, siendo una de sus grandes preocupaciones la

Autorregulación de su Aprendizaje de sus estudiantes, debido a que no es suficiente con las clases recibidas, teniendo en cuenta que más del 50% provienen de escuelas estatales, con diversos niveles de conocimientos, lo que se ve reflejado en las notas de sus exámenes semanales, en el cumplimiento de sus tareas domiciliarias, entre otros, donde en muchos casos tienen dificultades para resolverlos. Se planifican las sesiones clase para abordar los temas desde lo más simple a lo complejo, con sílabos y materiales didácticos analizados y discutidos por las planas docentes, se dispone de una plataforma web con materiales, actividades y test en línea, haciendo que muchos estudiantes avancen desde su nivel real de desarrollo en su zona de próximo desarrollo hacia su zona de desarrollo potencial con apoyo del docente mediador, como lo sugiere Vigotsky (1978).

Por lo tanto, se formula como problema general lo siguiente: ¿Cómo influye Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?, de la misma forma, como problemas específicos se ha formulado lo siguiente: i) ¿Cómo influye Machine Learning en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?, ii) ¿Cómo influye Machine Learning en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023? y iii) ¿Cómo influye Machine Learning en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?

Esta investigación se sustenta en cuatro pilares fundamentales: la justificación práctica, la justificación epistemológica, la justificación metodológica y la justificación teórica. Epistemológicamente se justifica debido a que la razón fundamental de esta investigación fue la de producir conocimiento detallado, preciso y sólido acerca de los elementos que influyen en la autorregulación del aprendizaje, y evidenciar la influencia de la implementación de modelos Machine Learning en el ámbito educativo. Se justifica teóricamente debido a que presentó un aporte teórico relevante para la educación y la psicología educativa, al revisar y consolidar la teoría

existente mediante revistas indexadas relacionada a la integración de Machine Learning en el contexto educativo, y comprender cómo esta tecnología influye en la autorregulación del aprendizaje de los estudiantes, a partir de investigaciones previas con una base sólida como la de Zimmerman (2000) sobre la autorregulación del aprendizaje. Como justificación práctica, permitió que los estudiantes puedan conocer de forma más precisa su predicción de aprobar el examen de admisión a la universidad mediante el uso de una aplicación basada en Machine Learning y tomar las medidas necesarias sobre sus habilidades en la autorregulación de su aprendizaje. La predicción del rendimiento se ha transformado en un tema de investigación valioso en la optimización del método educativo y el proceso de adquisición de conocimiento (Nawang et al., 2021). Se justifica metodológicamente debido a que aportó un cuestionario para medir la autorregulación de estudiantes en el contexto peruano de la presente investigación, a partir de la adaptación de un cuestionario validado en otros contextos como lo menciona Bruna et al. (2017), con la finalidad de que pueda utilizarse en futuras investigaciones.

De acuerdo a lo expuesto, se planteó como objetivo principal lo siguiente: Determinar la influencia de Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, del mismo modo se establecen los objetivos específicos siguientes: i) Determinar la influencia de Machine Learning en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, ii) Determinar la influencia de Machine Learning en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023 y iii) Determinar la influencia de Machine Learning en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

De igual forma, se realizaron suposiciones acerca de los hallazgos de la presente investigación. La hipótesis general: Machine Learning influye significativamente en la autorregulación del aprendizaje de los estudiantes en una

academia preuniversitaria privada, Lima 2023, y se formulan las hipótesis específicas siguientes: i) Machine Learning influye significativamente en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, ii) Machine Learning influye significativamente en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, y iii) Machine Learning influye significativamente en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

## **II MARCO TEÓRICO**

## II. Marco Teórico.

Se consideraron como antecedentes los siguientes trabajos previos, a nivel internacional, Sáez et al. (2020), llevaron a cabo un estudio en dos escuelas públicas y una privada en Ibarra, Ecuador, cuya finalidad de estudio consistió en desarrollar y analizar las características psicométricas de una serie de escalas destinadas a medir las etapas o fases del proceso en el que los estudiantes regulan su autoaprendizaje. Se utilizó un diseño experimental con enfoque cuantitativo, concluyendo que se requieren cinco escalas con un total de 53 ítems para medir en estudiantes de secundaria los mecanismos de autorregulación del aprendizaje ecuatorianos, abarcando las tres fases del Aprendizaje Autorregulado; asimismo, que cada escala tiene adecuadas propiedades psicométricas y finalmente, que las escalas se ponen a disposición para medir el Aprendizaje Autorregulado en general o en determinados procesos.

Del mismo modo, Contreras et al. (2020), llevaron a cabo un estudio en una universidad de Colombia, cuya finalidad fue identificar el contexto óptimo para realizar pronósticos precisos sobre el rendimiento académico de los estudiantes de ingeniería. Para ello, utilizaron diferentes métodos que permitieron seleccionar las variables más relevantes para su determinación y desarrollar modelos mediante algoritmos de clasificación, incluyendo Perceptrón, SVC, árbol de decisión y KNN. Utilizando un enfoque cuantitativo y un diseño experimental, llegaron a la conclusión de que los factores que ejercen mayor influencia en el rendimiento académico son la edad, el género, el valor de matrícula y los puntajes. Asimismo, encontraron que el modelo Perceptrón resultó más preciso, con una exactitud del 66,4%, seguido del algoritmo Máquina de Vectores de Soporte (SVM), y finalmente sugieren superar el 90% de precisión teniendo en cuenta otros factores que también ejercen influencia en el desempeño académico.

De igual modo, De la Hoz et al. (2019), en su estudio desarrollaron una metodología basada en el Machine Learning para clasificar a los alumnos que participan en entornos virtuales de aprendizaje, con el propósito de encontrar la correlación existente entre la frecuencia de uso de la plataforma y el rendimiento



obtenido en los exámenes semestrales, a fin de establecer la posible influencia de la intensidad de uso en el desempeño académico de los alumnos. Se desarrolló un método para predecir si un estudiante independiente pertenecía a un determinado conglomerado. El estudio se basó en un enfoque cuantitativo utilizando con diseño no experimental y determinó que el método permitió formular criterios para analizar los procesos de transición de perfiles estudiantiles, basados en su desempeño previo, y prever si un estudiante independiente pertenecía a un conglomerado en particular, cuando se disponía de las variables utilizadas en la investigación.

De igual manera, en su investigación, Vera (2022) realizó un estudio en una universidad de Chile, con la finalidad de examinar el nivel de autorregulación de los estudiantes de una especialidad y la forma en que guarda correlación con el desempeño académico en las etapas específicas de planificación, supervisión y revisión, considerando sus diferencias en variables sociodemográficas. Se empleó una metodología cuantitativa de diseño no experimental para llevar a cabo el estudio. Se encontró que los estudiantes que planifican y supervisan su aprendizaje tendrían mejores resultados académicos y que los estudiantes de primeros ciclos varones tendrían mayores dificultades en autorregular su aprendizaje porque suelen no preguntar o pedir ayuda, el investigador sugiere emplear estrategias cognitivas y autocontrol con el fin de supervisar y evaluar sus procesos de aprendizaje.

Del mismo modo, Bruna et al. (2017), realizó un estudio cuantitativo a 780 de primer año de diversas especialidades de una universidad de Chile para evaluar psicométricamente el cuestionario Inventario de Procesos de Autorregulación del Aprendizaje, concluyendo su validez y confiabilidad, además encontró medias para las dimensiones de autorregulación del aprendizaje de 3.46 en planificación, 3.45 en ejecución y 3.92 en evaluación, y considera estadísticos descriptivos adecuados.

Asimismo, Zambrano et al. (2020), en su estudio cuantitativo de diseño no experimental a estudiantes de primer año de pedagogía de instituciones municipales y privadas de Chile, encontró que la dimensión que obtuvo mayor valoración fue el de hábitos inadecuados de regulación de aprendizaje, principalmente en las instituciones municipales, mientras que sus otras dimensiones

mostraron medias con bajas valoraciones, en conclusión se obtuvieron bajos resultados en los estudiantes sobre sus técnicas de autorregulación del proceso de aprendizaje.

De modo similar, Paredes y Moreta (2020), en su estudio cuantitativo y correlacional a 222 estudiantes universitarios de Ecuador, buscan encontrar la existencia de relaciones entre la autorregulación del aprendizaje y las actitudes investigativas, y concluyó que la dimensión de planificación en la autorregulación del aprendizaje se encuentra estrechamente relacionada con las actitudes investigativas de manera más significativa y a su vez la dimensión cognitiva de las actitudes investigativas sobre la autorregulación del aprendizaje, resultando la media de la dimensión evaluación de la autorregulación del aprendizaje similar a la media de ejecución y ligeramente superior a la media de planificación.

Finalmente, Panadero et al. (2020), en su investigación llevó a cabo un estudio en cuatro universidades diferentes de Madrid, España, siendo el objetivo desarrollar y validar un cuestionario que permita medir la autorregulación del aprendizaje de los estudiantes, enfocado en el uso realista de estrategias de aprendizaje. Utilizando un enfoque de naturaleza cuantitativa mediante un diseño no experimental para validar el instrumento, el investigador concluyó que el nuevo cuestionario se basa en las estrategias que los estudiantes utilizan en su día a día, prescindiendo de una dependencia directa de un modelo teórico de aprendizaje autorregulado de amplio alcance. Además, se creó un cuestionario de Estrategias de aprendizaje profundo que demostró tener validez interna y externa, y se propusieron escalas para evaluar las estrategias fundamentales de autorregulación del aprendizaje, como las estrategias de resumen y de elaboración visual, así como las estrategias de profundo procesamiento de la información y de métodos de estudio basados en la elaboración social.

Por otro lado, en investigaciones nacionales, tenemos a Caselli (2021), en su estudio realizado en la Universidad Nacional del Santa (UNS), propuso la predicción multiclase para potenciar el seguimiento académico de los alumnos de Ingeniería en la UNS. Se realizó un estudio cuasi experimental con una metodología

cuantitativa, en el cual se determinó que la implementación del Machine Learning puede optimizar el seguimiento del desempeño académico de los estudiantes entre un 28.89% y un 58.47%. A través de la utilización de una red neuronal de perceptrón multicapa con capa de salida softmax y el aprendizaje profundo, se logró diseñar un modelo predictivo efectivo. Además, se identificó con precisión del 81.73% en el conjunto de prueba y 98.97% en el conjunto de entrenamiento a los estudiantes con un alto riesgo de abandonar los estudios y no obtener el diploma correspondiente. En última instancia, se determinó que las variables académicas, como el número de semestres y los promedios, así como las demográficas, como la posesión de un teléfono celular y el acceso a internet, tenían una mayor influencia en la predicción.

Del mismo modo, Chavez (2022) se propuso evaluar el efecto del sistema web que utiliza Machine Learning como base tecnológica en la motivación del aprendizaje de estudiantes de nivel secundario. Se utilizó un enfoque metodológico pre experimental y cuantitativo. Los resultados demostraron que la puesta en marcha del sistema web fundamentado en Aprendizaje Automático (Machine Learning), contribuyó a un aumento del 16.75% en el aprendizaje autónomo de los estudiantes de secundaria. A pesar de que la motivación no mejoró significativamente, se encontró una mejora del 15.54% en la elaboración de métodos de estudio, un aumento del 17.9% en la cognición y un incremento del 20.85% en la conducta en análisis de técnicas y procedimientos.

De acuerdo con la investigación de Vega (2019) llevada a cabo en la Universidad Ricardo Palma (URP), con el fin de realizar predicciones utilizando algoritmos de Machine Learning que identifiquen de manera temprana a los estudiantes con alta probabilidad de tener un rendimiento académico deficiente en cualquiera de los cursos, se empleó una metodología cuantitativa de diseño no experimental. Como resultado, se llegó a la conclusión de que el algoritmo de Redes Neuronales Artificiales (RNA) obtuvo una alta precisión al predecir el número de estudiantes que aprobaron y reprobaron cada curso, mostrando indicadores de exactitud muy favorables en cada uno de ellos. Asimismo, tanto el modelo de aprendizaje automático Gradient Boosting Machine (GBM) como el modelo de

XGBoosting lograron predecir con gran exactitud la cantidad de estudiantes que aprobarían y reprobarían en los cursos.

Además, Svagelj y Vallejos (2021) en su trabajo realizado en tres colegios de Lima, cuya finalidad de la investigación consistió en encontrar la relación existente entre el desempeño académico en estudiantes y la autorregulación del aprendizaje, a través del diseño no experimental de naturaleza cuantitativa. Concluyendo que el cuestionario Motivated Strategies for Learning Questionnaire (MSLQ) de De Groot y Pintrich es un instrumento de evaluación diseñado para medir la capacidad de autorregular el proceso de aprendizaje en Lima Metropolitana para estudiantes de secundaria, pues posee propiedades psicométricas adecuadas para su aplicación en estudios del ámbito psicológico y la educativo, presenta evidencia de validez de contenido, ya que se ha establecido una fuerte correlación positiva entre el rendimiento académico en estudiantes de secundaria y la autorregulación del aprendizaje en Lima, así también correlación entre el rendimiento académico y la autoeficacia.

Así también, Vélez et al. (2022) en su trabajo de enfoque cuantitativo y diseño no experimental, realizado con alumnos de quinto año de secundaria de una escuela de Piura, encontró que los estudiantes se encontraban en un nivel medio de 45% y bajo de 33.1%, respecto a la autorregulación de su aprendizaje, específicamente bajo en planificación con 52.6%, contexto 63,9% y evaluación 44%, mientras que medio en cognición 51% y motivación 45,9%, y propone un programa de aprendizaje basado en proyectos .

Por último, Muñoz (2021), en su investigación realizada en tres universidades privadas de Lima cuyo objetivo consistió en establecer una relación entre el rendimiento académico y la autorregulación del aprendizaje de los alumnos universitarios; utilizando la metodología descriptiva correlacional con diseño no experimental concluyo que existe relación entre sus variables y específicamente que la autorregulación del aprendizaje influye positivamente en el rendimiento académico.

La investigación que se presenta se sustenta en una base teórica que incluye la Teoría General de Sistemas. Según Maldonado (2017), la Teoría General de Sistemas, también llamada Teoría de Sistemas o Ciencia de Sistemas, es considerada como una de las teorías más relevantes en la actualidad. Se ha adoptado en distintos ámbitos de la sociedad, incluyendo el Gobierno, las instituciones universitarias y el sector privado. Además, ha dado lugar al desarrollo de diversas herramientas y enfoques sistémicos que reflejan las últimas tendencias y avances del pensamiento actual. Del mismo modo, De la Peña & Velázquez (2018) reconoce que la Teoría General de Sistemas es un método y herramienta útiles para analizar y sintetizar la realidad objetiva, permitiendo una representación funcional y estructural que abarca desde una perspectiva general hasta la singularidad de los fenómenos y objetos analizados. Asimismo, su aplicación implica la exploración en un conjunto de categorías inherentes a la teoría, las cuales son obligatorias para la argumentación y explicación en la investigación. Asimismo, Ossa (2017) menciona que la Teoría General de Sistemas se entiende como una combinación de conocimientos que busca considerar globalmente los fenómenos que estudia, a diferencia del enfoque tradicional que se enfoca en estudiar las partes para entender el todo. Aunque no es una teoría científica en sí misma, se trata de un enfoque que involucra una visión más amplia e interrelacionada de los diferentes aspectos que determinan un fenómeno complejo, y que requiere la interdisciplinariedad. De la misma manera, Peralta (2016) menciona que la Teoría General de Sistemas tiene como objetivo explicar los fenómenos de la realidad a través del estudio de los sistemas como modelo de organización, que es aplicable a diferentes enfoques. Su enfoque es integrador y holístico, donde las relaciones y conjuntos que emergen a partir de ellas son lo más importante.

Los enfoques conceptuales de Machine Learning y Autorregulación del Aprendizaje se obtienen a partir de artículos de revistas indexadas para obtener una amplia gama de información sobre las variables que se investigarán.

Referente a la variable independiente Machine Learning, Porcelli (2020) define Machine Learning como un conjunto de técnicas de aprendizaje automático utilizadas por las máquinas para aprender de datos proporcionados por los matemáticos, con el fin de identificar y clasificar información mediante el uso de algoritmos, que permitan que las máquinas sean entrenadas con grandes cantidades de datos predefinidos y categorizados por humanos para aprender a ejecutar diferentes tareas de forma autónoma, a medida que se enfrentan a información nueva, las máquinas se ajustan basándose en cálculos previos y se modelan los patrones para proporcionar respuestas fiables, sin necesidad de programar reglas específicas. Por su parte, Mamani (2022) menciona que el Machine Learning es un área dentro de la inteligencia artificial que se apoya en la informática científica, las matemáticas y la estadística para resolver problemas mediante el uso de técnicas automatizadas de clasificación, regresión y agrupamiento. Asimismo, Pedrero et al. (2021) ofrecen una definición de Machine Learning como una serie de estrategias analíticas que utilizan algoritmos para extraer información de los datos, con la finalidad de explicar, clasificar o predecir información. Los algoritmos de Machine Learning pueden ser clasificados en tres tipos: supervisados, no supervisados y parcialmente supervisados. Los algoritmos no supervisados tienen la capacidad de extraer, clasificar y reducir la dimensionalidad de los datos, mientras que los algoritmos supervisados se utilizan para la predicción. Los algoritmos parcialmente supervisados combinan características, es decir el Machine Learning utiliza los datos de entrada para aprender patrones y relaciones, y utiliza estos patrones para realizar tareas específicas de forma autónoma. Por otro lado, Ma et al. (2023) define Machine Learning como parte de la inteligencia artificial que involucra el empleo de algoritmos y de modelos estadísticos para permitir a una máquina aprender y realizar tareas específicas sin una programación explícita, donde las relaciones entre los datos se aprenden a través del procesamiento de vastos conjuntos de datos que permiten reconocer patrones y tendencias, también define el Deep Learning o Aprendizaje profundo como una extensión del Machine Learning que emplea redes neuronales profundas para adquirir y comprender características

complejas y no lineales de los datos de entrada y salida, permitiendo que la máquina realice tareas más sofisticadas y precisas. En ese sentido, Siche R. y Siche N. (2023) mencionan que Chat GPT es un ejemplo de cómo el Machine Learning se relaciona con los seres humanos, ya que se trata de un programa avanzado de aprendizaje profundo que cuenta con la habilidad de analizar y procesar grandes volúmenes de datos. Asimismo, Baviera (2017) define Machine Learning como un tipo de programa informático que utiliza algoritmos estadísticos y algebraicos para aprender de los datos de entrada y extraer patrones de comportamiento, en lugar de estar programado para responder de una determinada forma, permitiendo que la máquina pueda evaluar nuevas entradas y realizar predicciones basadas en el conocimiento adquirido, con el objetivo de entrenar al modelo para que sea capaz de realizar tareas de forma autónoma y adaptarse a nuevos datos, en lugar de seguir reglas programadas por humanos. Finalmente, Vite (2020) define Machine Learning como un conjunto de técnicas que permiten que una máquina aprenda a partir de un conjunto de datos sin ser programada explícitamente, utilizando diferentes algoritmos para analizar y evaluar datos y determinar si el problema es de regresión o de clasificación, con el objetivo de entrenar a la máquina para que sea capaz de predecir nuevos datos y mejorar su capacidad de tomar decisiones precisas y autónomas en el futuro.

En esta investigación, se empleó la metodología Scrum para desarrollar la aplicación en Machine Learning. Scrum fue elegido como enfoque de gestión y organización del proyecto, permitiendo la adaptación a los cambios y cumplir con los objetivos establecidos, concordante con los beneficios de Scrum mencionados por Timkyw et al (2020). Se realizaron los análisis de requisitos, planificación de sprints y reuniones diarias para dar seguimiento al progreso. El desarrollo se realizó de manera iterativa, con pruebas frecuentes y ajustes según fuera necesario. Se establecieron mecanismos de retroalimentación y colaboración con los usuarios finales. En general, la metodología Scrum permitió la entrega de un producto de excelente calidad que satisfizo las necesidades de los usuarios finales de manera efectiva en el ámbito de Machine Learning.

Referente a la variable dependiente Autorregulación del aprendizaje, Sáez et al. (2021) define la autorregulación del aprendizaje como un sistema cognitivo-motivacional que implica un enfoque holístico y se refiere al desarrollo integral de los estudiantes, abarcando habilidades, conocimientos, motivaciones, creencias y comportamientos, y esto se aplica durante sus experiencias académicas. El aprendizaje autorregulado implica un proceso cíclico que se divide en tres fases: disposición, desempeño y evaluación, y abarca desde la planificación de una tarea hasta la persistencia frente a la frustración y el ajuste de estrategias. Aunque existen varios modelos, se llega a un consenso al conceptualizarse como un proceso cíclico. Esto concuerda con Zimmerman (2000), que define la autorregulación del aprendizaje como un proceso en el que el individuo utiliza sus emociones, pensamientos y acciones, de manera cíclica para alcanzar sus objetivos personales, por medio de un conjunto de enfoques o métodos que el estudiante utiliza para controlar, supervisar y ajustar su propio proceso de adquisición de conocimientos. Por su parte, Ganda y Boruchovitch (2018) define como un proceso de autorreflexión y acción en que el estudiante se autoevalúa, planifica y controla su propio aprendizaje, lo que se traduce en una mayor implicación en sus estudios, mejor retención de la información y un desempeño académico más satisfactorio. En ese sentido, Panadero (2017) define la autorregulación del aprendizaje como un concepto amplio que abarca diferentes aspectos relacionados con el aprendizaje, como son los cognitivos, metacognitivos, conductuales, motivacionales y emocionales/afectivos, donde estos aspectos influyen en la forma en que los estudiantes estructuran, monitorean y evalúan su propio aprendizaje, lo que se traduce en un enfoque integral y holístico que toma en cuenta diversas variables que afectan el proceso de aprendizaje, tales como la autoeficacia, la volición y las estrategias cognitivas, finalmente Cunill y Curbelo (2021) afirma que el proceso de aprendizaje autorregulado es consciente e intencional, y requiere que el estudiante tome medidas activas, con un propósito definido y un conocimiento de su propia percepción, donde la motivación desempeña un papel significativo en la influencia en este proceso.



La variable dependiente Autorregulación del aprendizaje es un proceso cíclico que comprende tres dimensiones: La planificación, la ejecución y la evaluación, en base al modelo de Zimmerman (2000).

La primera dimensión, Planificación, de la variable Autorregulación del aprendizaje, es definida por Sáez et al. (2020) como la fase de disposición, consistente en una serie de actividades muy importantes para llevar a cabo el análisis de tareas, establecer objetivos y planificar acciones. En ese sentido, Panadero (2017) define Planificación como la fase en que los estudiantes llevan a cabo un análisis de la tarea asignada, establecen objetivos claros y detallados, planifican estrategias para alcanzarlos y, al mismo tiempo, una serie de creencias motivacionales los impulsa y afecta la activación de sus estrategias de aprendizaje. Del mismo modo, Bruna et al. (2017) define Planificación como la fase de Preparación o disposición, que sucede antes de la actividad de aprendizaje, y consta del Análisis de la Tarea, consistente en establecer metas realizando una estratégica planificación, y Automotivación que se basa en las percepciones de los estudiantes con respecto al proceso de aprendizaje. Así mismo, Moreno et al. (2021) define Planificación como la primera operación, planeación o forethought, que se realiza antes de comenzar una tarea específica, se utiliza una preparación que incluye un esquema general y orientador que establece las estrategias y herramientas a utilizar para lograr los objetivos, así como las expectativas en cuanto a la ejecución completa de la tarea. Finalmente, Zimmerman (2000) define Planificación como la etapa previa de llevar a cabo una tarea, se desarrolla la fase de planificación (forethought phase), donde se analiza detalladamente la tarea y se activan las creencias relacionadas con la automotivación.

