



UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA MECÁNICA ELÉCTRICA,
ELECTRÓNICA Y SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



**ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA
PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ
JULIACA**

TESIS

PRESENTADA POR:

Bach. DAVID FERNANDEZ CHAMBILLA

Bach. CARLOS ALBERTO JHOSEP HUAYTA QUISPE

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO DE SISTEMAS

PUNO – PERÚ

2024



DAVID FERNANDEZ CHAMBILLA CARLOS ALBERTO...

ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ J

 Universidad Nacional del Altiplano

Detalles del documento

Identificador de la entrega
trn:oid::8254:418840894

Fecha de entrega
26 dic 2024, 3:42 p.m. GMT-5

Fecha de descarga
26 dic 2024, 3:44 p.m. GMT-5

Nombre de archivo
ultimo.pdf

Tamaño de archivo
2.1 MB

110 Páginas

18,941 Palabras

112,755 Caracteres





8% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 7% Fuentes de Internet
- 2% Publicaciones
- 6% Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



Firmado digitalmente por GOMEZ
QUISEPÉ Hugo Yosef FAU
2018498170 soft:
Motivo: Soy el autor del documento
Fecha: 26.12.2024 15:54:34 -05:00



Firmado digitalmente por
SOTOMAYOR ALZAMORA Guina
Guadalupe FAU 2018498170 hard:
Motivo: Soy el autor del documento
Fecha: 26.12.2024 19:33:10 -05:00





DEDICATORIA

En primer lugar, a Dios, por ser mi guía constante y por iluminar cada paso de mi vida. A mis queridos padres, Felipa y Paulino, por su amor incondicional, apoyo constante y sacrificios incansables para ver cumplidos mis sueños. Su fe en mí ha sido mi mayor fuente de inspiración y el pilar de este logro. A mis hermanos, familiares y amigos, cuyas palabras y acciones, de una u otra forma, han sido un apoyo valioso para alcanzar mis objetivos.

David Fernandez Chambilla



DEDICATORIA

A Dios, por ser mi guía y fortaleza en cada momento. A mis padres, por su amor y sacrificio, y a mis profesores de la Universidad, por su dedicación y enseñanzas. A todos quienes me apoyaron en este camino, gracias por ser parte de este logro.

A mi bebe Helen y a mi esposa Mary, por darme una razón más para seguir adelante con amor y determinación.

Carlos Alberto Jhosep Huayta Quispe



AGRADECIMIENTOS

A Dios, por darnos la sabiduría, la fortaleza y las oportunidades que nos han permitido avanzar y superar cada reto a lo largo de esta carrera. Su presencia ha sido una guía constante y fuente de paz en cada paso de este camino.

A nuestra alma mater, Universidad Nacional del Altiplano de Puno, y a la Escuela Profesional de Ingeniería de Sistemas, por brindarnos una educación de calidad y hacernos profesionales competentes.

A nuestros padres, cuyo amor, esfuerzo y sacrificio incondicional han sido el fundamento de nuestra vida y de cada logro que hemos alcanzado. Su ejemplo, dedicación y valores nos han impulsado a seguir adelante, incluso en los momentos más desafiantes. A ellos, nuestro agradecimiento profundo por creer en nosotros y motivarnos siempre.

A nuestros profesores de la Universidad Nacional del Altiplano, por su compromiso y paciencia en la enseñanza. Gracias por compartir su conocimiento y por despertar en nosotros la pasión por la ingeniería de sistemas. Sus enseñanzas han sido un pilar fundamental en nuestra formación profesional y personal, y los llevamos con nosotros como ejemplo de vocación y excelencia.

Finalmente, agradecemos a todas aquellas personas que de alguna forma contribuyeron a este proceso, directa o indirectamente. Este logro es el reflejo de cada una de sus enseñanzas y apoyo.

David Fernandez Chambilla

Carlos Alberto Jhosep Huayta Quispe



ÍNDICE GENERAL

	Pág.
DEDICATORIA	
AGRADECIMIENTOS	
ÍNDICE GENERAL	
ÍNDICE DE TABLAS	
ÍNDICE DE FIGURAS	
ÍNDICE DE ANEXOS	
ACRÓNIMOS	
RESUMEN	16
ABSTRACT	17
CAPÍTULO I	
INTRODUCCIÓN	
1.1. DESCRIPCIÓN DEL PROBLEMA DE INVESTIGACIÓN.....	19
1.2. FORMULACIÓN DEL PROBLEMA	21
1.2.1. Problema general	21
1.3. OBJETIVOS DE LA INVESTIGACIÓN.....	