La segunda dimensión, Ejecución, de la variable Autorregulación del aprendizaje, es definida por Sáez et al. (2020) como la fase de ejecución o desempeño, en la cual se realiza la actividad asignada y se finaliza el trabajo mientras se supervisa el progreso del rendimiento. Asimismo, Panadero (2017) define la Ejecución como la fase de desempeño, que es la etapa en la que los estudiantes llevan a cabo la tarea, al mismo tiempo que supervisan su progreso y

emplean diversas estrategias de autocontrol para mantenerse mentalmente involucrados y motivados hasta su finalización. Del mismo modo, Bruna et al. (2017), define la Ejecución como la fase de desempeño, que se desarrolla durante la ejecución conductual de una tarea. Esta fase implica dos procesos principales: el Autocontrol que hace referencia a la utilización de técnicas y tácticas concretas que se eligieron previamente durante la etapa de disposición o planificación, y la auto observación referida a la capacidad de asumir conscientemente el proceso de estudio mientras se está llevando a cabo. Así también, Moreno et al. (2021) define la Ejecución como la segunda operación, denominada supervisión, control o performance, la cual se emplea durante el desarrollo de una actividad y está relacionada con la observación constante del progreso, ejecución y estructuración de dicha actividad, así como con la evaluación de la consecución de las metas establecidas inicialmente. Finalmente, Zimmerman (2000) define la Ejecución como la fase de Performance o Control Volitivo que tiene lugar una vez iniciada la tarea y durante su realización. En esta fase, se destacan el autocontrol y la autoobservación, los cuales están dirigidos a mantener la concentración y el esfuerzo durante la ejecución de las acciones requeridas para alcanzar los objetivos establecidos para corregir los errores que se presenten.

La tercera dimensión de la Autorregulación del aprendizaje, Evaluación, es definida por Sáez et al. (2020) como la fase de evaluación que incluye la evaluación y la reflexión de los resultados. En ese sentido, Panadero (2017) define la Evaluación como fase de autorreflexión donde los estudiantes analizan cómo han llevado a cabo la tarea, estableciendo atribuciones sobre su éxito o fracaso. Estas atribuciones pueden generar respuestas de los estudiantes que podrían tener un impacto positivo o negativo en la forma en que abordan tareas similares en desempeños posteriores. Así también, Bruna et al. (2017) define la Evaluación como la fase de Autorreflexión, que se compone de dos procesos: el autojuzgamiento y la autoreacción. En el proceso de autojuzgamiento, el estudiante evalúa su rendimiento en relación con criterios específicos y realiza inferencias sobre las causas de sus éxitos y errores. En cuanto a la autoreacción, consta de dos subprocesos: la autoafirmación y las emociones positivas, así como las respuestas

defensivas o adaptativas. Del mismo modo, Moreno et al. (2021) define la Evaluación como la tercera operación, revisión o self-reflection, se emplea al concluir la tarea y se refiere a una evaluación de la ejecución global del proyecto, donde el estudiante verifica la eficacia de los recursos de aprendizaje empleados mediante un juicio de valor. Finalmente, Zimmerman (2000) define la evaluación como la fase de autorreflexión (Self-reflection phase) y establece que se presenta al finalizar la tarea, y en ella se aplican estrategias de auto juicio y autor reacción, sugiriendo que cuanto mayor sea el compromiso de los estudiantes con las actividades de autorreflexión en su proceso de aprendizaje, mayores serán sus niveles de desempeño.

Con respecto a los indicadores, el indicador de la primera dimensión Planificación, de acuerdo con Bruna et al. (2017), es Planificación, que evalúa los aspectos de preparación definidos para dicha dimensión, basado en Zimmerman (2000) y en Rosário et al. (2007) como el análisis de la tarea y las creencias de automotivación, el indicador de la segunda dimensión Ejecución, de acuerdo con Bruna et al. (2017), es Ejecución, que evalúa los aspectos de desempeño definidos para dicha dimensión, basado en Zimmerman (2000) y en Rosário et al. (2007) como el autocontrol y la autoobservación y finalmente, el indicador de la tercera dimensión Evaluación, de acuerdo con Bruna et al. (2017), es Evaluación, que evalúa los aspectos de autorreflexión definidos para dicha dimensión, basado en Zimmerman (2000) y en Rosário et al. (2007) como el autojuzgamiento y autoreacción.

## **III METODOLOGÍA**

### **III. Metodología**

#### **3.1. Tipo y Diseño de Investigación**

##### **3.1.1. Tipo de Investigación**

La investigación presente es de tipo aplicada y se centra en la generación de conocimientos que tienen una aplicación directa en la sociedad o en el ámbito productivo a corto plazo, según la definición de Lozada (2014). Esta clase de investigación es altamente valorada debido a su capacidad para aportar soluciones prácticas.

En el estudio se adoptó un enfoque cuantitativo, ya que se centró en variables que pueden ser objetivamente medidas, y se emplearon técnicas estadísticas para recopilar, procesar, analizar e interpretar los datos, siguiendo un método hipotético-deductivo, en relación a lo definido por Sánchez (2019).

##### **3.1.2. Diseño de Investigación**

En este estudio, se utilizó el diseño pre-experimental como enfoque metodológico para la investigación llevada a cabo, que contempla el tomado de un pre-test y post-test. Según Hernández (2014), la investigación pre-experimental de preprueba y posprueba con un solo grupo, es un tipo de estudio en el que se realiza una evaluación inicial antes de aplicar el tratamiento o estímulo experimental al grupo, seguida de la aplicación del tratamiento y finalmente se tomó una prueba tras el estímulo, con el objetivo de establecer un punto de inicio o de línea base para determinar el nivel del grupo antes de la aplicación del estímulo, lo que permite hacer un seguimiento del grupo a lo largo del estudio. De este modo, es posible analizar la repercusión del tratamiento experimental y obtener conclusiones más precisas sobre su eficacia.

El diagrama del diseño pre-experimental para esta investigación es el siguiente:

$$G: O_1 \rightarrow X \rightarrow O_2$$

Donde:

G: Grupo de estudiantes.

O<sub>1</sub>: Preprueba.

X: Tratamiento o estímulo (Machine Learning).

O<sub>2</sub>: Posprueba.

### 3.2. Variables y Operacionalización

La conceptualización de la variable independiente Machine Learning, de acuerdo con Ma et al. (2023), establece que el Aprendizaje Automático forma parte de la Inteligencia Artificial basada en la utilización de modelos matemáticos y algoritmos para habilitar a las computadoras a adquirir aprendizajes y mejorar en la realización de tareas específicas a través del análisis de datos y patrones, como la clasificación y predicción, en lugar de ser programado explícitamente, el sistema aprende de manera autónoma a medida que se le proporciona más información y se ajusta a los resultados obtenidos.

Asimismo, Machine Learning, la variable independiente es definida operacionalmente como la tecnología de inteligencia artificial que permitirá predecir el resultado que obtendrá el estudiante en el examen de admisión a partir de su récord académico y las notas de ingresantes del último examen de la UNMSM y generar respuestas y textos coherentes con los resultados, siendo una variable cuantitativa continua. Según Castro (2019), una variable continua se refiere a un atributo que puede asumir un número ilimitado de valores dentro de un rango específico. Estas variables están asociadas con una unidad de medida y se representan en el plano cartesiano en el eje x, también conocidas como variables intervalares.

Como definición conceptual de la variable dependiente Autorregulación del Aprendizaje, Sáez et al. (2021), la autorregulación del aprendizaje es un sistema cognitivo-motivacional que tiene un enfoque holístico y está relacionado con el desarrollo integral de los estudiantes durante sus experiencias académicas. Este proceso abarca una amplia gama de habilidades, conocimientos, motivaciones, creencias y comportamientos, mediante un proceso cíclico que se divide en tres fases como son planificación/disposición, ejecución/desempeño y evaluación, siendo concordante con el modelo propuesto por Zimmerman (2000) y en este estudio es una variable cuantitativa continua.

Asimismo, como definición operacional la autorregulación del aprendizaje es el conjunto de habilidades, estrategias y competencias que los estudiantes adquieren para supervisar y orientar de manera autónoma su proceso de aprendizaje. Implica que los estudiantes sean conscientes de sus propias fortalezas y debilidades, establezcan metas claras, planifiquen su estudio, monitoreen su progreso, regulen sus emociones y utilicen estrategias efectivas para lograr un aprendizaje óptimo, lo que puede conducir a mejores resultados académicos y preparación para el ingreso a la universidad. Por consiguiente, se operacionaliza la variable del siguiente modo, su primera dimensión Planificación, considera el indicador planificación formado por los ítems P1, P10 y P12; su segunda dimensión Ejecución, considera el indicador ejecución formado por los ítems P3, P5, P8 y P6; y su tercera dimensión Evaluación, considera el indicador evaluación formado por los ítems P2, P4, P7, P9 y P11, siendo medidos a través del cuestionario, empleando un nivel de medida tipo Likert en una escala ordinal, con 5 categorías: 1,2,3,4,5.

### 3.3. Población, Muestra y Muestreo

#### 3.3.1. Población

En la presente investigación, la población se compone de 1322 estudiantes, pertenecientes a los ciclos académicos A (Anual) y B (Semestral) que preparan postulantes a la UNMSM. Para Casteel et al. (2021) La población de interés para el estudio se encuentra constituida por los individuos, díadas, grupos, organizaciones u otras entidades que se busca comprender y a quienes o a las cuales los resultados del estudio podrían generalizarse o transferirse, siendo el grupo principal sobre el cual se centra la investigación.

**Tabla 1**

*Tabla de población*

<b>Población</b>	<b>Cantidad</b>
Estudiantes del CICLO A	982
Estudiantes del CICLO B	340
Total	1322

#### 3.3.2. Muestra

En este estudio de investigación se utilizará una muestra compuesta por 298 estudiantes. La muestra en una investigación se refiere a un grupo seleccionado de forma representativa para inferir y generalizar los resultados observados en ella hacia una población más amplia. Una muestra es considerada representativa cuando ha sido seleccionada al azar, lo que implica que todos los sujetos de la población de interés tuvieron igual oportunidad de ser seleccionados para formar parte del estudio, sin importar su nivel de interés. Además, en el caso de muestras estratificadas, se divide la población en dos o más grupos homogéneos, y la muestra se obtiene reclutando participantes de cada estrato, en este enfoque, el investigador puede emplear un método de muestreo aleatorio simple dentro de cada estrato para seleccionar a los participantes (Setia, 2016) . Se utilizó la



siguiente fórmula para estimar la muestra a partir de una población de 1322 estudiantes.

$$n = \frac{N * Z_{\alpha}^2 * p * q}{\varepsilon^2 * (N - 1) + Z_{\alpha}^2 * p * q}$$

Donde:

$Z$  : Valor estadístico para una confianza de  $(1-\alpha)$

$p$  : Probabilidad de éxito del evento.

$q$  : Probabilidad de fracaso del evento. ( $q = 1 - p$ )

$\varepsilon$  : Tolerancia de error

$N$  : Tamaño de la población.

### 3.3.3. Muestreo

En la presente investigación, la muestra fue seleccionada mediante el método de muestreo probabilístico estratificado proporcional. El procedimiento para elegir una muestra representativa de una población se conoce como muestreo, y el enfoque de muestreo estratificado proporcional implica asignar una cantidad específica de elementos a diferentes estratos de la población objetivo de acuerdo con la representación proporcional de cada estrato (Casteel & Bridier, 2021). El proceso de muestreo se caracteriza por la interacción entre la población y la muestra, lo que establece una conexión entre las discusiones teóricas y metodológicas que se fundamentan en el ciclo de desarrollo de la teoría.(Cash et al., 2022)

**Tabla 2**

*Tabla de muestra estratificada proporcional*

	<b>Población</b>	<b>Proporción</b>	<b>Muestra</b>
Estudiantes del CICLO A	982	74.28%	221
Estudiantes del CICLO B	340	25.72%	77
Total	1322	100%	298

### **3.3.4. Unidad de Análisis**

En esta investigación, la unidad de análisis es estudiante individualmente dentro de la muestra. Cada estudiante constituye una entidad independiente que será investigada y analizada en el estudio.

### **3.4. Técnicas e Instrumentos de Recolección de Datos**

En este estudio, se optó por la técnica de encuesta para recopilar los datos, lo que permitió emplear el instrumento apropiado e hizo más fácil obtener la información necesaria para alcanzar el objetivo de la investigación. Según Taherdoost (2021), una encuesta se define como un método adecuado para determinar los sentimientos, opiniones y pensamientos de un grupo de personas, pudiendo ser amplio como específico, obteniendo un gran volumen de datos a través de diferentes medios, como llamadas telefónicas, correos electrónicos o entrevistas en persona o recopilando datos mediante encuestas autoadministradas o a través de la intervención de un entrevistador.

En calidad de instrumento para recolectar de datos se consideró utilizar un cuestionario de 12 ítems, basado en la escala de Likert de cinco categorías como herramienta para recopilar los datos, el cual se administró en línea a los estudiantes mediante el uso de Google Forms. Para el procesamiento, recopilación e interpretación de los datos, se empleó el programa de análisis SPSS. Según Clark & Watson (2019) una de las dos formas de respuesta predominantes es el uso de escalas de calificación tipo Likert, que constan de tres o más opciones de respuesta.

En cuanto a la validación del instrumento, se realizó una evaluación por tres expertos con formación de doctorado o maestría en el área temática de la investigación. Se valora la claridad, coherencia y relevancia de los aspectos planteados en el instrumento con respecto a las dimensiones especificadas. Según Hernández et al. (2014), una herramienta se considera válida si logra capturar de manera precisa y exacta lo que tiene la intención de medir.

**Tabla 3***Validez del Instrumento para recolectar los datos*

<b>DNI</b>	<b>Experto</b>	<b>Claridad</b>	<b>Coherencia</b>	<b>Relevancia</b>
07146324	Dr. Laberiano Matías Andrade Arenas	Alto nivel	Alto nivel	Alto nivel
10692220	Mg. Luis Alfredo Romero Untiveros	Alto nivel	Alto nivel	Alto nivel
44147992	Mg. Alan Leoncio Fierro Barriales	Alto nivel	Alto nivel	Alto nivel

Con respecto a la determinación de la fiabilidad del instrumento, se empleó el test denominado Coeficiente Alfa de Cronbach. Dentro de los indicadores de confiabilidad de coherencia interna, el coeficiente de confiabilidad de Cronbach se destaca como uno de los índices más ampliamente empleados, con más de 250.000 aciertos en la base de datos Scholar de Google (Sideridis et al., 2018). En la tabla 4 se muestran los rangos para interpretar el alfa de Cronbach (Hernández & Pascual Barrera, 2018; George & Mallery, 2003).

**Tabla 4***Rango alfa de Cronbach*

<b>Rango</b>	<b>Magnitud</b>
Mayor que 0.90	Excelente
0.80 a 0.90	Bueno
0.70 a 0.79	Aceptable
0.60 a 0.69	Cuestionable
0.50 a 0.59	Pobre
Menor que 0.50	Inaceptable

Con respecto a la evaluación de la confiabilidad del cuestionario “Inventario de Procesos de Autorregulación del Aprendizaje” empleado en este estudio, tenemos el siguiente resultado:

**Tabla 5**

*Análisis de fiabilidad*

<b>Alfa de Cronbach</b>	<b>Alfa de Cronbach basada en elementos estandarizados</b>	<b>N de elementos</b>	<b>N de encuestados</b>
0,871	0,872	12	298

*Fuente:* SPSS Statistics v 25

El instrumento consta de 12 preguntas y se obtuvo un coeficiente de 0.871, y según la tabla 4, su calidad es considerada "Bueno". Por lo tanto, se puede concluir que el instrumento se considera confiable.

### **3.5. Procedimientos**

Se ejecutaron los trámites o procesos correspondientes para llevar a cabo la investigación requerida. Se informó a los estudiantes seleccionados sobre el propósito de la investigación. Antes de administrar los cuestionarios, se coordinó su consentimiento informado. Se realizó el pre-test previo a la intervención donde se evaluó el estado inicial y estableció una referencia para luego comparar los resultados. Se brindó acceso a los estudiantes de la muestra un programa web basado en Machine Learning durante un período determinado, que cuenta con un coeficiente de determinación  $r^2$  score del 73.3%, es decir, de precisión en la predicción de resultados. Posteriormente, se aplicó el post-test haciendo uso del mismo cuestionario utilizado en el pre-test. Los datos recolectados se analizaron mediante el software SPSS para realizar análisis estadísticos, como la obtención del coeficiente alfa de Cronbach, que evalúa la coherencia interna de las escalas de medición utilizadas en el cuestionario.

### **3.6. Método de Análisis de Datos**

Con la finalidad de analizar los datos recolectados, se realizaron varias acciones, como asignación de valores numéricos a las respuestas proporcionadas en la escala Likert, verificar la consistencia de los datos y eliminar valores atípicos o faltantes. Luego, se efectuó un análisis descriptivo para examinar los atributos fundamentales de las variables, incluyendo métricas como la desviación estándar, la media, el rango, así como la distribución de las respuestas en la escala Likert y un proceso de baremación considerando percentiles con resultados en niveles de alto, medio y bajo. Esto permitió obtener una visión general de los datos y comprender la tendencia general de las respuestas. Además, se evaluó la normalidad de los datos con la prueba de Kolmogorov-Smirnov. Este análisis contrastó la distribución empírica de los datos con la distribución teórica esperada, que en este caso sería la distribución normal. Realizando una comparación de respuestas entre el pre-test y el post-test, luego de una intervención en el mismo grupo, se empleó la prueba de Wilcoxon, la cual no necesita que tengan una distribución normal, como ocurrió en este caso. En cuanto al software utilizado para el tratamiento y la interpretación de los datos, se empleó el programa SPSS (Statistical Package for the Social Sciences) debido a su capacidad para realizar estas tareas, incluyendo la etapa de análisis de datos, análisis descriptivo y la aplicación de pruebas estadísticas, como la prueba de Wilcoxon.

### **3.7. Aspectos Éticos**

Durante el desarrollo de este trabajo de investigación se ha prestado especial atención al respeto del derecho de propiedad intelectual, así como de cualquier fuente de información utilizada. Se han empleado únicamente aquellas informaciones necesarias proporcionadas por el departamento de Tecnologías de la Información de la institución, garantizando su confidencialidad y limitando su uso al marco del presente proyecto. Todo el contenido de la investigación es auténtico y ha sido verificado por el sistema Turnitin para garantizar su autenticidad, siguiendo los parámetros

establecidos en el formato APA en su séptima edición para las citas y referencias bibliográficas; cumpliendo con los lineamientos establecidos en la Resolución de Vicerrectorado RVI N°062-2023-VI-UCV Aprueba Guía de elaboración de trabajos conducentes a grados y títulos y RVI N°066-2023-VI-UCV Aprueba directiva para investigación formativa, aplicable a partir 2023-1.

## **IV RESULTADOS**

## IV. Resultados

La finalidad del presente trabajo de investigación es determinar la influencia de Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, a través de un diseño pre-experimental realizando un pre-test y un post-test sobre la autorregulación del aprendizaje, luego de exponer a los estudiantes al uso de una aplicación informática basada en Machine Learning.

### 4.1. Análisis Descriptivo

Las medidas descriptivas obtenidas de la Planificación, correspondiente a la primera dimensión de la variable dependiente Autorregulación del Aprendizaje se muestra a continuación:

**Tabla 6**

*Tabla descriptiva del indicador Planificación*

	N	Mínimo	Máximo	Media	Desviación
Pre-Test	298	1	3	1.96	0.799
Post-Test	298	1	3	2.15	0.803


*Fuente:* Propia elaboración mediante el programa SPSS v.25.

Interpretando la información de la tabla 5, se observa que la media de las puntuaciones sobre el indicador Planificación de la Autorregulación del aprendizaje obtenidas en el pre-test fue de 1.96 y la media en el post-test fue de 2.15, lo que representa un aumento del 9.69% como se aprecia en la Figura 2. Del pre-test la desviación estándar es de 0.799 y del post-test es de 0.803, siendo muy similares y representan la dispersión de las puntuaciones alrededor de la media en cada prueba. Se encuestó a 298 estudiantes. En ambos test, los valores mínimos y máximos fueron de 1 y 3 respectivamente, proporcionando información sobre el rango de variabilidad de las puntuaciones y los valores obtenidos por los estudiantes en cada prueba.



**Figura 1**


*Comparativo Pre-test Post-test - Planificación*



*Fuente: Propia elaboración*

**Figura 2:**

*Porcentaje aumento en Planificación*



*Fuente: Propia elaboración*

Las medidas descriptivas obtenidas de la Ejecución, correspondiente a la dimensión segunda de la variable dependiente Autorregulación del Aprendizaje se muestra a continuación:

**Tabla 7**

*Tabla descriptiva del indicador Ejecución*


	N	Mínimo	Máximo	Media	Desviación
Pre-Test	298	1	3	1.91	0.753
Post-Test	298	1	3	2.10	0.754

*Fuente:* Propia elaboración mediante el programa SPSS v.25.

Interpretando la información de la tabla 7, se observa que la media de las puntuaciones sobre el indicador Ejecución de la Autorregulación del aprendizaje obtenidas en el pre-test es de 1.91 y la media de las puntuaciones obtenidas en el post-test es de 2.10, lo que representa un aumento del 9.95% como se muestra en la Figura 4. Del pre-test la desviación estándar es de 0.753 y del post-test es de 0.754, siendo muy similares y representan la dispersión de las puntuaciones alrededor de la media en cada prueba. Se encuestaron a 298 estudiantes. En ambos tests, los valores mínimos fueron de 1 y los máximos fueron de 3, proporcionando información sobre el rango de variabilidad de las puntuaciones y los valores obtenidos por los estudiantes en cada prueba.

**Figura 3**


Comparativo Pre-test Post-test - Ejecución



Fuente: Propia elaboración

**Figura 4**

Porcentaje aumento en Ejecución



Fuente: Propia elaboración

Las medidas descriptivas obtenidas de la Evaluación, correspondiente a la tercera dimensión de la variable dependiente Autorregulación del Aprendizaje se muestra a continuación:

**Tabla 8**

*Tabla descriptiva del indicador Evaluación*


	N	Mínimo	Máximo	Media	Desviación
Pre-Test	298	1	3	1.94	0.808
Post-Test	298	1	3	2.12	0.759

*Fuente:* Propia elaboración mediante el programa SPSS v.25.

De la tabla 8, se observa que la media de las puntuaciones sobre el indicador Evaluación de la Autorregulación del aprendizaje obtenidas en el pre-test es de 1.94 y la media de las puntuaciones obtenidas en el post-test es de 2.12, lo que representa un aumento del 9.28%. Del pre-test la desviación estándar es de 0.808 y del post-test es de 0.759, siendo muy similares y representan la dispersión de las puntuaciones alrededor de la media en cada prueba. Se encuestaron a 298 estudiantes En ambos tests, los valores mínimos fueron de 1 y los máximos fueron de 3, proporcionando información sobre el rango de variabilidad de las puntuaciones y los valores obtenidos por los estudiantes en cada prueba.

**Figura 5**


*Comparativo Pre-test Post-test - Evaluación*



*Fuente: Propia elaboración*

**Figura 6**

*Porcentaje aumento en Evaluación*



*Fuente: Propia elaboración*

## 4.2. Análisis Inferencial

La prueba de normalidad busca evaluar si las respuestas o puntuaciones obtenidas en la encuesta siguen una distribución normal o se desvían significativamente de ella. Las respuestas en una encuesta tipo Likert son datos ordinales y no necesariamente siguen una distribución normal. En ese sentido, se obtuvieron las pruebas de normalidad para los indicadores Planificación, Ejecución y Evaluación de la variable dependiente Autorregulación del Aprendizaje, utilizando la prueba de Kolmogorov-Smirnov a razón de que la muestra es de 298 superior a 50, mediante el software estadístico SPSS v.25, considerando una significancia del 5% y un nivel de confianza del 95%, se plantearon las hipótesis, donde  $H_0$  es la hipótesis nula, que indica que los datos tienen distribución normal y una hipótesis alternativa  $H_a$ , que indica que los datos no siguen una distribución normal y dependiendo del  $p$  obtenido, si  $p < 0,05$  aceptamos  $H_a$  y rechazamos  $H_0$  y en caso  $p \geq 0,05$  rechazamos  $H_a$  y aceptamos la  $H_0$ .

Con respecto a la prueba de normalidad de la Planificación, correspondiente a la primera dimensión de la variable dependiente Autorregulación del Aprendizaje, se propusieron las hipótesis, donde la hipótesis nula  $H_0$  señala que los datos del indicador Planificación tienen una distribución normal y la hipótesis alterna  $H_a$  señala que los datos del indicador Planificación no siguen una distribución normal. Luego se llevó a cabo el test de Kolmogorov-Smirnov dado que la muestra de 298 es mayor que 50, considerando una confianza del 95% y significancia del 5%.

**Tabla 9**

*Indicador Planificación - Prueba de normalidad de Kolmogorov-Smirnov*

	<b>Estadístico</b>	<b>gl</b>	<b>p</b>
Pre-Test	,224	298	,000
Post-Test	,262	298	,000

*Fuente:* Procesado en programa SPSS v.25.

De la tabla 9, el valor de  $p = 0.00$  siendo menor que  $0.05$ , aceptándose la hipótesis alternativa ( $H_a$ ) y rechazándose la hipótesis nula ( $H_0$ ), en consecuencia, los datos del indicador Planificación no tienen una distribución normal y se optará por utilizar métodos estadísticos no paramétricos en lugar de métodos paramétricos para este segundo indicador.

Con respecto a la prueba de normalidad de la Ejecución, correspondiente a la segunda dimensión de la variable dependiente Autorregulación del Aprendizaje se propusieron las hipótesis, donde la hipótesis nula  $H_0$  señala que los datos del indicador Ejecución tienen una distribución normal y la hipótesis alterna  $H_a$  señala que los datos del indicador Ejecución no tienen una distribución normal. Luego se llevó a cabo el test de Kolmogorov-Smirnov dado que la muestra de 298 es mayor que 50, considerando una confianza del 95% y significancia del 5%.

**Tabla 10**

*Prueba de normalidad de Kolmogorov-Smirnov – Indicador Ejecución*

	<b>Estadístico</b>	<b>gl</b>	<b>p</b>
Pre-Test	,219	298	,000
Post-Test	,222	298	,000

*Fuente:* Propia elaboración mediante el software estadístico SPSS v.25.

De la tabla 10, el valor de  $p = 0.00$  siendo menor que  $0.05$ , aceptándose la hipótesis alternativa ( $H_a$ ) y rechazándose la hipótesis nula ( $H_0$ ), en consecuencia, los datos del indicador Ejecución no tienen una distribución normal y se optará por utilizar métodos estadísticos no paramétricos en lugar de métodos paramétricos para este segundo indicador.

Con respecto a la prueba de normalidad de la Evaluación, correspondiente a la primera dimensión de la variable dependiente Autorregulación del Aprendizaje se propusieron las hipótesis, donde la hipótesis nula  $H_0$  señala que los datos del indicador Evaluación tienen una distribución normal y la hipótesis alterna  $H_a$  señala que los datos del indicador Evaluación no tienen una distribución normal. Luego se llevó a cabo el test de Kolmogorov-Smirnov dado que la muestra de 298 es mayor que 50, considerando una confianza del 95% y significancia del 5%.

**Tabla 11**

*Prueba de normalidad de Kolmogorov-Smirnov – Indicador Evaluación*

	<b>Estadístico</b>	<b>gl</b>	<b>p</b>
Pre-Test	,234	298	,000
Post-Test	,230	298	,000

Fuente: Propia mediante el programa SPSS v.25.

De la tabla 11, el valor de  $p = 0.00$  siendo menor que 0.05, aceptándose la hipótesis alternativa ( $H_a$ ) y rechazándose la hipótesis nula ( $H_0$ ), en consecuencia, los datos del indicador Evaluación no tienen una distribución normal y se optará por utilizar métodos estadísticos no paramétricos en lugar de métodos paramétricos para este tercer indicador.

Luego se realizaron las pruebas de hipótesis para muestras relacionadas, debido a que los 298 estudiantes que participaron en el Pre-test son los mismos que participaron en Post-test, considerando un método estadístico no paramétrico para los indicadores Planificación, Ejecución y Evaluación en concordancia con el resultado obtenido de las pruebas de normalidad de *Kolmogorov-Smirnov*, se determinó entonces realizar la prueba de hipótesis de Wilcoxon para cada indicador. El objetivo de la prueba de Wilcoxon es determinar si existe evidencia adecuada para afirmar que hay una significativa diferencia entre los dos conjuntos de datos. Se plantearon las hipótesis, donde  $H_0$  es la hipótesis nula, que indica no hay significativa



diferencia entre los resultados del pre-test y post-test y la hipótesis alternativa  $H_a$ , que indica que sí existe significativa diferencia entre los resultados del pre-test y post-test, y dependiendo del  $p$  obtenido, si  $p < 0,05$  se rechazaría la hipótesis  $H_0$ , aceptándose  $H_a$  y en caso  $p \geq 0,05$  se rechaza  $H_a$  y se acepta la hipótesis  $H_0$ . Se consideró un nivel de significancia alfa de 0.05.

Con respecto a la prueba de hipótesis de la Planificación, correspondiente a la primera dimensión de la variable dependiente Autorregulación del Aprendizaje, se realizó la prueba de Wilcoxon, donde se propusieron las hipótesis,  $H_0$  es la hipótesis nula, planteando que Machine Learning no influye significativamente en la Planificación de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; y la hipótesis alterna  $H_a$ , planteando que Machine Learning influye significativamente en la Planificación de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; se consideró además una significancia alfa de 0.05.

**Tabla 12**

*Prueba de Wilcoxon – Indicador Planificación*

N total	298
Estadístico de contraste	9.457,500
Error estándar	631,547
Estadístico de contraste estandarizado	3,059
Sig. Asintótica (prueba bilateral)	0,002

*Fuente:* Procesado en programa SPSS v.25

De acuerdo a la tabla 12, el valor de  $p$  es 0.002 menor a 0.05. En consecuencia, se hace evidente que debe aceptarse la hipótesis alterna  $H_a$  y rechazarse la hipótesis nula  $H_0$ . Esto indica que entre las medias del pre y

post test existen significativas diferencias. En conclusión, se puede afirmar que machine learning influye significativamente en la Planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

Con respecto a la prueba de hipótesis de la Ejecución, correspondiente a la segunda dimensión de la variable dependiente autorregulación del aprendizaje, se realizó la prueba de Wilcoxon, donde se propusieron las hipótesis,  $H_0$  es la hipótesis nula, planteando que machine learning no influye significativamente en la Ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; y la hipótesis alterna  $H_a$ , planteando que machine learning influye significativamente en la Ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; se consideró además una significancia alfa de 0.05.

**Tabla 13**

*Prueba de Wilcoxon – Indicador Ejecución*

N total	298
Estadístico de contraste	11.662,000
Error estándar	745,478
Estadístico de contraste estandarizado	2,957
Sig. Asintótica (prueba bilateral)	0,003

*Fuente:* Procesado en programa SPSS v.25

De acuerdo a la tabla 13, el valor de p es 0.003 menor a 0.05. En consecuencia, se hace evidente que debe aceptarse la hipótesis alterna  $H_a$  y rechazarse la hipótesis nula  $H_0$ . Esto indica que entre las medias del pre y post test existen significativas diferencias. En conclusión, se puede afirmar

que machine learning influye significativamente en la Ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

Con respecto a la prueba de hipótesis de la Evaluación, correspondiente a la tercera dimensión de la variable dependiente Autorregulación del Aprendizaje, se realizó la prueba de Wilcoxon, donde se propusieron las hipótesis,  $H_0$  es la hipótesis nula, planteando que Machine Learning no influye significativamente en la Evaluación de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; y la hipótesis alterna  $H_a$ , planteando que Machine Learning influye significativamente en la Evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023; se consideró además una significancia alfa de 0.05.

**Tabla 14**

*Prueba de Wilcoxon – Indicador Evaluación*

N total	298
Estadístico de contraste	12.359,000
Error estándar	793,630
Estadístico de contraste estandarizado	2,656
Sig. Asintótica (prueba bilateral)	0,008

*Fuente:* Procesado en programa SPSS v.25

De acuerdo a la tabla 14, el valor de  $p$  es 0.008 menor a 0.05. En consecuencia, se hace evidente que debe aceptarse la hipótesis alterna  $H_a$  y rechazarse la hipótesis nula  $H_0$ . Esto indica que entre las medias del pre y post test existen significativas diferencias. En conclusión, se puede afirmar que machine learning influye significativamente en la Evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

# V DISCUSIÓN

## V. Discusión

De acuerdo con los hallazgos del estudio, se pudo observar un aumento significativo en los indicadores de la variable dependiente autorregulación del aprendizaje luego de la aplicación de machine learning en una academia preuniversitaria privada, Lima 2023.

Con respecto al indicador Planificación, se evaluaron 298 datos con valor mínimo 1 y valor máximo 3, obteniéndose en el pre-test un promedio de 1,96 y en el post-test un promedio de 2,15, es decir se produjo incremento de 0,19, lo cual representa un aumento del 9,69% con respecto al punto de partida, es decir, el pre-test. La desviación estándar en el pre-test es de 0,799 y en el post-test es de 0,803, es decir, la dispersión de datos alrededor de la media casi se mantiene, solo que ahora en el post-test, alrededor de una media incrementada.

Así, utilizando el enfoque inferencial para examinar la normalidad de la data del indicador Planificación, se empleó el test de Kolmogórov-Smirnov. Tanto el pre-test como el post-test evidenciaron una significancia (p) de 0.000 al realizar esta prueba de normalidad sobre los datos. Razón por lo que ( $p < 0,05$ ), se aceptó la hipótesis alterna ( $H_a$ ) y se rechazó la hipótesis nula ( $H_0$ ), lo que indica que los datos del indicador Planificación no tienen una distribución normal. Se llevó a cabo el test de Wilcoxon no paramétrico, con una significancia de  $p = 0,002 < 0.05$ , prosiguiéndose con la aceptación de la hipótesis alterna  $H_a$ , rechazando la hipótesis nula  $H_0$ , es decir, fue validada la hipótesis que machine learning influye significativamente en la Planificación de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

De acuerdo a los resultados obtenidos del indicador Planificación de la Autorregulación del Aprendizaje y de sus antecedentes, se evidenció una influencia de Machine Learning sobre este indicador, de modo similar, Vera

(2022) en su estudio encontró que los estudiantes que planifican y supervisan su aprendizaje, logran mejores resultados académicos, específicamente los que planifican las actividades, los contenidos y los tiempos que necesitan para llevar a cabo su tarea, del mismo modo, Caselli (2021) aplicando un modelo de predicción basado en machine Learning aumentó la precisión del desempeño académico de los estudiantes de las Escuelas Profesionales de Ingeniería de la UNS desde 28.89% a 58.47%. A diferencia de Zambrano et al. (2020), que encontró en estudiantes universitarios de primer ciclo, índices bajos en su dimensión de organización de la tarea, que comprende a la planificación, con una media de 1.7 y, por el contrario, mayores índices de hábitos inadecuados de regulación de aprendizaje con una media de 3.5 considerando una escala Likert de 1 a 5. También, el modelo Machine Learning utilizado en la presente investigación alcanzó un coeficiente de determinación  $r^2$  score del 73.3% es decir, en la precisión de la predicción de resultados, mientras que el modelo de Contreras et al. (2020) en Machine Learning utilizado para determinar el rendimiento académico de estudiantes alcanzó un 66.4% de exactitud. De manera similar Svagelj y Vallejos (2021) en su estudio han encontrado una relación positiva entre autoeficacia que según Zimmerman (2000) y Bruna et al. (2017) es parte de la fase de planificación y el rendimiento académico.

Con respecto al indicador Ejecución, se evaluaron 298 datos con valor mínimo 1 y valor máximo 3, obteniéndose en el pre-test un promedio de 1,91 y en el post-test un promedio de 2,10, es decir se produjo incremento de 0,19, lo cual representa un aumento del 9,95% con respecto al punto de partida, es decir, el pre-test. La desviación estándar en el pre-test es de 0,753 y en el post-test es de 0,754, es decir, la dispersión de datos alrededor de la media casi se mantiene, solo que ahora en el post-test, alrededor de una media incrementada.

Así, utilizando el enfoque inferencial para examinar la normalidad de la data del indicador Ejecución, se empleó el test de Kolmogórov-Smirnov. Tanto el pre-test como el post-test evidenciaron una significancia (p) de 0.000 al realizar esta prueba de normalidad sobre los datos. Razón por lo que ( $p < 0,05$ ), se aceptó la hipótesis alterna ( $H_a$ ) y se rechazó la hipótesis nula ( $H_0$ ), lo que indica que los datos del indicador Ejecución no tienen una distribución normal. Se llevó a cabo el test de Wilcoxon no paramétrico, con una significancia de  $p = 0,003 < 0.05$ , prosiguiéndose con la aceptación de la hipótesis alterna  $H_a$ , rechazando la hipótesis nula  $H_0$ , es decir, fue validada la hipótesis que machine learning influye significativamente en la Ejecución de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

Asimismo, de acuerdo a los resultados obtenidos del indicador Ejecución de la Autorregulación del Aprendizaje y de sus antecedentes, se evidenció una influencia de Machine Learning sobre este indicador, al que también Sáez et al. (2020) se refiere como la fase de desempeño, de modo similar, Chavez (2022) encontró que un sistema web basado en machine Learning mejora en un 15.54% la elaboración de métodos de estudio y un 17.9% en la cognición. Mientras que De la Hoz et al. (2019) que desarrolló un modelo en Machine Learning para clasificar estudiantes de ambientes virtuales, encontró que los estudiantes que pasan mayor tiempo en la plataforma educativa de la institución de su estudio, no necesariamente son los obtienen las mejores notas y sino quienes lo usan de manera moderada. En cambio, Caselli (2021), determinó en su estudio que la implementación de Machine Learning sí optimiza el seguimiento del desempeño académico entre un 28% y 58%. De manera similar Svagelj y Vallejos (2021), han encontrado una relación positiva entre autoeficacia y rendimiento académico. Al igual que Vélez et al. (2022), que encontraron que los estudiantes de su estudio obtuvieron resultados de nivel medio en las dimensiones cognición 51% y motivación 49% de la autorregulación del aprendizaje, que justamente

sostenían los resultados de la dimensión ejecución en su estudio, debido a que obtuvieron resultados bajos en sus demás dimensiones. A diferencia de Zambrano et al. (2020), en su estudio a estudiantes de primer año de pedagogía de instituciones municipales de Chile, encontró bajos resultados en la ejecución de la autorregulación del aprendizaje, obteniendo en la organización del entorno y búsqueda de la información medias de 1.4 y 1.5 respectivamente sobre rango de 1 a 5. A diferencia de Vélez et al. (2022) que en su estudio realizado a estudiantes de 5° de secundaria en Piura, al estudiar la autorregulación del aprendizaje se obtuvo un nivel medio, con un 51% en cognición y con un 45,9% en la motivación. En cambio, Muñoz (2021), en su investigación realizada en tres universidades privadas de Lima cuyo objetivo consistió en establecer una relación entre el desempeño académico de los estudiantes universitarios ubicados en Lima Metropolitana y la autorregulación de su aprendizaje, encontrando que sí existe relación entre sus variables y específicamente que, en el rendimiento académico, la autorregulación del aprendizaje influye positivamente.

Con respecto al indicador Evaluación, se evaluaron 298 datos con valor mínimo 1 y valor máximo 3, obteniéndose en el pre-test un promedio de 1,94 y en el post-test un promedio de 2,12, es decir se produjo incremento de 0,18, lo cual representa un aumento del 9,28% con respecto al punto de partida, es decir, el pre-test. La desviación estándar en el pre-test es de 0,808 y en el post-test es de 0,759, es decir, la dispersión de datos alrededor de la media casi se mantiene, solo que ahora en el post-test, alrededor de una media incrementada.

Así, utilizando el enfoque inferencial para examinar la normalidad de la data del indicador Evaluación, se empleó el test de Kolmogórov-Smirnov. Tanto el pre-test como el post-test evidenciaron una significancia (p) de 0.000 al realizar esta prueba de normalidad sobre los datos. Razón por lo que ( $p < 0,05$ ), se aceptó la hipótesis alterna ( $H_a$ ) y se rechazó la hipótesis nula ( $H_0$ ), lo que indica que los datos del indicador Evaluación no tienen una



distribución normal. Se llevó a cabo el test de Wilcoxon no paramétrico, con una significancia de  $p=0,008 < 0.05$ , prosiguiéndose con la aceptación de la hipótesis alterna  $H_a$ , rechazando la hipótesis nula  $H_0$ , es decir, fue validada la hipótesis que machine learning influye significativamente en la Evaluación de la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.

Asimismo, con los resultados del indicador Evaluación de la Autorregulación del Aprendizaje y de sus antecedentes, se evidenció una influencia de machine learning sobre en este indicador, al que también Zimmerman (2000) le denomina fase de autorreflexión. De modo similar Vera (2022), en su estudio realizado a estudiantes del primer año de Pedagogía sobre la autorregulación de aprendizaje, encontró que la media de su dimensión Revisión fue de 14.638 en un rango de 4 a 20, siendo menor frente a las otras dimensiones de planificación y supervisión en las que se obtuvo 23.067 en un rango de 6 a 30 y 26.638 en un rango de 7 a 35. Del mismo modo Paredes y Moreta (2020), encontraron en su estudio que busca la existencia de relaciones entre la autorregulación del aprendizaje y la actitud investigativa, que en la dimensión evaluación de la autorregulación del aprendizaje se obtuvieron medias de 3.72 en varones y 3.90 en mujeres, por debajo levemente de la media de la dimensión ejecución y sobre la media de la dimensión planificación. En ese sentido, Panadero (2017), afirma que los estudiantes llevan a cabo análisis de su desempeño en la tarea, emitiendo juicios acerca de si han tenido éxito o han enfrentado dificultades, lo que a su vez generan autorreacciones que influyen de modo positivo o negativo en cómo abordan futuras tareas y desempeños.

La metodología utilizada en esta investigación presenta varias fortalezas. En primer lugar, el enfoque cuantitativo tipo pre-experimental permite medir y analizar datos de manera objetiva, proporcionando una base sólida para evaluar la influencia de Machine Learning en la autorregulación del aprendizaje. La elección de un cuestionario validado y adaptado al contexto del estudio, junto con su validación mediante juicio de expertos,

garantiza la confiabilidad de los resultados. La aplicación de un pre y post test permite comparar los cambios antes y después de la exposición al aplicativo web en machine learning, brindando una visión clara sobre el impacto de esta tecnología en el aprendizaje autorregulado. Además, la integración de la tecnología machine learning en el análisis de datos ofrece una perspectiva avanzada y completa para interpretar y comprender los resultados.

El aporte de esta investigación se destaca por su enfoque detallado, preciso y sólido sobre elementos que tienen influencia en la autorregulación del aprendizaje, así como por su exploración de la influencia de los modelos de machine learning en el ámbito educativo. En comparación con otros estudios, su contribución teórica resulta significativa al consolidar y enriquecer la teoría existente a través de la revisión de revistas indexadas que se enfocan en la integración del Machine Learning en la educación, lo que brinda un respaldo sólido a sus hallazgos. Al basarse en investigaciones previas de renombre, como la de Zimmerman (2000) sobre la autorregulación del aprendizaje, la investigación establece conexiones con trabajos previos, fortaleciendo así su validez y relevancia. Además, el valor práctico de esta investigación se evidencia al proporcionar una aplicación informática basada en Machine Learning que permite a los estudiantes conocer con mayor precisión su probabilidad de éxito en el examen de admisión universitaria, lo que les permite tomar medidas informadas y oportunas para mejorar su autorregulación del aprendizaje. La creación de un cuestionario validado y confiable para medir la autorregulación de los estudiantes en el contexto peruano también representa un aporte valioso, ya que su adaptación de una herramienta previamente validada en otros contextos ofrece una nueva herramienta de medición confiable y aplicable para futuras investigaciones, es decir, esta investigación se destaca por su riguroso enfoque teórico y sus aplicaciones prácticas, lo que la posiciona como un valioso y sólido aporte en el estudio de la influencia del machine learning en la educación y específicamente en la autorregulación del aprendizaje.

## **VI CONCLUSIONES**

## VI. Conclusiones

- Primera: Se cumplió el objetivo general: determinar la influencia del machine learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada en Lima 2023. Demostrándose que machine learning influye significativamente en la autorregulación del aprendizaje, constatándose en los resultados descriptivos e inferenciales de los indicadores de la autorregulación del aprendizaje, con incrementos significativos del 9,69% en Planificación, del 9,95% en Ejecución y 9,28% en Evaluación, y las pruebas Wilcoxon con  $p < 0.05$ .
- Segunda: Se cumplió el objetivo específico primero: determinar la influencia de machine learning en la Planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, como lo evidencian los resultados descriptivos e inferenciales de Planificación un aumento de la media del 9,69%, de 1,96 a 2,15, y la prueba Wilcoxon con significancia  $p$  de  $0,002 < 0.05$ , constatándose así, un aumento significativo de la Planificación debido a machine learning.
- Tercera: Se cumplió el objetivo específico segundo: determinar la influencia de machine learning en la Ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, como lo evidencian los resultados descriptivos e inferenciales de Ejecución con aumento de la media del 9,95%, de 1,91 a 2,10, y la prueba Wilcoxon con significancia  $p$  de  $0,003 < 0.05$ , constatándose así, un aumento significativo de la Ejecución debido a machine learning.
- Cuarta: Se cumplió el objetivo específico tercero: determinar la influencia de machine learning en la Evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, como lo evidencian los resultados descriptivos e inferenciales de Evaluación con aumento de la media del 9,28%, de 1,94 a 2,12, y la prueba Wilcoxon con significancia  $p$  de  $0,008 < 0.05$ , constatándose así, un aumento significativo de la Evaluación debido a machine learning.

## **VII RECOMENDACIONES**

## **VII. Recomendaciones**

- Primera: En relación al objetivo general: determinar la influencia del machine learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada en Lima 2023, y a la influencia significativa encontrada, se recomienda al director general de la institución continuar impulsando proyectos machine learning ampliando lo desarrollado en esta investigación, dado que contribuye a la forma como aprenden los estudiantes, autorregulándose y puedan afrontar con éxito el examen de admisión, que es una finalidad de la institución.
- Segunda: En relación al objetivo específico primero: determinar la influencia de machine learning en la Planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, se recomienda al director general implementar políticas para el uso de machine learning en el desarrollo de la Planificación de la autorregulación del aprendizaje, en aspectos de disposición como el análisis de la tarea y las creencias relacionadas con la automotivación
- Tercera: En relación al objetivo específico segundo: determinar la influencia de machine learning en la Ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, se recomienda al director general implementar políticas para el uso de machine learning en el desarrollo de la Ejecución de la autorregulación del aprendizaje, que comprende el desempeño, el autocontrol en el uso de técnicas y tácticas, y a la autoobservación, para el aprendizaje.
- Cuarta: En relación al objetivo específico tercero: determinar la influencia de machine learning en la Evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023, se recomienda al director general implementar políticas para el uso de machine learning en el desarrollo de la Evaluación de la autorregulación del aprendizaje, que aborda aspectos como la autorreflexión, autojuzgamiento y autorreacción frente a los éxitos y errores al aprender.

# REFERENCIAS

## Referencias

- Álvarez, E., Santos, E., Rojas, O., Tiburcio, R., Rosales, V., Mayta, R. (2022). Análisis de la Situación Académica de los Participantes en los Simulacros Descentralizados de Examen de Admisión de la Universidad Nacional Mayor de San Marcos. International Institute of Informatics and Cybernetics. <https://doi.org/10.54808/CISCI2022.01.60>
- Baviera, T. (2017). Técnicas para el Análisis de Sentimiento en Twitter: Aprendizaje Automático Supervisado y SentiStrength. Revista Dígitos, 1(3), 33-50. <https://dialnet.unirioja.es/servlet/articulo?codigo=6000693>
- Bruna, D., Pérez, M. V., Bustos, C., & Núñez, J. C. (2017). Propiedades Psicométricas del Inventario de Procesos de Autorregulación Del aprendizaje en Estudiantes Universitarios Chilenos. Revista Iberoamericana de Diagnóstico y Evaluación Psicológica, 2(44), 77–91. <https://doi.org/10.21865/RIDEP44.2.07>
- Caselli, H. (2021). Modelo predictivo basado en Machine Learning como soporte para el seguimiento académico del estudiante universitario. Universidad Nacional del Santa. Chimbote, Perú. <http://repositorio.uns.edu.pe/handle/20.500.14278/3804>
- Cash, P., Isaksson, O., Maier, A., & Summers, J. (2022). Sampling in design research: Eight key considerations. Design Studies, 78. <https://doi.org/10.1016/j.destud.2021.101077>
- Casteel, A., & Bridier, N. L. (2021). Describing populations and samples in doctoral student research. International Journal of Doctoral Studies, 16, 339–362. <https://doi.org/10.28945/4766>



- Castro, M. (2019). Biostatistics applied in clinical research: Basic concepts. [Bioestadística aplicada en investigación clínica: conceptos básicos] *Revista Médica Clínica Las Condes*, 30(1), 50-65. <https://doi.org/10.1016/j.rmcl.2018.12.002>
- Chavez, W. & Pacheco, G. (2022). Sistema web basado en Machine Learning para mejorar el autoaprendizaje en alumnos de secundaria en el colegio Jhon D'Alembert, Virú, La Libertad – 2021. Universidad Cesar Vallejo. Lima, Perú. <https://hdl.handle.net/20.500.12692/101414>
- Clark, L. A., & Watson, D. (2019). Constructing validity: New developments in creating objective measuring instruments. *Psychological Assessment*, 31(12), 1412–1427. <https://doi.org/10.1037/pas0000626>
- Contreras, L., Fuentes, H., & Rodríguez, J. (2020). Predicción del rendimiento académico como indicador de éxito/fracaso de los estudiantes de ingeniería, mediante aprendizaje automático. *Formación universitaria*, 13(5), 233-246. <https://dx.doi.org/10.4067/S0718-50062020000500233>
- Cordero, D. (2020). Promover el aprendizaje autónomo, un desafío. *El Peruano*. Perú. <https://elperuano.pe/noticia/111937-promover-el-aprendizaje-autonomo-un-desafio>
- Cunill, M., & Curbelo, L. (2021). Una aproximación a la autorregulación del aprendizaje desde la evaluación formativa en la educación médica. *Educación Médica Superior*, 35(1), e2498. Epub 01 de abril de 2021. [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S0864-21412021000100019&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-21412021000100019&lng=es&tlng=es).
- De la Hoz, Enrique, De la Hoz, Efrain, & Fontalvo, T. (2019). Methodology of Machine Learning for the classification and Prediction of users in Virtual

Education Environments. Información tecnológica, 30(1), 247-254.  
<https://dx.doi.org/10.4067/S0718-07642019000100247>

De la Peña, G., & Velázquez, R. (2018). Algunas reflexiones sobre la teoría general de sistemas y el enfoque sistémico en las investigaciones científicas. Revista Cubana de Educación Superior, 37(2), 31-44.  
[http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S0257-43142018000200003&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0257-43142018000200003&lng=es&tlng=es)

Ganda, D., & Boruchovitch, E. (2018). A autorregulação da aprendizagem: principais conceitos e modelos teóricos. Psicologia da Educação, (46), 71-80.  
[http://pepsic.bvsalud.org/scielo.php?script=sci\\_arttext&pid=S1414-69752018000100008&lng=pt&tlng=pt](http://pepsic.bvsalud.org/scielo.php?script=sci_arttext&pid=S1414-69752018000100008&lng=pt&tlng=pt).

George, D., & Mallery, P. (2003). SPSS for Windows step by step: A simple guide and reference. 11.0 update (4th ed.). Boston: Allyn & Bacon

Hernández, H. A., & Pascual Barrera, A. E. (2018). Validación de un instrumento de investigación para el diseño de una metodología de autoevaluación del sistema de gestión ambiental. Revista de Investigación Agraria y Ambiental, 9(1), 157–164. <https://doi.org/10.22490/21456453.2186>

Hernández, R., Fernández, C., y Baptista, P. (2014). Metodología de la investigación: MC Graw Hill  
<https://www.uca.ac.cr/wpcontent/uploads/2017/10/Investigacion.pdf>

Lozada, J. (2014). Investigación aplicada: Definición, propiedad intelectual e industria. CienciAmérica: Revista de Divulgación Científica de La Universidad Tecnológica Indoamérica, 3(1), 47–50.

- Ma, S., Liu, J., Li, W., Liu, Y., Hui, X., Qu, P., Jiang, Z. & Li, J. (2023). Machine learning in TCM with natural products and molecules: current status and future perspectives. *Chinese Medicine* 18, 43 (2023).  
<https://doi.org/10.1186/s13020-023-00741-9>
- Mamani, Z. (2022). Proceso de machine learning para determinar la demanda social de puestos de empleo de profesionales de TI. *Industrial Data*, 25(2), 275-300.  
[http://www.scielo.org.pe/pdf/idata/v25n2/en\\_1810-9993-idata-25-02-275.pdf](http://www.scielo.org.pe/pdf/idata/v25n2/en_1810-9993-idata-25-02-275.pdf)
- Maldonado, C. (2017). Ciencia hecha realidad Reseña de C. A. Ossa, Teoría general de sistemas. Conceptos y aplicaciones. *Innovar*, 27(64), 157-159.  
<https://doi.org/10.15446/innovar.v27n64.62377>
- Ministerio de Educación. (2016). Currículo Nacional de la Educación Básica. Perú.  
<http://www.minedu.gob.pe/curriculo/pdf/curriculo-nacional-de-la-educacion-basica.pdf>
- Ministerio de Educación. (2022). *El Perú en PISA 2018. Informe nacional de resultados*. Lima: Oficina de Medición de la Calidad de los Aprendizajes.  
<http://umc.minedu.gob.pe/el-peru-en-pisa-2018-informe-nacional-de-resultados/>
- Moreno, F., Palacios, J., & Nuñez, F. (2021). Estrategias de autorregulación y competencia discursiva en el nivel superior. *Propósitos y Representaciones*, 9(1), e1039.  
<https://dx.doi.org/10.20511/pyr2021.v9n1.1039>
- Muñoz, M. (2021). Autorregulación del aprendizaje y rendimiento académico de los estudiantes universitarios. Universidad Nacional Mayor de San Marcos. Lima, Perú. <https://doi.org/10.35381/r.k.v6i3.1436>

- Nawang, H., Makhtar, M., & Hamzah, W. M. A. F. W. (2021). A systematic literature review on student performance predictions. En *International Journal of Advanced Technology and Engineering Exploration* (Vol. 8, Número 84, pp. 1441–1453). Accent Social and Welfare Society. <https://doi.org/10.19101/IJATEE.2021.874521>
- Ossa, C. (2017). *Teoría general de sistemas. Conceptos y aplicaciones*. Universidad Tecnológica de Pereira. <https://doi.org/10.22517/9789587222289>
- Pacheco, B. (2020). *Siete claves para la innovación educativa*. El País. Argentina. [https://elpais.com/elpais/2020/07/31/planeta\\_futuro/1596204508\\_015285.html](https://elpais.com/elpais/2020/07/31/planeta_futuro/1596204508_015285.html)
- Panadero, E. (2017). A Review of Self-regulated Learning: Six Models and Four Directions for Research. *Front. Psychol*, 8, 1-28, (2017) <https://doi.org/10.3389/fpsyg.2017.00422>
- Panadero, E., Tapia, J., García, D., Fraile, J., Sánchez & J., Pardo, R. (2020). Deep learning self-regulation strategies: Validation of a situational model and its questionnaire. *Revista de Psicodidáctica*. 2021. <https://doi.org/10.1016/j.psicod.2020.11.003>
- Paredes, F., & Moreta, R. (2020). Actitudes hacia la investigación y autorregulación del aprendizaje en los estudiantes universitarios. *CienciAmérica*, 9(3), 11–26. <https://doi.org/10.33210/ca.v9i3.263>
- Pedrero, V., Reynaldos, K., Ureta, J., & Cortez, E. (2021). Generalidades del Machine Learning y su aplicación en la gestión sanitaria en Servicios de Urgencia. *Revista médica de Chile*, 149(2), 248-254. <https://dx.doi.org/10.4067/s0034-98872021000200248>

- Peralta, E. (2016). Teoría general de los sistemas aplicada a modelos de gestión. *Aglala*, 7(1), 122–145. <https://dialnet.unirioja.es/descarga/articulo/6832738.pdf>
- Pichel, M. (2017). Por qué Finlandia, el país con la "mejor educación del mundo", está transformando la arquitectura de sus escuelas. BBC MUNDO. <https://www.bbc.com/mundo/noticias-41232085>
- Porcelli, A. (2020). La Inteligencia Artificial y la Robótica: sus dilemas sociales, éticos y jurídicos. *Derecho Global. Estudios Sobre Derecho Y Justicia*, 6(16), 49–105. <https://doi.org/10.32870/dgedj.v6i16.286>
- Rosário, P., Mourão, R., Núñez, J. C., González-Pienda, J., Solano, P. y Valle, A. (2007). Eficacia de un programa instruccional para la mejora de procesos y estrategias de aprendizaje en la enseñanza superior. *Psicothema*, 19, 422-427. <https://www.redalyc.org/articulo.oa?id=72719310>
- Sáez, F., Mella, J., López, Y., & León, V. (2021). Scales to measure self-regulated learning phases in secondary school students. *Información tecnológica*, 32(2), 41-50. <https://dx.doi.org/10.4067/S0718-07642021000200041>
- Sánchez, F. (2019). Fundamentos Epistémicos de la Investigación Cualitativa y Cuantitativa: Consensos y Disensos. *Revista Digital de Investigación en Docencia Universitaria*, 101–122. <https://doi.org/10.19083/ridu.2019.644>
- Siche, R., & Siche, N. (2023). El modelo de lenguaje basado en inteligencia artificial sensible - ChatGPT: Análisis bibliométrico y posibles usos en la agricultura y pecuaria. *Scientia Agropecuaria*, 14(1), 111-116. Epub 17 de marzo de 2023. <https://dx.doi.org/10.17268/sci.agropecu.2023.010>

- Sideridis, G., Saddaawi, A., & Al-Harbi, K. (2018). Internal Consistency Reliability in Measurement: Aggregate and Multilevel Approaches. *Journal of Modern Applied Statistical Methods*, 17(1), 1–30. <https://doi.org/10.22237/jmasm/1530027194>
- Setia, M. (2016). Methodology series module 5: Sampling strategies. *Indian Journal of Dermatology*, 61(5), 505–509. <https://doi.org/10.4103/0019-5154.190118>
- Svagelj, R. & Vallejos, V. (2021). Autorregulación del aprendizaje y rendimiento académico en escolares limeños de secundaria: un estudio desde la neurociencia educacional. Universidad Antoni Ruiz de Montoya. Lima, Perú. <https://repositorio.uarm.edu.pe/handle/20.500.12833/2338>
- Taherdoost, H. (2021). Data Collection Methods and Tools for Research; A Step-by-Step Guide to Choose Data Collection Technique for Academic and Business Research Projects Hamed Taherdoost. Data Collection Methods and Tools for Research; A Step-by-Step Guide to Choose Data Collection Technique for Academic Data Collection Methods and Tools for Research; A Step-by-Step Guide to Choose Data Collection Technique for Academic and Business Research Projects. En *International Journal of Academic Research in Management (IJARM)* (Vol. 2021, Número 1). <https://hal.science/hal-03741847>
- Timkyw, N., Bournissen, J. M., & Tumino, M. C. (2020). Scrum como Herramienta Metodológica para el Aprendizaje de la Programación. *Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología*, 26, e9. <https://doi.org/10.24215/18509959.26.e9>
- Vega, J. (2019). Modelo de pronóstico de rendimiento académico de alumnos en los cursos del programa de estudios básicos de la Universidad Ricardo Palma

usando algoritmos de Machine Learning. Universidad Ricardo Palma. Lima, Perú. <https://hdl.handle.net/20.500.14138/2914>

Vélez, J., Zapata, J., Pacherras, M., & Tumi, B. (2022). Aprendizaje basado en proyectos, una propuesta para mejorar el aprendizaje autorregulado en estudiantes de secundaria de una institución educativa, Piura 2020. Prohominum, 4(1), 38–65. <https://doi.org/10.47606/acven/ph0093>

Vera, A. (2022). Self-regulation in student learning and its relationship with academic performance. Revista Conhecimento Online, 2, 49–68. <https://doi.org/10.25112/rco.v2.2943>

Vigotsky, L. (1978). El desarrollo de los procesos psicológicos superiores. [PDF]. [http://www.terras.edu.ar/biblioteca/6/TA\\_Vygotsky\\_Unidad\\_1.pdf](http://www.terras.edu.ar/biblioteca/6/TA_Vygotsky_Unidad_1.pdf)

Vite, H., Carvajal, H., & Barrezueta, S. (2020). Aplicación de algoritmos de aprendizaje automático para clasificar la fertilidad de un suelo bananero. Revista Conrado, 16(72), 15-19. [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1990-86442020000100015&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442020000100015&lng=es&tlng=es).

Zambrano, C., Rojas, D., Díaz, A., & Perez, M. (2020). Analysis of self-regulation strategies in pedagogy students from a Chilean university. Formacion Universitaria, 13(5), 223–232. <https://doi.org/10.4067/S0718-50062020000500223>

Zimmerman, B. (2000). Attaining self-regulation: A social cognitive perspective. En M. Boekaerts, P. R. Pintrich y M. Zeidner (Eds.), Handbook of self-regulation.

# **ANEXOS**



## Anexos

### Anexo 1: Matriz de Consistencia

TÍTULO: Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023							
AUTOR: Carlos Enrique Pandal Blas							
PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES E INDICADORES				
<b>Problema principal:</b>	<b>Objetivo principal:</b>	<b>Hipótesis principal:</b>	<b>Variable - 1: Machine Learning</b>				
¿Cómo influye Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?	Determinar la influencia de Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023	Machine Learning influye significativamente en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023	<b>Variable - 2: Autorregulación del aprendizaje</b>				
Problemas específicos:	Objetivos específicos:	Hipótesis específicas:	Dimensiones	Indicadores	Ítems	Escalas de medición	Niveles o Rangos
P1. ¿Cómo influye Machine Learning en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?	O1. Determinar la influencia de Machine Learning en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.	H1. Machine Learning influye significativamente en la planificación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.	Planificación	Planificación	3	Cuantitativo Ordinal Tipo Likert (5 categorías 1-5)	Bajo: 3- 10 Medio: 11 - 12 Alto: 13 - 15
P2. ¿Cómo influye Machine Learning en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?	O2. Determinar la influencia de Machine Learning en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.	H2. Machine Learning influye significativamente en la ejecución de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.	Ejecución	Ejecución	4	Cuantitativo Ordinal Tipo Likert (5 categorías 1-5)	Bajo: 6 - 12 Medio: 13 - 15 Alto: 16 - 20
P3. ¿Cómo influye Machine Learning en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023?	O3. Determinar la influencia de Machine Learning en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023	H3. Machine Learning influye significativamente en la evaluación de la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.	Evaluación	Evaluación	5	Cuantitativo Ordinal Tipo Likert (5 categorías 1-5)	Bajo: 5 - 15 Medio: 16 - 19 Alto: 20 - 25

## Metodología

TIPO Y DISEÑO	POBLACIÓN Y MUESTRA	TÉCNICAS E INSTRUMENTOS	ESTADÍSTICA
<p><b>Enfoque:</b> Cuantitativo</p> <p><b>Tipo:</b> Investigación Aplicada</p> <p><b>Diseño:</b> Pre-experimental</p>	<p><b>Población:</b> 1322 estudiantes</p> <p><b>Tamaño de muestra:</b> 298 estudiantes</p> <p><b>Muestreo:</b> Probabilístico estratificado proporcional.</p>	<p><b>Técnicas:</b> Encuesta</p> <p><b>Instrumentos:</b> Cuestionario</p>	<p><b>Descriptiva:</b> En el análisis descriptivo, se calculó el valor mínimo y máximo, la media y la desviación estándar de cada indicador. Además, se muestran tablas y figuras para comparar los datos antes y después de la prueba.</p> <p><b>Inferencial:</b> Se realizó la prueba de normalidad para cada indicador y debido la muestra de 298 estudiantes, es decir mayor que 50, se optó por la prueba de normalidad de Kolmogorov-Smirnov y se debido a que resultado <math>p=0 &lt; 0.05</math> se optó por realizar una prueba no paramétrica para comparación de respuestas del pre-test y post-test aplicado a el mismo grupo muestral empleando la prueba de Wilcoxon</p>

## Anexo 2: Matriz De Operacionalización De Variables

TÍTULO: Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023						
AUTOR: Carlos Enrique Pandal Blas						
Variables de estudio	Definición conceptual	Definición operacional	Dimensión	Indicadores	Items	Escala de medición
Variable 1: Machine Learning	Según Ma et al. (2023), Machine Learning, como rama de la inteligencia artificial, se basa en la utilización de algoritmos y modelos matemáticos para habilitar a las computadoras a adquirir aprendizajes y mejorar en la realización de tareas específicas a través del análisis de datos y patrones, como la clasificación y predicción, en lugar de ser programado explícitamente, el sistema aprende de manera autónoma a medida que se le proporciona más información y se ajusta a los resultados obtenidos	Machine Learning es la tecnología de inteligencia artificial que permitirá predecir el resultado que obtendrá el estudiante en el examen de admisión a partir de su récord académico y las notas de ingreso del último examen de la UNMSM y generar respuestas y textos coherentes a partir de una entrada de texto				
Variable 2: Autorregulación del aprendizaje	Según Sáez et al. (2021), la autorregulación del aprendizaje es un sistema cognitivo-motivacional que tiene un enfoque holístico y está relacionado con el desarrollo integral de los estudiantes durante sus experiencias académicas. Este proceso abarca una amplia gama de habilidades, conocimientos, motivaciones, creencias y comportamientos, mediante un proceso cíclico que se divide en tres fases como son planificación/disposición, ejecución/desempeño y evaluación, siendo concordante con el modelo propuesto por Zimmerman (2000).	La autorregulación del aprendizaje es el conjunto de habilidades, estrategias y competencias que los estudiantes adquieren para supervisar y orientar de manera autónoma su proceso de aprendizaje. Implica que los estudiantes sean conscientes de sus propias fortalezas y debilidades, establezcan metas claras, planifiquen su estudio, monitoreen su progreso, regulen sus emociones y utilicen estrategias efectivas para lograr un aprendizaje óptimo, lo que puede conducir a mejores resultados académicos y preparación para el ingreso a la universidad	Planificación	Planificación	<p><b>P1.</b> Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos.</p> <p><b>P10.</b> Busco un sitio tranquilo y donde pueda estar concentrado para estudiar.</p> <p><b>P12.</b> Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con Internet, libros, lápices, cuadernos, fotocopias para no estar siempre interrumpiendo mi estudio.</p>	Cuantitativo Ordinal Tipo Likert (5 categorías 1-5) 1. Nunca 2. Casi nunca 3. Algunas veces 4. Casi siempre 5. Siempre
			Ejecución	Ejecución	<p><b>P3.</b> Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos.</p> <p><b>P5.</b> Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.</p> <p><b>P8.</b> Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.</p> <p><b>P6.</b> Cumpló mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario</p>	
			Evaluación	Evaluación	<p><b>P2.</b> Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.</p> <p><b>P4.</b> Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.</p> <p><b>P7.</b> Guardó y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.</p> <p><b>P9.</b> Establezco objetivos académicos concretos para cada asignatura</p> <p><b>P11.</b> Comparo las notas que saco con los objetivos que me había marcado para esa asignatura</p>	

### Anexo 3: Instrumento de recolección de datos

#### Inventario de Procesos de Autorregulación del Aprendizaje

Instrucciones: Lea cuidadosamente cada pregunta y marque con un aspa la respuesta que mejor refleje su opinión o experiencia teniendo en consideración el puntaje que corresponda.

Valoración	Categoría
1	Nunca
2	Casi nunca
3	A veces
4	Casi siempre
5	Siempre

Ciclo Académico: Ciclo A ( ) Ciclo B ( )

N°	Preguntas	Valoración (1 es Nunca y 5 es Siempre)				
P01	Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos	1	2	3	4	5
P02	Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.	1	2	3	4	5
P03	Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos	1	2	3	4	5
P04	Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.	1	2	3	4	5
P05	Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.	1	2	3	4	5
P06	Cumplo mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario	1	2	3	4	5
P07	Guardo y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.	1	2	3	4	5
P08	Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.	1	2	3	4	5
P09	Establezco objetivos académicos concretos para cada asignatura	1	2	3	4	5
P10	Busco un lugar tranquilo y donde pueda estar concentrado para estudiar	1	2	3	4	5
P11	Comparo las notas que obtengo con los objetivos que me había marcado para esa asignatura	1	2	3	4	5
P12	Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con Internet, libros, lápices, cuadernos, fotocopias para no estar siempre interrumpiendo mi estudio	1	2	3	4	5

En el anexo 14 se muestra el cuestionario en Google Forms.

#### Anexo 4: Ficha técnica del cuestionario.

Nombre de la Prueba:	Inventario de Procesos de Autorregulación del Aprendizaje
Autor:	Pandal Blas Carlos Enrique
Procedencia:	Adaptado de Rosário et al. (2007) de la Universidad de Oviedo-España y Bruna et al. (2017) de la Universidad de Concepción-Chile
Administración:	La encuesta tipo Likert se administrará en forma de cuestionario impreso o electrónico, dependiendo de la disponibilidad y preferencia de los participantes.
Tiempo de aplicación:	10 minutos.
Ámbito de aplicación:	Academia preuniversitaria privada, Lima 2023.
Dimensiones:	Está compuesta por 12 ítems que evalúan la autorregulación del aprendizaje en sus tres dimensiones, su primera dimensión Planificación, relacionada a los ítems P1, P10 y P12; su segunda dimensión Ejecución, relacionada a los ítems P3, P5, P8 y P6; y su tercera dimensión Evaluación relacionada los ítems P2, P4, P7, P9 y P11.
Puntuaciones:	Se emplea la escala de tipo Likert, con 5 categorías: 1,2,3,4,5. Donde 1 nunca, 2 casi nunca, 3 a veces, 4 casi siempre, 5 siempre.
Baremos:	Puntuación percentil relacionado a niveles Alto, Medio y Bajo
Año	2023

## Anexo 5: Modelo de Consentimiento.

### Consentimiento Informado

**Título de la investigación:** Machine Learning en la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023.  
**Investigador:** Pandal Blas Carlos Enrique

#### **Propósito del estudio**

Le invitamos a participar en la investigación titulada "Machine Learning en la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023", cuyo objetivo es determinar la influencia de Machine Learning en la autorregulación del aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023. Esta investigación es desarrollada por estudiantes posgrado del programa académico de Maestría en Ingeniería de Sistemas con mención en Tecnologías de la Información, de la Universidad César Vallejo del campus Lima norte, aprobado por la autoridad correspondiente de la Universidad y con el permiso de la institución Academia Aduni. La inteligencia artificial se viene desarrollando rápidamente, siendo machine learning parte de ella y ofrece muchas oportunidades para la educación, en ese sentido se propone medir su influencia en la autorregulación del aprendizaje de los estudiantes preuniversitarios con la presente investigación.

#### **Procedimiento:**

Si usted decide participar en la investigación se realizará lo siguiente:

1. Se realizará una encuesta donde se recogerán algunas preguntas sobre la investigación titulada: "Machine Learning en la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023".
2. Esta encuesta tendrá un tiempo aproximado de 10 minutos y se realizará en sus aulas de clase a través de un formulario Google. Las respuestas al cuestionario serán codificadas usando un número de identificación y, por lo tanto, serán anónimas.

#### **Participación voluntaria**

Puede hacer todas las preguntas para aclarar sus dudas antes de decidir si desea participar o no, y su decisión será respetada. Posterior a la aceptación no desea continuar puede hacerlo sin ningún problema.

#### **Riesgo**

NO existe riesgo o daño al participar en la investigación. Sin embargo, en el caso que existan preguntas que le puedan generar incomodidad. Usted tiene la libertad de responderlas o no.

#### **Beneficios**

Los resultados de la investigación serán alcanzados a la institución al término de la investigación. No recibirá ningún beneficio económico ni de ninguna otra índole. El estudio no va a aportar individualmente a la persona, sin embargo, los resultados del estudio podrán convertirse en beneficio pública en el ámbito educativo.

#### **Confidencialidad:**

Los datos recolectados son anónimos y no existe ninguna forma de identificar al participante. Garantizamos que la información que usted nos brinde es totalmente Confidencial y no será usada para ningún otro propósito fuera de la investigación. Los datos permanecerán bajo custodia del investigador principal y pasado un tiempo determinado serán eliminados convenientemente.

#### **Problemas o preguntas:**

Si tiene preguntas sobre la investigación puede contactar con el Investigador Pandal Blas Carlos Enrique email: [pandalcarlos@gmail.com](mailto:pandalcarlos@gmail.com) y Docente asesor Dr. Vargas Huaman, Jhonatar| Issac email: [jvargash@ucvvirtual.edu.pe](mailto:jvargash@ucvvirtual.edu.pe)

#### **Consentimiento:**

Después de haber leído los propósitos de la investigación autorizo participar en la investigación antes mencionada.

Nombre y apellidos: .....

Fecha y hora: .....

Firma:

## Anexo 6: Matriz Evaluación por juicio de expertos

### Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Inventario de Procesos de Autorregulación del Aprendizaje". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente, aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

#### 1. Datos generales del juez:

Nombre del juez:	Labeñano Matías Andrade Arenas	
Grado profesional:	Maestría ( )	Doctor (X)
Área de formación académica:	Clinica ( )	Social ( ) Educativa (X)
Áreas de experiencia profesional:	Gestión educativa	
Institución donde labora:	Universidad de Ciencias y Humanidades	
Tiempo de experiencia profesional en el área:	2 a 4 años ( )	Más de 5 años (X)
Experiencia en Investigación Psicométrica: (si corresponde)		

#### 2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

#### 3. Datos de la escala (Inventario de Procesos de Autorregulación del Aprendizaje)

Nombre de la Prueba:	Inventario de Procesos de Autorregulación del Aprendizaje
Autor:	Pandal Blas Carlos Enrique
Procedencia:	Adaptado de Rosário et al. (2007) de la Universidad de Oviedo-España y Bruna et al. (2017) de la Universidad de Concepción-Chile
Administración:	La encuesta tipo Likert se administrará en forma de cuestionario impreso o electrónico, dependiendo de la disponibilidad y preferencia de los participantes.
Tiempo de aplicación:	10 minutos.
Ámbito de aplicación:	Academia preuniversitaria privada, Lima 2023.
Significación:	Está compuesta por tres dimensiones, su primera dimensión Planificación, considera el indicador planificación formado por los ítems P1, P10 y P12; su segunda dimensión Ejecución, considera el indicador ejecución formado por los ítems P3, P5, P8 y P6; y su tercera dimensión Evaluación, considera el indicador evaluación formado por los ítems P2, P4, P7, P9 y P11, siendo medidos mediante el cuestionario, empleando la escala de tipo Likert, con 5 categorías: 1,2,3,4,5. El objetivo de la medición es determinar la autorregulación del aprendizaje en base al estudio de sus tres dimensiones

#### 4. Soporte teórico (describir en función al modelo teórico)

Escala/ÁREA	Subescala (dimensiones)	Definición
Autorregulación del aprendizaje	Planificación	Es explicada por Bruna et al. (2017) como la fase de preparación o disposición, que consiste en un conjunto de actividades que son importantes para llevar a cabo el análisis de tareas, establecer objetivos y planificar acciones para su aprendizaje.
	Ejecución	Es definida por Bruna et al. (2017) como la fase de desempeño, en la cual se realiza la actividad asignada y se finaliza el trabajo mientras se supervisa el progreso del rendimiento.
	Evaluación	Es definida por Bruna et al. (2017) como la fase de autorreflexión que incluye la autoevaluación y la reflexión de los resultados.

#### 5. Presentación de instrucciones para el juez:

A continuación, a usted le presento el Inventario de Procesos de Autorregulación del Aprendizaje elaborado por Daniela Bruna, María Victoria Pérez, Claudio Bustos y José Carlos Núñez en el año 2017. De acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda.

Categoría	Calificación	Indicador
CLARIDAD El ítem se comprende fácilmente, es decir, su sintáctico y semántica son adecuadas.	1. No cumple con el criterio	El ítem no es claro.
	2. Bajo Nivel	El ítem requiere bastantes modificaciones o una modificación muy grande en el uso de las palabras de acuerdo con su significado o por la ordenación de estas.
	3. Moderado nivel	Se requiere una modificación muy específica de algunos de los términos del ítem.
	4. Alto nivel	El ítem es claro, tiene semántica y sintaxis adecuada.
COHERENCIA El ítem tiene relación lógica con la dimensión o indicador que está midiendo.	1. totalmente en desacuerdo (no cumple con el criterio)	El ítem no tiene relación lógica con la dimensión.
	2. Desacuerdo (bajo nivel de acuerdo)	El ítem tiene una relación tangencial /lejana con la dimensión.
	3. Acuerdo (moderado nivel)	El ítem tiene una relación moderada con la dimensión que se está midiendo.
	4. Totalmente de Acuerdo (altónivel)	El ítem se encuentra está relacionado con la dimensión que está midiendo.
RELEVANCIA El ítem es esencialmente importante, es decir debe ser incluido.	1. No cumple con el criterio	El ítem puede ser eliminado sin que se vea afectada la medición de la dimensión.
	2. Bajo Nivel	El ítem tiene alguna relevancia, pero otro ítem puede estar incluyendo lo que mide éste.
	3. Moderado nivel	El ítem es relativamente importante.
	4. Alto nivel	El ítem es muy relevante y debe ser incluido.

Leer con detenimiento los ítems y calificar en una escala de 1 a 4 su valoración, así como solicitamos brindes sus observaciones que considere pertinente

1. No cumple con el criterio
2. Bajo Nivel
3. Moderado nivel
4. Alto nivel

Dimensiones del instrumento: Inventario de Procesos de Autorregulación del Aprendizaje

#### • Primera dimensión: Planificación

Objetivos de la Dimensión: Determinar el nivel de preparación o disposición del estudiante para llevar a cabo el análisis de tareas, establecer objetivos y planificar las acciones para su aprendizaje.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Planificación	P1. Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos.	4	4	4	
	P10. Busco un sitio tranquilo y donde pueda estar concentrado para estudiar.	4	4	3	
	P12. Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con Internet, libros, lápices, cuadernos, fotocopias para no estar siempre interrumpiendo mi estudio.	4	4	4	

• Segunda dimensión: Ejecución

Objetivos de la Dimensión: Determinar el nivel de desempeño del estudiante para realizar la actividad asignada, las estrategias cognitivas y búsqueda.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Ejecución	P3. Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos.	4	4	3	
	P5. Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.	4	3	4	
	P8. Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.	4	4	4	
	P6. Cumpló mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario	3	4	4	

• Tercera dimensión: Evaluación

Objetivos de la Dimensión: Determinar el nivel de autorreflexión del estudiante mediante la autoevaluación de la planificación del estudio y el aprendizaje y la reflexión de los resultados.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Evaluación	P2. Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.	4	4	4	
	P4. Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.	4	4	3	
	P7. Guardó y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.	4	3	4	
	P9. Establezco objetivos académicos concretos para cada asignatura	4	4	4	
	P11. Comparo las notas que saoco con los objetivos que me había marcado para esa asignatura	3	4	4	



FIRMA DEL EVALUADOR  
DNI: 07146324



### Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Inventario de Procesos de Autorregulación del Aprendizaje". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

#### 1. Datos generales del juez:

<b>Nombre del juez:</b>	LUIS ROMERO UNIVEROS	
<b>Grado profesional:</b>	Maestría (X)	Doctor ( )
<b>Área de formación académica:</b>	Clinica ( )	Social (X)
	Educativa (X)	Organizacional (X)
<b>Áreas de experiencia profesional:</b>	Gestión y dirección de proyectos Educación Soluciones tecnológicas y adopción de tecnología	
<b>Institución donde labora:</b>	Universidad de Ciencias y Humanidades	
<b>Tiempo de experiencia profesional en el área:</b>	2 a 4 años ( )	Más de 5 años (X)
<b>Experiencia en Investigación Psicométrica:</b> (si corresponde)	Impacto de los errores de software en los usuarios.	

#### 2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

#### 3. Datos de la escala (Inventario de Procesos de Autorregulación del Aprendizaje)

<b>Nombre de la Prueba:</b>	Inventario de Procesos de Autorregulación del Aprendizaje
<b>Autor:</b>	Pandaf Blas Carlos Enrique
<b>Procedencia:</b>	Adaptado de Rosário et al. (2007) de la Universidad de Oviedo-España y Bruna et al. (2017) de la Universidad de Concepción-Chile
<b>Administración:</b>	La encuesta tipo Likert se administrará en forma de cuestionario impreso o electrónico, dependiendo de la disponibilidad y preferencia de los participantes.
<b>Tiempo de aplicación:</b>	10 minutos.

LUIS ALFREDO ROMERO UNIVEROS  
INGENIERO DE SISTEMAS  
Reg. CIP. 171260

<b>Ámbito de aplicación:</b>	Academia preuniversitaria privada, Lima 2023.
<b>Significación:</b>	Está compuesta por tres dimensiones, su primera dimensión Planificación, considera el indicador planificación formado por los ítems P1, P10 y P12; su segunda dimensión Ejecución, considera el indicador ejecución formado por los ítems P3, P5, P8 y P6; y su tercera dimensión Evaluación, considera el indicador evaluación formado por los ítems P2, P4, P7, P9 y P11, siendo medidos mediante el cuestionario, empleando la escala de tipo Likert, con 5 categorías: 1,2,3,4,5. El objetivo de la medición es determinar la autorregulación del aprendizaje en base al estudio de sus tres dimensiones.

#### 4. Soporte teórico (reescribir en función al modelo teórico)

Escola/ÁREA	Subescala (dimensiones)	Definición
AUTORREGULACIÓN del aprendizaje	Planificación	Es explicada por Bruna et al. (2017) como la fase de preparación o disposición, que consiste en un conjunto de actividades que son importantes para llevar a cabo el análisis de tareas, establecer objetivos y planificar acciones para su aprendizaje.
	Ejecución	Es definida por Bruna et al. (2017) como la fase de desempeño, en la cual se realiza la actividad asignada y se finaliza el trabajo mientras se supervisa el progreso del rendimiento.
	Evaluación	Es definida por Bruna et al. (2017) como la fase de autorreflexión que incluye la autoevaluación y la reflexión de los resultados.

#### 5. Presentación de instrucciones para el juez:

A continuación, a usted le presento el **Inventario de Procesos de Autorregulación del Aprendizaje** elaborado por Daniela Bruna, María Victoria Pérez, Claudio Bustos y José Carlos Núñez en el año 2017. De acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda.

Categoría	Calificación	Indicador
CLARIDAD El ítem se comprende fácilmente, es decir, su sintáctica y semántica son adecuadas.	1. No cumple con el criterio	El ítem no es claro.
	2. Bajo Nivel	El ítem requiere bastantes modificaciones o unamodificación muy grande en el uso de las palabras de acuerdo con su significado o por la ordenación de éstas.
	3. Moderado nivel	Se requiere una modificación muy específica de algunos de los términos del ítem.

LUIS ALFREDO ROMERO UNIVEROS  
INGENIERO DE SISTEMAS  
Reg. CIP. 171260

	4. Alto nivel	El ítem es claro, tiene semántica y sintaxis adecuada.
<b>COHERENCIA</b> El ítem tiene relación lógica con la dimensión o indicador que está midiendo.	1. totalmente en desacuerdo (no cumple con el criterio)	El ítem no tiene relación lógica con la dimensión.
	2. Desacuerdo (bajo nivel de acuerdo)	El ítem tiene una relación tangencial /lejana con la dimensión.
	3. Acuerdo (moderado nivel)	El ítem tiene una relación moderada con la dimensión que se está midiendo.
	4. Totalmente de Acuerdo (alto nivel)	El ítem se encuentra está relacionado con la dimensión que está midiendo.
<b>RELEVANCIA</b> El ítem es esencial o importante, es decir debe ser incluido.	1. No cumple con el criterio	El ítem puede ser eliminado sin que se vea afectada la medición de la dimensión.
	2. Bajo Nivel	El ítem tiene alguna relevancia, pero otro ítem puede estar incluyendo lo que mide éste.
	3. Moderado nivel	El ítem es relativamente importante.
	4. Alto nivel	El ítem es muy relevante y debe ser incluido.

Leer con detenimiento los ítems y calificar en una escala de 1 a 4 su valoración, así como solicitamos brinde sus observaciones que considere pertinente

1. No cumple con el criterio
2. Bajo Nivel
3. Moderado nivel
4. Alto nivel

**Dimensiones del Instrumento:** Inventario de Procesos de Autorregulación del Aprendizaje

• **Primera dimensión:** Planificación

Objetivos de la Dimensión: Determinar el nivel de preparación o disposición del estudiante para llevar a cabo el análisis de tareas, establecer objetivos y planificar las acciones para su aprendizaje.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Planificación	P1. Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos.	4	4	4	
	P10. Busco un sitio tranquilo y donde pueda estar concentrado para estudiar.	4	4	4	Mejorar la redacción "Busco un lugar tranquilo y donde pueda concentrarme para estudiar".
	P12. Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con internet, libros, lápices, cuadernos, fotocopias pero no estar siempre interrumpiendo mi estudio.	4	4	4	

LUIS ALFREDO ROMERO UNTIVEROS  
INGENIERO DE SISTEMAS  
Reg. CIP. 171269

• **Segunda dimensión:** Ejecución

Objetivos de la Dimensión: Determinar el nivel de desempeño del estudiante para realizar la actividad asignada, las estrategias cognitivas y búsqueda.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Ejecución	P3. Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos.	4	4	4	
	P5. Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.	4	4	4	
	P8. Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.	4	4	4	
	P6. Cumpló mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario	4	4	4	

• **Tercera dimensión:** Evaluación

Objetivos de la Dimensión: Determinar el nivel de autorreflexión del estudiante mediante la autoevaluación de la planificación del estudio y el aprendizaje y la reflexión de los resultados.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Evaluación	P2. Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.	4	4	4	
	P4. Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.	4	4	4	
	P7. Guardo y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.	4	4	4	
	P9. Establezco objetivos académicos concretos para cada asignatura	4	4	4	
	P11. Comparo las notas que saqué con los objetivos que me había marcado para esa asignatura	4	4	4	Mejorar la redacción: "Comparo las calificaciones que obtengo con los objetivos que me había marcado para esa asignatura"

LUIS ALFREDO ROMERO UNTIVEROS  
INGENIERO DE SISTEMAS  
Reg. CIP. 171269

FIRMA DEL EVALUADOR  
DNI: 10692220

## Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Inventario de Procesos de Autorregulación del Aprendizaje". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

### 1. Datos generales del juez:

Nombre del juez:	Alan Leoncio Fierro Barriales	
Grado profesional:	Maestría (X)	Doctor ( )
Área de formación académica:	Clinica ( )	Social ( )
	Educativa (X)	Organizacional ( )
Áreas de experiencia profesional:	Desarrollo de Software, Implementación de Base de Datos, Diseño Web	
Institución donde labora:	Universidad César Vallejo	
Tiempo de experiencia profesional en el área:	2 a 4 años ( )	Más de 5 años (x)
Experiencia en Investigación Psicométrica: (si corresponde)		

### 2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

### 3. Datos de la escala (Inventario de Procesos de Autorregulación del Aprendizaje)

Nombre de la Prueba:	Inventario de Procesos de Autorregulación del Aprendizaje
Autor:	Pandal Blas Carlos Enrique
Procedencia:	Adaptado de Rosário et al. (2007) de la Universidad de Oviedo-España y Bruna et al. (2017) de la Universidad de Concepción-Chile
Administración:	La encuesta tipo Likert se administrará en forma de cuestionario impreso o electrónico, dependiendo de la disponibilidad y preferencia de los participantes.
Tiempo de aplicación:	10 minutos.
Ámbito de aplicación:	Academia preuniversitaria privada, Lima 2023.
Significación:	Está compuesta por tres dimensiones, su primera dimensión Planificación, considera el indicador planificación formado por los ítems P1, P10 y P12; su segunda dimensión Ejecución, considera el indicador ejecución formado por los ítems P3, P5, P8 y P6; y su tercera dimensión Evaluación, considera el indicador evaluación formado por los ítems P2, P4, P7, P9 y P11, siendo medidos mediante el cuestionario, empleando la escala de tipo Likert, con 5 categorías: 1,2,3,4,5. El objetivo de la medición es determinar la autorregulación del aprendizaje en base al estudio de sus tres dimensiones

### 4. Soporte teórico (describir en función al modelo teórico)

Escala/ÁREA	Subescala (dimensiones)	Definición
Autorregulación del aprendizaje	Planificación	Es explicada por Bruna et al. (2017) como la fase de preparación o disposición, que consiste en un conjunto de actividades que son importantes para llevar a cabo el análisis de tareas, establecer objetivos y planificar acciones para su aprendizaje.
	Ejecución	Es definida por Bruna et al. (2017) como la fase de desempeño, en la cual se realiza la actividad asignada y se finaliza el trabajo mientras se supervisa el progreso del rendimiento.
	Evaluación	Es definida por Bruna et al. (2017) como la fase de autorreflexión que incluye la autoevaluación y la reflexión de los resultados.

### 5. Presentación de instrucciones para el juez:

A continuación, a usted le presento el Inventario de Procesos de Autorregulación del Aprendizaje elaborado por Daniela Bruna, María Victoria Pérez, Claudio Bustos y José Carlos Núñez en el año 2017. De acuerdo con los siguientes indicadores califique cada uno de los ítems según corresponda.

Categoría	Calificación	Indicador
<b>CLARIDAD</b> El ítem se comprende fácilmente, es decir, su sintácticas y semántica son adecuadas.	1. No cumple con el criterio	El ítem no es claro.
	2. Bajo Nivel	El ítem requiere bastantes modificaciones o una modificación muy grande en el uso de las palabras de acuerdo con su significado o por la ordenación de éstas.
	3. Moderado nivel	Se requiere una modificación muy específica de algunos de los términos del ítem.
	4. Alto nivel	El ítem es claro, tiene semántica y sintaxis adecuada.
<b>COHERENCIA</b> El ítem tiene relación lógica con la dimensión o indicador que está midiendo.	1. totalmente en desacuerdo (nó cumple con el criterio)	El ítem no tiene relación lógica con la dimensión.
	2. Desacuerdo (bajo nivel de acuerdo)	El ítem tiene una relación tangencial /lejana con la dimensión.
	3. Acuerdo (moderado nivel)	El ítem tiene una relación moderada con la dimensión que se está midiendo.
	4. Totalmente de Acuerdo (alt nivel)	El ítem se encuentra está relacionado con la dimensión que está midiendo.
<b>RELEVANCIA</b> El ítem es esencialmente importante, es decir debe ser incluido.	1. No cumple con el criterio	El ítem puede ser eliminado sin que se vea afectada la medición de la dimensión.
	2. Bajo Nivel	El ítem tiene alguna relevancia, pero otro ítem puede estar incluyendo lo que mide éste.
	3. Moderado nivel	El ítem es relativamente importante.
	4. Alto nivel	El ítem es muy relevante y debe ser incluido.

Leer con detenimiento los ítems y calificar en una escala de 1 a 4 su valoración, así como solicitamos brindes sus observaciones que considere pertinente

1. No cumple con el criterio
2. Bajo Nivel
3. Moderado nivel
4. Alto nivel

Dimensiones del instrumento: Inventario de Procesos de Autorregulación del Aprendizaje

#### • Primera dimensión: Planificación

Objetivos de la Dimensión: Determinar el nivel de preparación o disposición del estudiante para llevar a cabo el análisis de tareas, establecer objetivos y planificar las acciones para su aprendizaje.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Planificación	P1. Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos.	4	4	3	
	P10. Busco un sitio tranquilo y donde pueda estar concentrado para estudiar.	4	3	4	
	P12. Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con Internet, libros, lápices, cuadernos, fotocopias para no estar siempre interrumpiendo mi estudio.	4	4	4	

- **Segunda dimensión: Ejecución**

Objetivos de la Dimensión: Determinar el nivel de desempeño del estudiante para realizar la actividad asignada, las estrategias cognitivas y búsqueda.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Ejecución	P3. Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos.	4	4	4	
	P5. Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.	3	4	4	
	P8. Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.	4	4	4	
	P6. Cumpló mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario	4	4	3	

- **Tercera dimensión: Evaluación**

Objetivos de la Dimensión: Determinar el nivel de autorreflexión del estudiante mediante la autoevaluación de la planificación del estudio y el aprendizaje y la reflexión de los resultados.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Evaluación	P2. Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.	4	4	4	
	P4. Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.	4	3	4	
	P7. Guardo y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.	4	4	4	
	P9. Establezco objetivos académicos concretos para cada asignatura	4	4	4	
	P11. Comparo las notas que saco con los objetivos que me había marcado para esa asignatura	4	4	4	



FIRMA DEL EVALUADOR  
DNI: 44147992

## Anexo 7: Cálculo del tamaño de la muestra

La población en la presente investigación es de 1322 estudiantes pertenecientes a dos ciclos académicos Ciclo A con 982 estudiantes y Ciclo B con 340 estudiantes. Para estimar la muestra total se utilizó la siguiente fórmula:

$$n = \frac{N * Z_{\alpha}^2 * p * q}{\varepsilon^2 * (N - 1) + Z_{\alpha}^2 * p * q}$$

Donde:

$Z$  : Valor estadístico para una confianza de  $(1-\alpha)$

$p$  : Probabilidad de éxito del evento.

$q$  : Probabilidad de fracaso del evento. ( $q = 1 - p$ )

$\varepsilon$  : Tolerancia de error

$N$  : Tamaño de la población.

$$n = \frac{1322 * 1.96^2 * 0.5 * 0.5}{0.05^2 * (1322 - 1) + 1.96^2 * 0.5 * 0.5} = 297.836872$$

Como la muestra debe ser entera, entonces la muestra total es de  $n = 298$  estudiantes. Para calcular la muestra estratificada para cada ciclo se obtuvo la proporcionalidad correspondiente:

$$\%CicloA = \frac{Estudiantes\ CicloA}{N} * 100\% = \frac{982}{1322} * 100\% = 74.28\%$$

$$\%CicloB = \frac{Estudiantes\ CicloB}{N} * 100\% = \frac{340}{1322} * 100\% = 25.72\%$$

Por lo tanto, la muestra estratificada para cada ciclo es:

$$MuestraCicloA = n * 74.28\% = 221.3544 \approx 221$$

$$MuestraCicloB = n * 25.72\% = 76.6456 \approx 77$$

*Tabla de muestra estratificada proporcional*

	<b>Población</b>	<b>Proporción</b>	<b>Muestra</b>
Estudiantes del CICLO A	982	74.28%	221
Estudiantes del CICLO B	340	25.72%	77
Total	1322	100%	298

## Anexo 8: Confiabilidad de los instrumentos de recolección de datos

Se utilizó la prueba Alfa de Cronbach para determinar la confiabilidad del cuestionario, obteniéndose 0.871, concluyendo que el instrumento es confiable. A partir de la Figura 2, se evaluó que eliminando ítems no aumentaría el alfa de Cronbach por lo que se decidió mantener los 12 ítems.

### Alfa de Cronbach

Alfa de Cronbach	Alfa de Cronbach basada en elementos estandarizados	N de elementos
,871	,872	12

Fuente: Base de datos procesado en software estadístico SPSS v.25

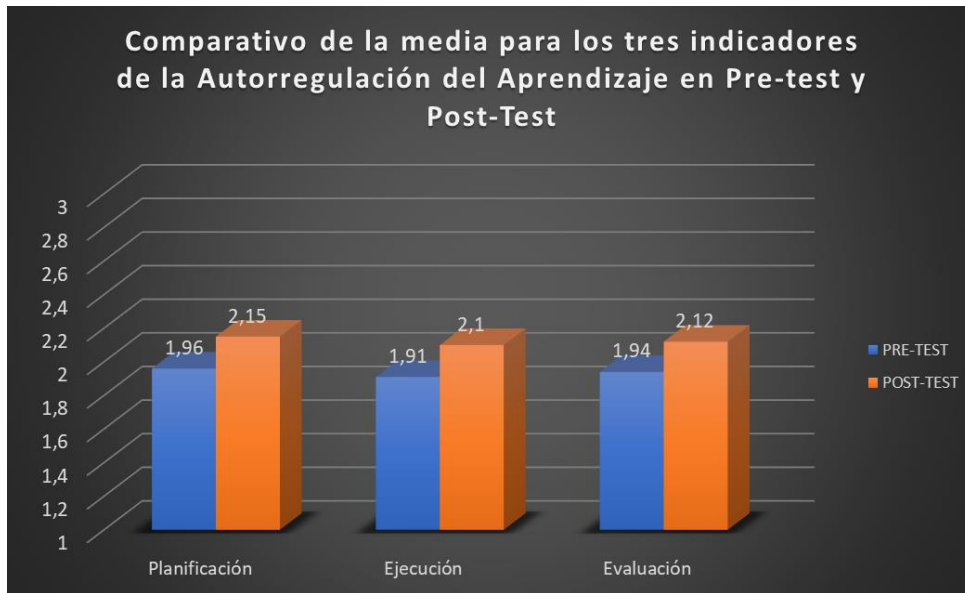
### Alfa de Cronbach eliminado ítem

	Media de escala si el elemento se ha suprimido	Varianza de escala si el elemento se ha suprimido	Correlación total de elementos corregida	Correlación múltiple al cuadrado	Alfa de Cronbach si el elemento se ha suprimido
P1.Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos	38,52	54,143	,580	,389	,860
P2.Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener.	38,43	54,495	,462	,283	,868
P3.Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos	38,03	54,733	,578	,370	,860
P4.Cuando recibo una nota, suelo pensar en cosas concretas que tengo que hacer para mejorar mi rendimiento y nota promedio.	38,05	53,897	,618	,421	,857
P5.Estoy seguro de que soy capaz de comprender lo que me van a enseñar y por eso creo que voy a tener buenas notas.	38,32	56,890	,425	,248	,869
P6.Cumplo mis horarios de estudio, e introduzco pequeños cambios siempre que es necesario	38,81	53,920	,602	,412	,858
P7.Guardo y analizo las correcciones de los trabajos escritos o pruebas parciales, para ver dónde me equivoqué y saber qué tengo que cambiar para mejorar.	38,31	54,167	,558	,350	,861
P8.Mientras estoy en clase o estudiando, si me distraigo o pierdo el hilo, suelo hacer algo para volver a la tarea y alcanzar mis objetivos.	38,27	55,158	,549	,350	,862
P9.Establezco objetivos académicos concretos para cada asignatura	38,43	53,876	,639	,468	,856
P10.Busco un sitio tranquilo y donde pueda estar concentrado para estudiar	37,78	54,947	,496	,340	,865
P11.Comparo las notas que saco con los objetivos que me había marcado para esa asignatura	38,37	51,702	,688	,504	,852
P12.Antes de comenzar a estudiar, compruebo si tengo todo lo que necesito: boletines, dispositivo con Internet, libros, lápices, cuadernos, fotocopias para no estar siempre interrumpiendo mi estudio	37,82	54,811	,519	,336	,863

Fuente: Base de datos procesado en software estadístico SPSS v.25

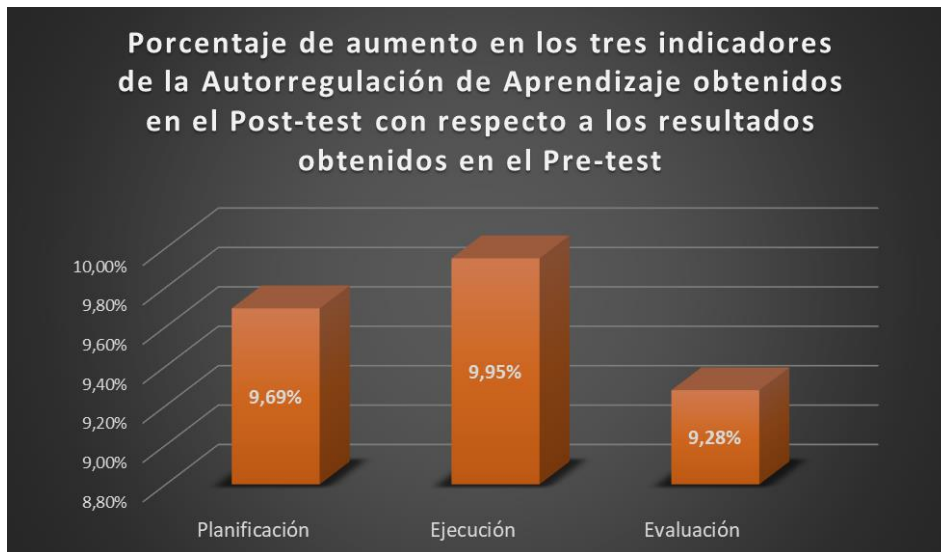
## Anexo 9: Figuras del Análisis Descriptivo

### Comparativo de Medias Pre-test y Post-test



Fuente: Base de datos procesado en software estadístico SPSS v.25

### Porcentaje de aumento en el Post-test con respecto al Pre-test



Fuente: Base de datos procesado en software estadístico SPSS v.25

## Anexo 10: Pruebas de Normalidad

En la Figura 3 se muestran resultados de la prueba de normalidad, considerando una muestra de  $298 > 50$  entonces, se evalúa según la prueba de Kolmogorov-Smirnov, donde se observa la significancia  $p = 0$  en todos los pre y post.

### Pruebas de normalidad

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Pre - Autorregulación del aprendizaje	,212	298	,000	,803	298	,000
Pre - Planificación	,224	298	,000	,799	298	,000
Pre - Ejecución	,219	298	,000	,806	298	,000
Pre - Evaluación	,234	298	,000	,795	298	,000
Post - Autorregulación del aprendizaje	,248	298	,000	,794	298	,000
Post - Planificación	,262	298	,000	,787	298	,000
Post - Ejecución	,222	298	,000	,805	298	,000
Post - Evaluación	,230	298	,000	,803	298	,000

a. Corrección de significación de Lilliefors

*Fuente:* Base de datos procesado en software estadístico SPSS v.25



## Anexo 11: Pruebas de Hipótesis

### Prueba de Wilcoxon- Planificación

```
*Nonparametric Tests: Related Samples.
NPTESTS
/RELATED TEST(Pre_Plan Post_Plan) WILCOXON
/MISSING SCOPE=ANALYSIS USERMISSING=EXCLUDE
/CRITERIA ALPHA=0.05 CILEVEL=95.
```

► **Pruebas no paramétricas**

[ConjuntoDatos1] D:\Maestria\TESIS 2023\SPSS\DATA\_AMBOS\Data\_ambos\_prepost.sav

**Resumen de prueba de hipótesis**

	Hipótesis nula	Prueba	Sig.	Decisión
1	La mediana de las diferencias entre Pre - Planificación y Post - Planificación es igual a 0.	Prueba de rangos con signo de Wilcoxon para muestras relacionadas	,002	Rechazar la hipótesis nula.

Se muestran significaciones asintóticas. El nivel de significación es de ,05.

Fuente: Base de datos procesado en software estadístico SPSS v.25

### Prueba de Wilcoxon - Ejecución

```
*Nonparametric Tests: Related Samples.
NPTESTS
/RELATED TEST(Pre_Ejec Post_Ejec) WILCOXON
/MISSING SCOPE=ANALYSIS USERMISSING=EXCLUDE
/CRITERIA ALPHA=0.05 CILEVEL=95.
```

**Pruebas no paramétricas**

**Resumen de prueba de hipótesis**

	Hipótesis nula	Prueba	Sig.	Decisión
1	La mediana de las diferencias entre Pre - Ejecución y Post - Ejecución es igual a 0.	Prueba de rangos con signo de Wilcoxon para muestras relacionadas	,003	Rechazar la hipótesis nula.

Se muestran significaciones asintóticas. El nivel de significación es de ,05.

Fuente: Base de datos procesado en software estadístico SPSS v.25

## Prueba de Wilcoxon - Evaluación

```
*Nonparametric Tests: Related Samples.  
NPTESTS  
/RELATED TEST(Pre_Eval Post_Eval) WILCOXON  
/MISSING SCOPE=ANALYSIS USERMISSING=EXCLUDE  
/CRITERIA ALPHA=0.05 CILEVEL=95.
```

➔ **Pruebas no paramétricas**

**Resumen de prueba de hipótesis**

	Hipótesis nula	Prueba	Sig.	Decisión
1	La mediana de las diferencias entre Pre - Evaluación y Post - Evaluación es igual a 0.	Prueba de rangos con signo de Wilcoxon para muestras relacionadas	,008	Rechazar la hipótesis nula.

Se muestran significaciones asintóticas. El nivel de significación es de ,05.

*Fuente:* Base de datos procesado en software estadístico SPSS v.25

## Anexo 12: Baremación

### Baremación Planificación

Estadísticos			
Planificación			
N	Válido	298	
	Perdidos	0	
Mínimo		3	
Máximo		15	
Percentiles	30	10,00	
	70	12,30	
MÍNIMO	P30	P70	MAXIMO
3	10	12,3	15
	3 a 10	Nivel bajo	
	11 a 12	Nivel Medio	
	13 a 15	Nivel Alto	

Fuente: Base de datos procesado en software estadístico SPSS v.25

### Baremación Ejecución

Estadísticos			
Ejecución			
N	Válido	298	
	Perdidos	0	
Mínimo		6	
Máximo		20	
Percentiles	30	12,00	
	70	15,00	
MÍNIMO	P30	P70	MAXIMO
6	12	15	20
	6 a 12	Nivel bajo	
	13 a 15	Nivel Medio	
	16 a 20	Nivel Alto	

Fuente: Base de datos procesado en software estadístico SPSS v.25

## Baremación Evaluación

Estadísticos			
Evaluación			
N	Válido	298	
	Perdidos	0	
Mínimo		5	
Máximo		25	
Percentiles	30	15,00	
	70	19,30	
MÍNIMO	P30	P70	MAXIMO
5	15	19,3	25
	5 a 15	Nivel bajo	
	16 a 19	Nivel Medio	
	20 a 25	Nivel Alto	

Fuente: Base de datos procesado en software estadístico SPSS v.25





## Anexo 14: Tomado de la Encuesta y Fotos de la Actividad

### Inventario de Procesos de Autorregulación del Aprendizaje

Estimado estudiante, el presente cuestionario es parte de un estudio para conocer la influencia de Machine Learning en la autorregulación del aprendizaje. Se agradece puedas participar en esta encuesta anónima y voluntaria respondiendo 12 preguntas con 5 opciones de respuesta, donde 1: **Nunca**, 2: **Casi nunca**, 3: **A veces**, 4: **Casi siempre** y 5: **Siempre**.

Por favor, lee cada pregunta cuidadosamente y selecciona el número que mejor refleje tu opinión o experiencia.

cpandal@ucvvirtual.edu.pe [Cambiar de cuenta](#)

No compartido

\* Indica que la pregunta es obligatoria

Luego de leer el documento de [Consentimiento Informado](#) \*

Doy mi consentimiento de participar en la investigación

**Ciclo de estudios** \*

Elige

**Pregunta 01** \*

Hago un plan antes de comenzar a estudiar los cursos. Pienso lo que voy a hacer y lo que necesito para aprenderlos.

Nunca      1      2      3      4      5      Siempre

**Pregunta 02** \*

Después de terminar un Examen Semanal, Simulacro o Test, lo reviso mentalmente para saber dónde tuve los aciertos y errores y, hacerme una idea de la nota que voy a tener

Nunca      1      2      3      4      5      Siempre

**Pregunta 03** \*

Cuando estudio, intento comprender las materias, tomar apuntes, hacer resúmenes, resolver ejercicios, hacer preguntas sobre los contenidos

Url del formulario: <https://forms.gle/HN7xYYajoDyZjmgW8>

Explicaciones previas al tomado de la encuesta en una de las aulas de la academia preuniversitaria del estudio de investigación.



Aquí en otra de las aulas.



Se utilizó un formulario de Google para la recolección los datos, debido a que todas las aulas de la institución cuentan con WIFI y a que la mayoría de estudiantes cuenta con un celular, pues es necesario para sus actividades de clase diarias y retroalimentación.



## Anexo 15: Metodología de desarrollo de la aplicación en Machine Learning

### Historias de usuario

Historia	Título	Descripción (como,quiero,para)	Prioridad	Tiempo estimado
HU1	Ingreso al Sistema como Estudiante	Como estudiante preuniversitario o postulante a la UNMSM, quiero poder ingresar al sistema web utilizando mi nombre de usuario o correo electrónico y contraseña para acceder a las funcionalidades del sistema	1	1
HU2	Selección de Especialidad	Como estudiante logueado, quiero tener la opción de seleccionar la especialidad a la que deseo postular para el próximo examen de admisión, para visualizar la información relacionada con esa especialidad.	2	1
HU3	Visualización de Últimas Notas	Como estudiante logueado y habiendo seleccionado una especialidad, quiero ver las últimas 6 notas de mis exámenes semanales en la academia ADUNI. La última nota debe ser editable para que pueda realizar pruebas y simular diferentes escenarios.	2	2
HU4	Cálculo de Estimación de Nota	Como estudiante logueado, quiero poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado con datos históricos de estudiantes aprobados en el examen de ingreso anterior, para estimar la nota que podría obtener en el próximo examen de admisión.	3	3
HU5	Visualización de Opciones de Especialidades	Como estudiante logueado y después de calcular mi posible nota de ingreso, quiero ver una lista de especialidades a las que podría ingresar con esa puntuación estimada. La lista debe incluir información como los puntajes mínimos y máximos requeridos, la cantidad de postulantes y la cantidad de ingresantes del último año.	2	1
HU6	Cambio de Especialidad y Notas para Simulación	Como estudiante logueado, quiero tener la opción de cambiar la especialidad seleccionada y la última de mis notas para probar diferentes resultados y ver cómo afectarían mis probabilidades de ingreso en otras especialidades.	2	1
HU7	Consultas mediante la API de ChatGPT	Como estudiante logueado, quiero tener la capacidad de realizar consultas adicionales utilizando la API de ChatGPT integrada en el sistema, para obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, deseo que las preguntas y respuestas se almacenen en una base de datos y tener la opción de borrarlos si así lo deseo.	4	3

### Scrum Team (Equipo scrum)

Rol	Cargo	Persona
Scrum Master	Responsable del área de desarrollo de TI	Nilo Saravia
Product Owner	Director del Tecnologías de la Información	Juan Infante
Desarrollador	Tesista	Pandal Blas Carlos Enrique

### Matriz de impacto

Prioridad	
Muy alta	1
Alta	2
Media	3
Baja	4
Muy Baja	5

## Product Backlog

Muestra los requerimientos funcionales debidamente especificados con su número de historia, prioridad y tiempo estimado.

### Pila del Producto Inicial (Product Backlog)

ReqFun	Título	Descripción	Historias	Tiempo estimado	Prioridad
RF1	Iniciar Sesión	Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.	HU1	1	1
RF2	Seleccionar Especialidad	Después de iniciar sesión, el estudiante debe tener la opción de seleccionar la especialidad a la que desea postular para el próximo examen de admisión.	HU2	1	2
RF3	Mostrar Últimas 6 Notas de Exámenes Semanales	Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.	HU3	2	2
RF4	Calcular Nota Estimada de Examen de Admisión	Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.	HU4	3	3
RF5	Mostrar Opciones de Especialidades	Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.	HU5	1	2
RF6	Permitir Cambio de Especialidad y Última Nota	Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.	HU6	1	2
RF7	Utilizar API de ChatGPT para Consultas	En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.	HU7	3	4

### Pila del Producto Organizada por Prioridad (Product Backlog)

ReqFun	Título	Descripción	Historias	Tiempo estimado	Prioridad
RF1	Iniciar Sesión	Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.	HU1	1	1
RF2	Seleccionar Especialidad	Después de iniciar sesión, el estudiante debe tener la opción de seleccionar la especialidad a la que desea postular para el próximo examen de admisión.	HU2	1	2
RF3	Mostrar Últimas 6 Notas de Exámenes Semanales	Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.	HU3	2	2
RF5	Mostrar Opciones de Especialidades	Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.	HU5	1	2
RF6	Permitir Cambio de Especialidad y Última Nota	Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.	HU6	1	2
RF4	Calcular Nota Estimada de Examen de Admisión	Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.	HU4	3	3
RF7	Utilizar API de ChatGPT para Consultas	En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.	HU7	3	4

## Entregables por Sprint

En este punto se detalla la cantidad de Sprints, los requerimientos funcionales de la Pila de Producto y sus respectivos prioridades y tiempos estimados.

SPRINT 1	RF1	Iniciar Sesión	Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.	HU1	1	1
	RF2	Seleccionar Especialidad	Después de iniciar sesión, el estudiante debe tener la opción de seleccionar la especialidad a la que desea postular para el próximo examen de admisión.	HU2	1	2
	RF3	Mostrar Últimas 6 Notas de Exámenes Semanales	Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.	HU3	2	2
	RF5	Mostrar Opciones de Especialidades	Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.	HU5	1	2
	RF6	Permitir Cambio de Especialidad y Última Nota	Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.	HU6	1	2
	RF4	Calcular Nota Estimada de Examen de Admisión	Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.	HU4	3	3
SPRINT 2	RF7	Utilizar API de ChatGPT para Consultas	En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.	HU7	3	4

# Plan de trabajo

Tarea	Recurso	Informe	Proyecto	Vista	Ayuda	Diagrama de Gantt	Formato	¿Qué desea hacer?			
Inicio		sáb 13 may	dom 14 may	lun 15 may	mar 16 may	mié 17 may	jue 18 may	vie 19 may	sáb 20 may	dom 21 may	lun
vie 12/05/23		Agregar tareas con fechas a la línea de tiempo									
Modo de	Nombre de tarea	Duración	Comienzo	Fin	Predeces	23 08 15 22 29 jun 20					
🔗	📁 Sistema Web en Machine Learning	12 días	vie 12/05/23	sáb 27/05/23		[Barra de Gantt: Sistema Web en Machine Learning]					
🔗	📁 Sprint 1	9 días	vie 12/05/23	mié 24/05/23		[Barra de Gantt: Sprint 1]					
🔗	📁 RF1: Iniciar Sesión	1 día	vie 12/05/23	vie 12/05/23		[Barra de Gantt: RF1: Iniciar Sesión]					
🔗	Análisis	1 día	vie 12/05/23	vie 12/05/23		[Barra de Gantt: RF1: Iniciar Sesión - Análisis]					
🔗	Diseño	1 día	vie 12/05/23	vie 12/05/23		[Barra de Gantt: RF1: Iniciar Sesión - Diseño]					
🔗	Implementación	1 día	vie 12/05/23	vie 12/05/23		[Barra de Gantt: RF1: Iniciar Sesión - Implementación]					
🔗	📁 RF2: Seleccionar Especialidad	1 día	lun 15/05/23	lun 15/05/23		[Barra de Gantt: RF2: Seleccionar Especialidad]					
🔗	Análisis	1 día	lun 15/05/23	lun 15/05/23		[Barra de Gantt: RF2: Seleccionar Especialidad - Análisis]					
🔗	Diseño	1 día	lun 15/05/23	lun 15/05/23		[Barra de Gantt: RF2: Seleccionar Especialidad - Diseño]					
🔗	Implementación	1 día	lun 15/05/23	lun 15/05/23		[Barra de Gantt: RF2: Seleccionar Especialidad - Implementación]					
🔗	📁 RF3: Mostrar Últimas 6 Notas de Exámenes Semanales	2 días	mar 16/05/23	mié 17/05/23		[Barra de Gantt: RF3: Mostrar Últimas 6 Notas de Exámenes Semanales]					
🔗	Análisis	1 día	mar 16/05/23	mar 16/05/23		[Barra de Gantt: RF3: Mostrar Últimas 6 Notas de Exámenes Semanales - Análisis]					
🔗	Diseño	2 días	mar 16/05/23	mié 17/05/23		[Barra de Gantt: RF3: Mostrar Últimas 6 Notas de Exámenes Semanales - Diseño]					
🔗	Implementación	1 día	mié 17/05/23	mié 17/05/23		[Barra de Gantt: RF3: Mostrar Últimas 6 Notas de Exámenes Semanales - Implementación]					
🔗	📁 RF5: Mostrar Opciones de Especialidades	1 día	jue 18/05/23	jue 18/05/23		[Barra de Gantt: RF5: Mostrar Opciones de Especialidades]					
🔗	Análisis	1 día	jue 18/05/23	jue 18/05/23		[Barra de Gantt: RF5: Mostrar Opciones de Especialidades - Análisis]					
🔗	Diseño	1 día	jue 18/05/23	jue 18/05/23		[Barra de Gantt: RF5: Mostrar Opciones de Especialidades - Diseño]					
🔗	Implementación	1 día	jue 18/05/23	jue 18/05/23		[Barra de Gantt: RF5: Mostrar Opciones de Especialidades - Implementación]					
🔗	📁 RF6: Permitir Cambio de Especialidad y Última Nota	1 día	vie 19/05/23	vie 19/05/23		[Barra de Gantt: RF6: Permitir Cambio de Especialidad y Última Nota]					
🔗	Análisis	1 día	vie 19/05/23	vie 19/05/23		[Barra de Gantt: RF6: Permitir Cambio de Especialidad y Última Nota - Análisis]					
🔗	Diseño	1 día	vie 19/05/23	vie 19/05/23		[Barra de Gantt: RF6: Permitir Cambio de Especialidad y Última Nota - Diseño]					
🔗	Implementación	1 día	vie 19/05/23	vie 19/05/23		[Barra de Gantt: RF6: Permitir Cambio de Especialidad y Última Nota - Implementación]					
🔗	📁 RF4: Calcular Nota Estimada de Examen de Admisión	3 días	lun 22/05/23	mié 24/05/23		[Barra de Gantt: RF4: Calcular Nota Estimada de Examen de Admisión]					
🔗	Análisis	1 día	lun 22/05/23	lun 22/05/23		[Barra de Gantt: RF4: Calcular Nota Estimada de Examen de Admisión - Análisis]					
🔗	Diseño	1 día	mar 23/05/23	mar 23/05/23		[Barra de Gantt: RF4: Calcular Nota Estimada de Examen de Admisión - Diseño]					
🔗	Implementación	1 día	mié 24/05/23	mié 24/05/23		[Barra de Gantt: RF4: Calcular Nota Estimada de Examen de Admisión - Implementación]					
🔗	📁 Sprint 2	3 días	jue 25/05/23	sáb 27/05/23		[Barra de Gantt: Sprint 2]					
🔗	📁 RF7: Utilizar API de ChatGPT para Consultas	3 días	jue 25/05/23	sáb 27/05/23		[Barra de Gantt: RF7: Utilizar API de ChatGPT para Consultas]					
🔗	Análisis	1 día	jue 25/05/23	jue 25/05/23		[Barra de Gantt: RF7: Utilizar API de ChatGPT para Consultas - Análisis]					
🔗	Diseño	1 día	vie 26/05/23	vie 26/05/23		[Barra de Gantt: RF7: Utilizar API de ChatGPT para Consultas - Diseño]					
🔗	Implementación	1 día	sáb 27/05/23	sáb 27/05/23		[Barra de Gantt: RF7: Utilizar API de ChatGPT para Consultas - Implementación]					

## Lista de Pendientes de Sprint 1 (Sprint Backlog)

### Sprint N° 1: Story Point 9

Sprint	Requerimientos Funcionales			Historias	Tiempo estimado	Prioridad
	ReqFun	Título	Descripción			
SPRINT 1	RF1	Iniciar Sesión	Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.	HU1	1	1
	RF2	Seleccionar Especialidad	Después de iniciar sesión, el estudiante debe tener la opción de seleccionar la especialidad a la que desea postular para el próximo examen de admisión.	HU2	1	2
	RF3	Mostrar Últimas 6 Notas de Exámenes Semanales	Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.	HU3	2	2
	RF5	Mostrar Opciones de Especialidades	Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.	HU5	1	2
	RF6	Permitir Cambio de Especialidad y Última Nota	Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.	HU6	1	2
	RF4	Calcular Nota Estimada de Examen de Admisión	Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.	HU4	3	3

## Requerimiento RF1

**RF1:** Iniciar Sesión. Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.

Análisis RF1:

Caso de Uso: Diagrama de Caso de Uso “Iniciar sesión en el sistema”


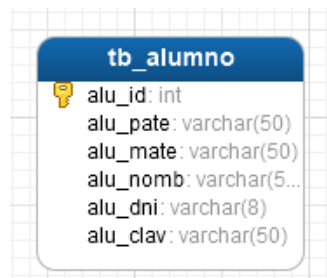


Diagrama Lógico de la Base de Datos RF1:



Diagrama Físico de la Base de Datos RF1:



## Diseño RF1:

### *Prototipo de inicio de sesión*

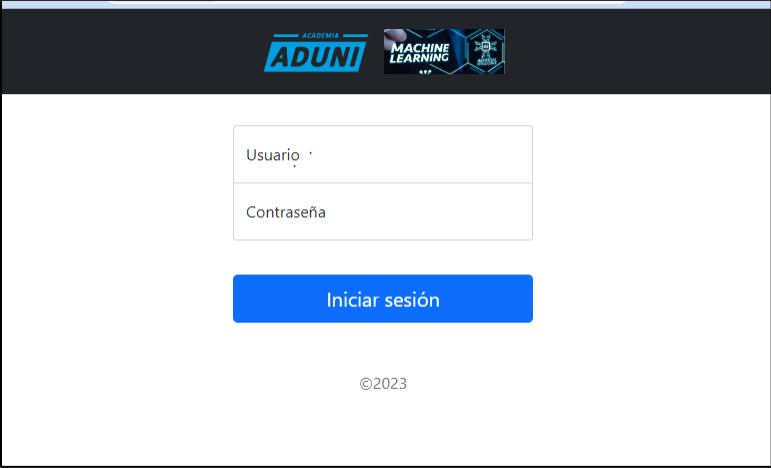
Imagen relativa a la academia y a machine learning

Elaboración propia

## Implementación RF1: GUI

### *Interfaz Iniciar sesión en el sistema*



ADUNI

MACHINE LEARNING

  
  
  
©2023

Elaboración propia

## Código RF1:

```
index.php X
index.php
1 <?php
2 session_start();
3 session_destroy();
4
5 require_once(__DIR__ . '/src/ConexionBD.class.php');
6
7 if(isset($_POST['txtusuario']) && isset($_POST['txtcontrasena']) && strlen(trim($_POST['txtusuario'])) == 8){
8     $pdo = ConexionBD::obtenerInstancia()->obtenerBD();
9     $sentencia = $pdo->prepare("SELECT alu_id,alu_pate,alu_mate,alu_nomb FROM tb_alumno where alu_dni= ? and alu_clav = ? ");
10    if ($sentencia->execute(array($_POST['txtusuario'],$_POST['txtcontrasena']))){
11        while($fila = $sentencia->fetch(PDO::FETCH_ASSOC)){
12            session_start();
13            $_SESSION['X21_alu_id'] = $fila['alu_id'];
14            $_SESSION['X21_alu_nombre'] = $fila['alu_pate']." ".$fila['alu_mate']." ".$fila['alu_nomb'];
15        }
16        header('Location: mod_notas/index.php');
17    }
18 }
19 ?>
20 <!doctype html>
21 <html lang="es">
22 <head>
23 <!-- Required meta tags -->
24 <meta charset="utf-8">
25 <meta name="viewport" content="width=device-width, initial-scale=1">
26
27 <!-- Bootstrap CSS -->
28 <link href="https://cdn.jsdelivr.net/npm/bootstrap@5.0.2/dist/css/bootstrap.min.css" rel="stylesheet">
29 <script src="https://code.jquery.com/jquery-3.7.0.min.js"></script>
30 <link rel="stylesheet" href="https://cdn.jsdelivr.net/npm/bootstrap-icons@1.10.5/font/bootstrap-icons.css">
31 <title>Machine Learning</title>
32 <style>
33     html,
34     body {
35         height: 100%;
36     }
37
38     .form-signin {
```

La siguiente es la clase conexión, valida para todo el sistema.

```
ConexionBD.class.php
<?php
require_once __DIR__ . '/../config.php';
class ConexionBD
{
    /*** ATRIBUTOS **
    private static $db = null; //Única instancia de la clase
    private static $pdo; //Instancia de PDO

    /*** CONSTRUCTOR **
    final private function __construct()
    {
        try {
            self::obtenerBD(); // Crear nueva conexión PDO
        } catch (PDOException $e) {
            // Manejo de excepciones
        }
    }

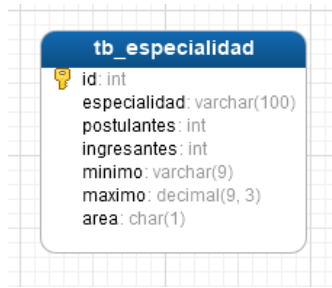
    /*** MÉTODOS **
    public function obtenerBD()
    {
        if (self::$pdo == null) {
            self::$pdo = new PDO("mysql:dbname=".BASE_DE_DATOS.";host=".NOMBRE_HOST.";charset=utf8", USUARIO, CONTRASENA,
                array(PDO::MYSQL_ATTR_INIT_COMMAND => "SET NAMES utf8"));
            // Habilitar excepciones
            self::$pdo->setAttribute(PDO::ATTR_ERRMODE, PDO::ERRMODE_EXCEPTION);
            //self::$pdo->setAttribute(PDO::ATTR_EMULATE_PREPARES, false);
        }
        return self::$pdo;
    }

    public static function obtenerInstancia()
    {
        if (self::$db === null) {
            self::$db = new self();
        }
        return self::$db; //Retorna en la única instancia de la clase o null
    }
}
```





## Diagrama Físico de la Base de Datos RF2:



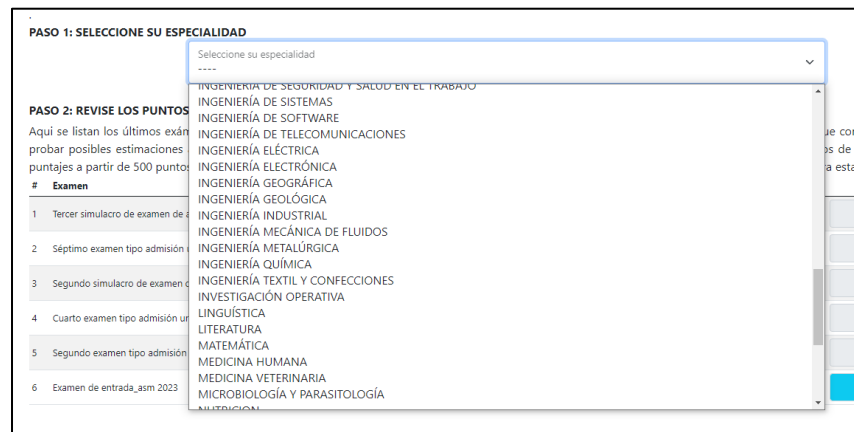
## Diseño RF2: Prototipo

### PASO 1: SELECCIONE SU ESPECIALIDAD

-- Seleccione especialidad --  
ADMINISTRACIÓN DE EMPRESAS ▼

Donde -1 es el valor por defecto no seleccionado

## Implementación RF2: GUI



Elaboración propia

## Código

```
<B>PASO 1: SELECCIONE SU ESPECIALIDAD</B>
<div class="d-flex justify-content-center">
  <div class="form-floating col-sm-12 col-lg-8 ">
    <select class="form-select cmbespecialidades" id="floatingSelect">
      <option value="1">EDUCACIÓN INICIAL</option>
      <option value="2">EDUCACIÓN PRIMARIA</option>
      <option value="3">EDUCACIÓN SECUNDARIA</option>
    </select>
    <label for="floatingSelect">Seleccione su especialidad</label>
  </div>
</div><br>
```

```

$msg = ;
$htmlspecialchars = "<option value='-1'>----</option>";
$htmlnotas = "";
$json = array();
$alu_id = $_SESSION['X21_alu_id'];
//*****ESPECIALIDADES ***** */
$sentencia = fun_notas_cargaEspecialidades();
if ($sentencia->execute(array())) {
    while($fila = $sentencia->fetch(PDO::FETCH_ASSOC)){
        $htmlspecialchars .= '<option value="'. $fila['id'].'">'. $fila['especialidad']. '</option>';
    }
}
}

<?php
function query_notas_cargaEspecialidades(){
    $query = "SELECT id, especialidad FROM tb_especialidad order by 2";
    return $query;
}

```

### Requerimiento RF3

**RF3:** Mostrar Últimas 6 Notas de Exámenes Semanales. Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.

Análisis RF3: Diagrama de Caso de Uso "Obtener últimas seis calificaciones"




Diagrama Lógico de la Base de Datos RF3:





Diagrama Físico de la Base de Datos RF3:



### Diseño RF3: Prototipo

**PASO 2: REVISE LOS PUNTOS OBTENIDOS EN ÚLTIMOS EXAMENES**  
 Aquí se listan los últimos exámenes rendidos y sus puntajes correspondientes, pudiendo modificar el puntaje del último examen de la lista las veces que considere conveniente para probar posibles estimaciones adicionales si así lo desea. También puede modificar en aquellos exámenes que no tenga puntuación estando resaltados de color naranja. Considere puntajes a partir de 500 puntos para una mejor estimación y menores al puntaje máximo base. Estos cambios no afectan las notas de su intranet, solo para estas estimaciones.

Num	Examen	Puntaje base	Puntaje alcanzado
1	Primer	2000	1600
2	Segundo	2000	1000
3	Tercer	1200	605
4	Cuarto	1200	700
5	Tercer	1200	650
6	Cuarto	2000	720

### Implementación RF3:

#### GUI

**PASO 2: REVISE LOS PUNTOS OBTENIDOS EN ÚLTIMOS EXAMENES**  
 Aquí se listan los últimos exámenes rendidos y sus puntajes correspondientes, pudiendo modificar el puntaje del último examen de la lista las veces que considere conveniente para probar posibles estimaciones adicionales si así lo desea. También puede modificar en aquellos exámenes que no tenga puntuación estando resaltados de color naranja. Considere puntajes a partir de 500 puntos para una mejor estimación y menores al puntaje máximo base. Estos cambios no afectan las notas de su intranet, solo para estas estimaciones.

# Examen	Puntaje máximo Base	Puntaje alcanzado
1 Tercer simulacro de examen de admisión unmsm_asm y nuevo inicio 2023	2000	483
2 Séptimo examen tipo admisión unmsm_asm 2023	1200	582
3 Segundo simulacro de examen de admisión unmsm_asm y nuevo inicio 2023	2000	669
4 Cuarto examen tipo admisión unmsm_asm 2023	1200	425
5 Segundo examen tipo admisión unmsm_asm 2023	1200	725
6 Examen de entrada_asm 2023	1200	604

Elaboración propia

## Código

```
//***** NOTAS ***** */
$htmlnotas= '<table class="table table-striped table-hover table-sm" style="font-size:13px">'.
<thead><tr><th scope="col">#</th><th scope="col">Examen</th><th scope="col" class="text-center">Puntaje máximo Base</th><th scope="col" class="text-center">Puntaje alcanzado</th></tr></thead><tbody>
$sentencia = fun_notas_cargaNotas();
$maximapreg = 6;
$sk = 0;
if ($sentencia->execute(array($alu_id)) ) {
    while($fila = $sentencia->fetch(PDO::FETCH_ASSOC)){
        //examen,fecha,alu_notas
        $sk++;
        if($sk <= $maximapreg){
            if($sk == $maximapreg){
                $lectura = "";
                $darcolor="bg-info";
                $tipo = 1;
            }else{
                $lectura = "readonly";
                $darcolor= "";
                $tipo = 0;
            }
            $htmlnotas .= '<tr style="vertical-align: middle;"><td>'. $sk.'</td><td>'.ucfirst(mb_strtolower($fila['examen'],'UTF-8')).'</td>'.
            '<td class="text-center" id="txtptmax'. $sk.'">'. $fila['puntomax']. '</td>'.
            '<td ><input type="number" class="form-control text-center '. $darcolor.'" id="txtpuntos'. $sk.'"
            placeholder="Ingrese puntuación" min="0" max="'. $fila['puntomax'].'" value="'. $fila['alu_puntos'].'" onkeydown="filtro()" '.$lectura.
            '<input type="hidden" id="hiddenp'. $sk.'" value="'. $tipo.'" >'.
            '</tr>';
        }
        //<input type="number" id="quantity" name="quantity" min="1" max="5">
    }
    for($si=$sk+1; $si<=$maximapreg; $si++){
        $htmlnotas .= '<tr style="vertical-align: middle;"><td>'. $si.'</td><td>Examen genérico</td>'.
        '<td class="text-center" id="txtptmax'. $si.'">2000</td>'.
        '<td ><input type="number" class="form-control text-center bg-warning" id="txtpuntos'. $si.'"
        placeholder="Ingrese puntuación" min="0" max="2000" value="500" onkeydown="filtro()"></td>'.
        '<input type="hidden" id="hiddenp'. $si.'" value="1" >'.
    }
}
}

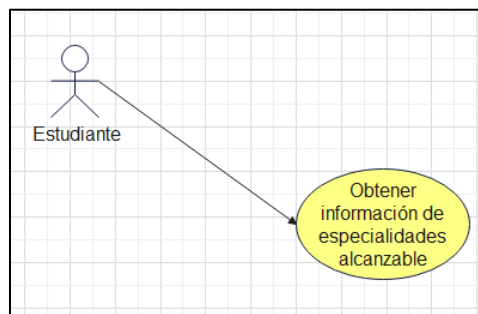
17 function fun_notas_cargaNotas(){
18     return getPDO()->prepare(query_notas_cargaNotas());
19 }
20 }

7 function query_notas_cargaNotas(){
8     $query = "SELECT examen,fecha,alu_notas,alu_puntos,puntomax FROM tb_alumnota where alu_id = ? order by fecha desc";
9     return $query;
10 }
11 }
```

## Requerimiento RF5

**RF5:** Mostrar Opciones de Especialidades. Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.

Análisis RF5: Diagrama de Caso de Uso "Obtener información de especialidades alcanzables"



## Diagrama Lógico de la Base de Datos RF5:



## Diagrama Físico de la Base de Datos RF5:



## Diseño RF5: Prototipo

Lista de especialidades cuya nota mínima de ingreso en 2023II puede ser alcanzado con este puntaje:

Especialidad	Postulantes	Ingresantes	Puntaje mínimo	Puntaje máximo
Administración	50	20	500	821
Ciencias de los Alimentos	50	17	560	1021

## Implementación RF5: GUI

Lista de especialidades cuya nota mínima de ingreso en 2023II puede ser alcanzado con este puntaje:

Especialidad	Postulantes	Ingresantes	Puntaje Mínimo	Puntaje Máximo
ADMINISTRACIÓN - HUARAL	38	30	500.125	821.500
ADMINISTRACIÓN DE NEGOCIOS INTERNACIONALES - HUARAL	30	15	605.75	987.125
ADMINISTRACIÓN DE NEGOCIOS INTERNACIONALES - S.J.L	76	16	755.875	1007.125
ADMINISTRACIÓN DE TURISMO - HUARAL	7	7	342.375	686.250
ADMINISTRACIÓN DE TURISMO - LIMA	179	69	715.875	1206.500
ADMINISTRACIÓN DE TURISMO - S.J.L	33	15	626.875	901.500
ANTROPOLOGÍA	68	38	643.75	1176.125
ARQUEOLOGÍA	52	32	651.625	1093.000
ARTE	58	33	563.125	1120.625
AUDITORÍA EMPRESARIAL Y DEL SECTOR PÚBLICO	147	105	598.125	1325.375
BIBLIOTECOLOGÍA Y CIENCIAS DE LA INFORMACIÓN	26	18	585.125	1173.000
CIENCIAS BIOLÓGICAS	183	32	780.875	1167.375
CIENCIAS DE LOS ALIMENTOS	50	17	568.25	1031.625
COMPUTACIÓN CIENTÍFICA	93	66	523.5	987.125

## Elaboración propia

## Código

```
$html='<div class=""><small>Lista de especialidades cuya nota mínima de ingreso en 2023II puede ser alcanzado con este puntaje: </small>';  
$html.= '<table class="table table-striped table-hover table-sm" style="font-size:13px">'.  
    '<thead><tr><th scope="col">Especialidad</th><th scope="col">Postulantes</th><th scope="col">Ingresantes</th>  
    <th scope="col">Puntaje Mínimo</th><th scope="col">Puntaje Máximo</th></tr></thead><tbody>';  
  
$sentencia = fun_notas_cargaMaximosMinimos();  
if ($sentencia->execute(array($notafinal))) {  
    while($fila = $sentencia->fetch(PDO::FETCH_ASSOC)){  
        //especialidad, postulantes, ingresantes,minimo, maximo  
        $html.= "<tr><td>".$fila['especialidad']."</td>".  
            "<td>".$fila['postulantes']."</td>".  
            "<td>".$fila['ingresantes']."</td>".  
            "<td>".$fila['minimo']."</td>".  
            "<td>".$fila['maximo']."</td></tr>";  
    }  
}  
$html.="</tbody></table>";  
$html.='<div class=""><small>(*) El modelo de regresión en Machine Learning utilizado presenta un coeficiente de determinación r2score=J';  
$sentencia = fun_notas_registrar();  
$sentencia->execute(array($alu_id,$notafinal));
```

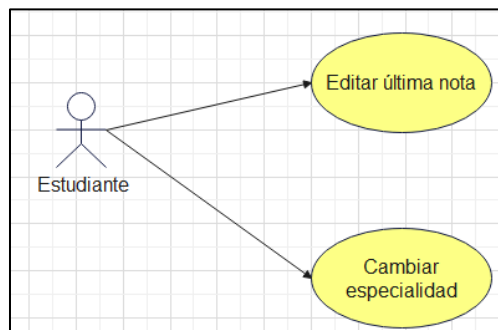
```
function fun_notas_cargaMaximosMinimos(){  
    return getPDO()->prepare(query_notas_cargaMaximosMinimos());  
}
```

```
17 function query_notas_cargaMaximosMinimos(){  
18     $query = "SELECT especialidad, postulantes, ingresantes,minimo, maximo FROM tb_especialidad WHERE minimo < cast(? as decimal(9,3)) ";  
19     return $query;  
20 }
```

## Requerimiento RF6

**RF6:** Permitir Cambio de Especialidad y Última Nota. Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.

Análisis RF6: Diagrama de Caso de Uso “Editar última nota y seleccionar otra especialidad”



## Diseño RF6: Prototipos

Num	Examen	Puntaje base	Puntaje alcanzado
1	Primer	2000	1600
2	Segundo	2000	1000
3	Tercer	1200	605
4	Cuarto	1200	700
5	Tercer	1200	650
6	Cuarto	2000	720

**Editable**

PASO 1: SELECCIONE SU ESPECIALIDAD

-- Seleccione especialidad --  
 ADMINISTRACIÓN DE EMPRESAS ▼

RESELECCIONABLE

## Implementación RF6: GUI

Seleccione su especialidad  
----

**OBTENIDOS EN ÚLTIMOS EXAMENES**

enes rendidos y sus puntajes correspondientes, pudiendo modificar el puntaje del último examen de la lista las veces que considere conveniente para dicionales si así lo desea. También puede modificar en aquellos exámenes que no tenga puntuación estando resaltados de color naranja. Considere para una mejor estimación y menores al puntaje máximo base. Estos cambios no afectan las notas de su intranet, solo para estas estimaciones.

	Puntaje máximo Base	Puntaje alcanzado
misión unmsm_asm y nuevo inicio 2023	2000	483
mism_asm 2023	1200	582
admisión unmsm_asm y nuevo inicio 2023	2000	669
msm_asm 2023	1200	425
nmism_asm 2023	1200	725
	1200	604

## Elaboración propia

## Código

```

if($k == $maximapreg){
  $lectura = "";
  $darcolor="bg-info";
  $tipo = 1;
}else{
  $lectura = "readonly";
  $darcolor="";
  $tipo = 0;
}

$htmlnotas .= '<tr style="vertical-align: middle;"><td>'. $k. '</td><td>'.ucfirst(mb_strtolower($fila['examen'],'UTF-8')). '</td>'.
  '<td class="text-center" id="txtptmax'. $k. '">'. $fila['puntosmax']. '</td>'.
  '<td ><input type="number" class="form-control text-center '. $darcolor. '" id="txtpuntos'. $k. '"
  placeholder="Ingrese puntuación" min="0" max="'. $fila['puntosmax']. '" value="'. $fila['alu_puntos']. '" onkeydown="filtro()" '. $lectura.
  '<input type="hidden" id="hiddenp'. $k. '" value="'. $tipo. '" >'.
  '</tr>';
}
//<input type="number" id="punt'. $k. '" name="punt'. $k. '" min="0" max="'. $k. '"

```



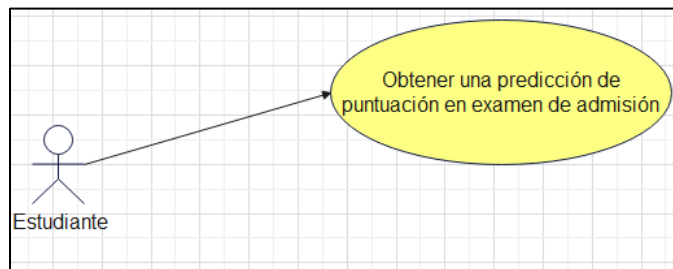
```
$.ajax({
  type: 'POST',
  url: 'aco_php/aco_data.php',
  dataType: 'json',
  data: {
    action: 'data_notas_calcular',
    xp1: $("#txtpuntos1").val()*(2000/$("#txtptmax1").html()),
    xp2: $("#txtpuntos2").val()*(2000/$("#txtptmax2").html()),
    xp3: $("#txtpuntos3").val()*(2000/$("#txtptmax3").html()),
    xp4: $("#txtpuntos4").val()*(2000/$("#txtptmax4").html()),
    xp5: $("#txtpuntos5").val()*(2000/$("#txtptmax5").html()),
    xp6: $("#txtpuntos6").val()*(2000/$("#txtptmax6").html()),
    hp1: $("#hiddenp1").val(),
    hp2: $("#hiddenp2").val(),
    hp3: $("#hiddenp3").val(),
    hp4: $("#hiddenp4").val(),
    hp5: $("#hiddenp5").val(),
    hp6: $("#hiddenp6").val(),
    cmbesp:$("#.cmbespecialidades").val()
  },
  success: function (data) {
    if (data.error == 1 || data.error == 2 || data.error == 3) {
      alert(data.msg)
    } else {
      $(".divResultados").html(data.htmlresultado);
      $(".divResultadosEspecialidades").html(data.html);
    }
  }
});
```

### **Requerimiento RF4**


**RF4:** Calcular Nota Estimada de Examen de Admisión. Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.

### **Análisis RF4:**


Caso de Uso: Diagrama de Caso de Uso ""



## Diagrama Lógico de la Base de Datos RF4:



## Diagrama Físico de la Base de Datos RF4:



## Diseño RF4: Prototipo

Realizar estimación

Calcular

Resultados

En base al proceso de admisión 2023II (modalidad Educación básica regular y Educación básica alternativa) y sus notas ingresadas, su posible puntaje alcanzado sería de: 795.549(\*). Para su especialidad seleccionada ADMINISTRACIÓN - HUARAL, el puntaje mínimo de ingreso fue 500.125, el puntaje máximo de ingreso fue 821.500 y de los 38 que postularon a esta especialidad lograron su ingreso 30, es decir, ingresaron el 78.95% de los postulantes.

## Implementación RF4: GUI

**PASO 3: REALIZAR ESTIMACIÓN**

Calcular

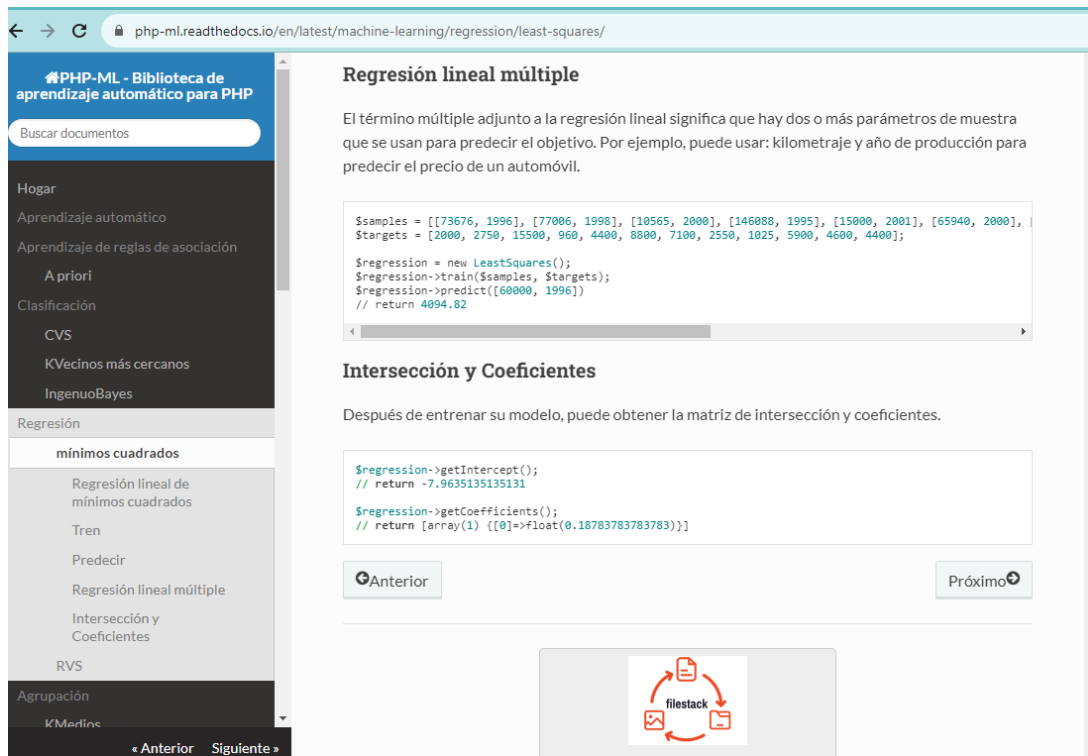
**VER RESULTADOS:**

En base al proceso de admisión 2023II (modalidad Educación básica regular y Educación básica alternativa) y sus notas ingresadas, su posible puntaje alcanzado sería de: 795.549(\*). Para su especialidad seleccionada INGENIERÍA DE SISTEMAS, el puntaje mínimo de ingreso fue 964.875, el puntaje máximo de ingreso fue 1284.000 y de los 1519 que postularon a esta especialidad lograron su ingreso 72, es decir, ingresaron el 4.74% de los postulantes.

## Elaboración propia

Código:

Para Machine Learning se utilizó la librería php-ml descargada desde <https://php-ml.readthedocs.io>



The screenshot shows the PHP-ML documentation website. The left sidebar contains a search bar and a navigation menu with categories like 'Hogar', 'Aprendizaje automático', 'Clasificación', 'Regresión', and 'Agrupación'. The main content area is titled 'Regresión lineal múltiple' and explains that multiple regression involves two or more parameters. It includes a code block for training and predicting a model, and another section titled 'Intersección y Coeficientes' showing how to retrieve the intercept and coefficients. Navigation buttons for 'Anterior' and 'Próximo' are visible at the bottom of the content area.

El siguiente código genera y entrena un modelo además de evaluar la precisión a partir de un DataSet de datos en formato CSV.

```
//GENERAR MODELO
$data = new \Phpml\Dataset\CsvDataset("../data/dataAduni2023_6d.csv",6,true);
$dataset =new \Phpml\CrossValidation\RandomSplit($data,0.20,280); //97, 7
//Genera cuatro grupos
//$dataset->getTrainSamples();// Entrada de muestras entrenados/
//$dataset->getTrainLabels();// Salida de etiquetas de los datos entrenados
//$dataset->getTestSamples();// obtener muestras de prueba
//$dataset->getTestLabels();// obtener etiquetas de prueba
$regression =new \Phpml\Regression\LeastSquares();
$regression->train($dataset->getTrainSamples(),$dataset->getTrainLabels());
$predict = $regression->predict($dataset->getTestSamples());
$score = \Phpml\Metric\Regression::r2Score($dataset->getTestLabels(),$predict);//coeficiente de determinación: 1 modelo fiable
$html = "r2score is : " . $score;
$modelManager = new \Phpml\ModelManager();
$modelManager->saveToFile($regression,'../data/modelo/modelo2023.phpml');
```

Aquí el código separa un 20% de los datos para evaluar la precisión del modelo y el resto se usa para entrenar el modelo.


A continuación, se muestra parte de la data que presenta un coeficiente de determinación r2score de 73.3% de precisión.

```

nod_notas > data > dataAduni2023_6d.csv
 1  ptos1,ptos2,ptos3,ptos4,ptos5,ptos6,puntajeadmission
 2  1220.625,906.875,1227.292,1334.792,1405.208,1199.5,1050.5
 3  619.25,847.5,743.75,990.208,792.75,1195.833,773.875
 4  1030.5,1049.375,1331.042,1331.042,1197.25,1401.458,1108.5
 5  766.25,873,581.5,377.25,855.25,806.25,818.375
 6  1376.375,732.5,799.25,628,669.125,711.375,774.75
 7  415.625,415.625,556.458,521.25,436.75,697.292,830.75
 8  1471.875,1225.417,1119.792,1176.125,1401.458,1190.208,901.5
 9  859.25,1239.5,1331.042,1331.042,1155,1112.75,1198.375
10  1062.5,1201.458,853.125,1218.375,1190.208,1119.792,927.125
11  697.292,662.083,712.5,370,290.625,521.25,780.375
12  883.5,838.125,415.625,908.542,556.458,838.125,838.125
13  1281.75,1218.375,1331.042,1331.042,1475.625,1282.875,947.625
14  1218.375,1401.458,1295.833,1225.417,1260.625,1401.458,1176.125
15  662.083,310,978.958,415.625,457.875,873.333,859.25
16  859.25,1197.25,1112.75,817,690.25,394.5,732.5
17  732.5,964.875,943.75,838.125,875.208,859.25,843.75
18  890.208,440,838.125,721.5,1017.917,843.75,870.5
19  1163.75,1158.692,1264.375,1073.875,1266.25,1131.042,992.75
20  1403.125,1614.583,1625.833,1616.458,1462,1516.458,1136.375
21  1218.375,1197.25,1263.75,1239.5,1281.75,1155,1028.25
22  1133.875,500.125,457.875,394.5,100.875,753.625,795.875
23  1260.625,1197.25,1260.625,1295.833,1429.625,1260.625,859.5
24  641.875,578.958,662.083,817,817,943.75,920.625
25  897.5,874.125,729.125,955.25,824,853,863.75
26  842.625,830.5,1127.375,1065.125,1064,938.375,1248.5
27  817.5,927.625,647.375,729.875,769.875,764.25,926
28  662.5,634.792,838.625,673.75,870,866.25,793.875
29  732.5,1155,1014.167,817,697.292,415.625,1091.625
30  943.75,964.875,1119.792,1049.375,908.542,986,875
31  986,244.167,753.625,978.958,943.75,943.75,943.75
32  557.292,919.75,1034.792,805.208,940.417,853,1007.125
33  875.567,953.125,908.542,908.542,904,1260.625,1096.375
34  1137.5,840.417,966.25,1283.125,1098.625,907.083,853
35  901.5,838.125,690.25,880.375,732.5,859.25,901.5
36  775.208,781.75,897.708,888.333,682.708,582.625,966
37  502.917,1136.667,792.75,782.708,1097.708,830.5,654.75
38  204.375,415.625,225.5,274.792,204.375,450.775,653.625
39  200,989.875,790.625,1686.875,1666.5,1757.292,944.875
40  000.542,1040.275,072.222,1155,1014.167,1266.25,064.975

```

Una referencia del método es encontrar una línea recta que este a la menor distancia de todos los puntos



## Para usar el modelo entrenado

```
$modelManager = new \Phpml\ModelManager();
$regression = $modelManager->restoreFromFile('../data/modelo/modelo2023.phpml');

$mp1 = $_POST['xp1'];
$mp2 = $_POST['xp2'];
$mp3 = $_POST['xp3'];
$mp4 = $_POST['xp4'];
$mp5 = $_POST['xp5'];
$mp6 = $_POST['xp6'];

$notafinal = $regression->predict([$mp1,$mp2,$mp3,$mp4,$mp5,$mp6]);

$sentencia = fun_notas_consultaespecialidad();
$zespecialidad="";
$zpostulantes="";
$zingresantes="";
$zminimo="";
$zmaximo="";
if ($sentencia->execute(array($_POST['cmbesp']))) {
    while($fila = $sentencia->fetch(PDO::FETCH_ASSOC)){
        $zespecialidad = $fila['especialidad'];
        $zpostulantes = $fila['postulantes'];
        $zingresantes = $fila['ingresantes'];
        $zminimo = $fila['minimo'];
        $zmaximo = $fila['maximo'];
    }
}
$htmlresultado = "En base al proceso de admisión 2023II (modalidad Educación básica regular y Educación básica alternativa) y sus notas
"Para su especialidad seleccionada ".$zespecialidad.", el puntaje mínimo de ingreso fue ".$zminimo.", el puntaje máximo
" y de los ".$zpostulantes." que postularon a esta especialidad lograron su ingreso ".$zingresantes.",
es decir, ingresaron el ".round(($zingresantes*100)/$zpostulantes,2)."% de los postulantes.";

$html='<div class=""><small>Lista de especialidades cuya nota mínima de ingreso en 2023II puede ser alcanzado con este puntaje: </small>
$html=' <table class="table table-striped table-hover table-sm" style="font-size:13px">
    <thead><tr><th scope="col">Especialidad</th><th scope="col">Postulantes</th><th scope="col">Ingresantes</th>
    <th scope="col">Puntaje Mínimo</th><th scope="col">Puntaje Máximo</th></tr></thead><tbody>';
```

## Acta de Conformidad del Sistema Web en Machine Learning para predecir el puntaje de estudiantes postulantes a UNMSM

Fecha: 24 de mayo de 2023 – Sede Sur

Hora: 11:00 am

Entregable: Sprint N°1

PARTICIPANTES	
Juan Francisco Infante Carrascal	Director del Tecnologías de la Información
Nilo Saravia Santisteban	Responsable del área de desarrollo de TI
Carlos Enrique Pandal Blas	Tesista

TEMAS TRATADOS
<ul style="list-style-type: none"> <li>• RF1: Iniciar Sesión. Los estudiantes preuniversitarios de la academia ADUNI y los postulantes a la UNMSM deben poder iniciar sesión en el sistema utilizando su nombre de usuario o correo electrónico y contraseña.</li> <li>• RF2: Seleccionar Especialidad. Después de iniciar sesión, el estudiante debe tener la opción de seleccionar la especialidad a la que desea postular para el próximo examen de admisión.</li> <li>• RF3: Mostrar Últimas 6 Notas de Exámenes Semanales. Una vez que el estudiante ha seleccionado una especialidad, el sistema debe mostrar las últimas 6 notas de sus exámenes semanales en la academia ADUNI. La última nota debe ser editable para permitir pruebas y simulaciones.</li> <li>• RF5: Mostrar Opciones de Especialidades. Una vez que se ha realizado el cálculo de la nota estimada, el sistema debe mostrar una lista de especialidades a las que el estudiante podría ingresar con esa puntuación. La lista debe incluir información sobre los puntajes mínimos y máximos requeridos, así como la cantidad de postulantes e ingresantes del último año.</li> <li>• RF6: Permitir Cambio de Especialidad y Última Nota. Después de ver las opciones de especialidades, el sistema debe permitir al estudiante cambiar la especialidad seleccionada y editar la última de sus notas para probar diferentes escenarios y visualizar cómo afectaría sus posibilidades de ingreso en otras especialidades.</li> <li>• RF4: Calcular Nota Estimada de Examen de Admisión. Después de revisar sus últimas notas, el estudiante debe poder hacer clic en el botón "Calcular" para que el sistema utilice Machine Learning y un modelo previamente entrenado para estimar la nota que obtendría en el próximo examen de admisión, basado en el desempeño histórico de estudiantes aprobados del año anterior.</li> </ul>

OBSERVACIONES
a) Sistema en óptimas condiciones en funcionalidad de acuerdo a los requerimientos
b) Ninguna observación
c)
d)

Firmas y DNI

 Juan Francisco Infante Carrascal	 Nilo Saravia Santisteban 07509968	 Carlos Enrique Pandal Blas
---	---	---

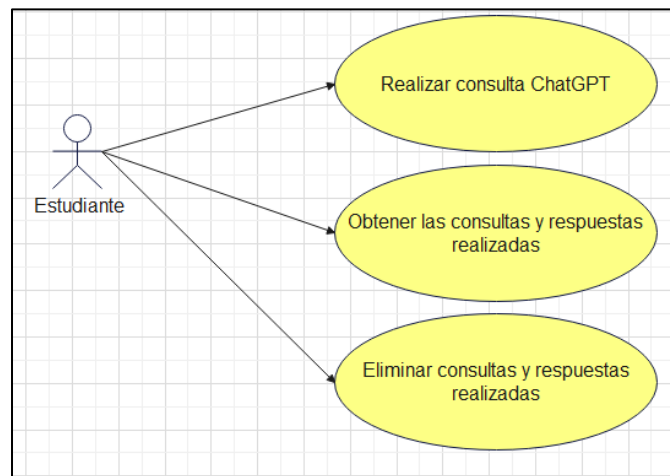
## Sprint N° 2: Story Point 3

Sprint	Requerimientos Funcionales			Historias	Tiempo estimado	Prioridad
	ReqFun	Título	Descripción			
SPRINT 2	RF7	Utilizar API de ChatGPT para Consultas	En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.	HU7	3	4

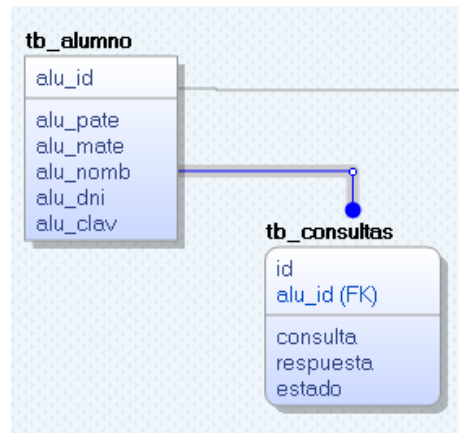
### Requerimiento RF7

**RF7:** Utilizar API de ChatGPT para Consultas. En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.

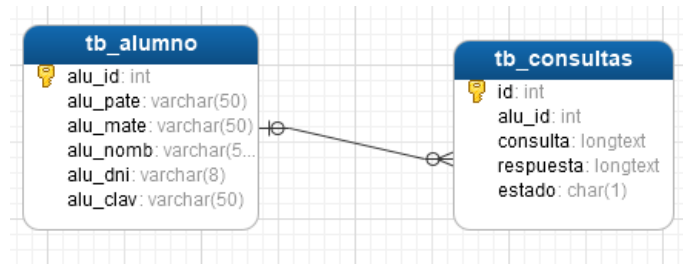
Análisis RF7: Diagrama de Caso de Uso “Consultar ChatGPT, guardar y eliminar respuestas”.



## Diagrama Lógico de la Base de Datos RF7:



## Diagrama Físico de la Base de Datos RF7:



## Implementación RF7: GUI

Implementación RF7: GUI. Captura de pantalla de una interfaz de usuario web. En la parte superior, hay un encabezado con el logo de **ADUNI** (ACADEMIA) y el texto "Bienvenid@: Pandal Blas Carlos". A la derecha del encabezado, hay tres botones: "Notas Admisión", "Consultas" (destacado) y "Salir".

El contenido principal de la página es "Consultas de texto". Hay un campo de entrada de texto con el placeholder "Escriba su consulta ..." y un botón de envío con una flecha blanca.

Debajo del campo de entrada, hay una sección "Lista de consultas realizadas:" con un ícono de ayuda. El texto de esta sección es: "Neuronal: codificación a través de la actividad de los circuitos neuronales. e) Eidética: codificación a corto plazo de información basada en recuerdos imágenes".

Hay tres tarjetas de consulta:

- de acuerdo con la teoría del decaimiento el material guardado se pierde por..? a) la interferencia de otra informacion b) el transcurso del tiempo c) represion afectiva d) desatencion e) amnesia retrograda cual clave es** (ícono de borrar). La respuesta es la b) el transcurso del tiempo. El decaimiento se refiere a cómo, con el tiempo, la información y los recuerdos se pierden, debido a la disminución de la actividad neuronal.
- de acuerdo con la teoría del decaimiento el material guardado se pierde por..?** (ícono de borrar). El decaimiento teoriza que el material guardado se pierde con el paso del tiempo debido a la desintegración molecular, afinidad química, erosión, alteración en los contenidos o desconexión de los contenidos.
- en la película como si fuera la primera vez un biologo conoce a lucy, con quien entabla una relacion y pronto descubre que ella sufre de amnesia a consecuencia de un accidente por lo que lucy no tiene ningun recuerdo de lo que ocurrio el día del accidente el presente es decir, que hay problemas en la memoria de corto plazo la informacion no pasa a la memoria de largo plazo podemos afiermar que la película alude al tipo de amnesia** (ícono de borrar). La película trata de un biólogo que se enamora de Lucy, a pesar de descubrir que sufre de amnesia a raíz de un accidente. Esto implica que se ha perdido la memoria a corto plazo, ya que no recuerda lo ocurrido el día del accidente. Esto hace referencia al tipo de amnesia que padece Lucy.





## Acta de Conformidad del Sistema Web en Machine Learning para predecir el puntaje de estudiantes postulantes a UNMSM

Fecha: 30 de mayo de 2023 – Sede Sur

Hora: 11:00 am

Entregable: Sprint N°2

PARTICIPANTES	
Juan francisco Infante Carrascal	Director del Tecnologías de la Información
Nilo Saravia Santisteban	Responsable del área de desarrollo de TI
Carlos Enrique Pandal Blas	Tesista

TEMAS TRATADOS
<ul style="list-style-type: none"><li>RF7: Utilizar API de ChatGPT para Consultas. En el segundo módulo del sistema, el estudiante debe tener acceso a la API de ChatGPT para realizar consultas adicionales y obtener respuestas a preguntas específicas relacionadas con la preparación para el examen de admisión o detalles sobre las especialidades. Además, el sistema debe almacenar las preguntas y respuestas en una base de datos para mostrarlas al estudiante cuando ingrese a este módulo, y proporcionar la opción de borrarlas si así lo desea.</li></ul>

OBSERVACIONES
a) Sistema en óptimas condiciones en funcionalidad de acuerdo a los requerimientos
b) Ninguna observación
c)
d)

Firmas y DNI

 Juan francisco Infante Carrascal	 Nilo Saravia Santisteban 07509968	 Carlos Enrique Pandal Blas
---	---	---

## Acta de Conformidad y Cierre del Sistema Web en Machine Learning para predecir el puntaje de estudiantes postulantes a UNMSM

Fecha: 15 de junio de 2023 – Sede Sur

Hora: 11:00 am

Agenda: Cierre del proyecto

PARTICIPANTES	
Juan francisco Infante Carrascal	Director del Tecnologías de la Información
Nilo Saravia Santisteban	Responsable del área de desarrollo de TI
Carlos Enrique Pandal Blas	Tesista

TEMAS TRATADOS
<ul style="list-style-type: none"><li>• Por medio de la presente, se da cierre formal al proyecto, con la entrega de todos los productos de conformidad con los requerimientos, como consta en las actas del 24 y 30 de mayo de 2023.</li></ul>

OBSERVACIONES
a) Sistema en óptimas condiciones en funcionalidad de acuerdo a los requerimientos
b) Ninguna observación
c)
d)

Firmas y DNI

 Juan Francisco Infante Carrascal	 Nilo Saravia Santisteban 07509968	 Carlos Enrique Pandal Blas
---	---	---



**ESCUELA DE POSGRADO**

**MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA INFORMACIÓN**

**Declaratoria de Autenticidad del Asesor**

Yo, JHONATAN ISAAC VARGAS HUAMAN, docente de la ESCUELA DE POSGRADO MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN TECNOLOGÍAS DE LA INFORMACIÓN de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Machine Learning en la Autorregulación del Aprendizaje de los estudiantes en una academia preuniversitaria privada, Lima 2023", cuyo autor es PANDAL BLAS CARLOS ENRIQUE, constato que la investigación tiene un índice de similitud de 21.00%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 02 de Agosto del 2023

<b>Apellidos y Nombres del Asesor:</b>	<b>Firma</b>
JHONATAN ISAAC VARGAS HUAMAN <b>DNI:</b> 70430225 <b>ORCID:</b> 0000-0002-1433-7494	Firmado electrónicamente por: JIVARGASH el 04- 08-2023 19:45:15

Código documento Trilce: TRI - 0636299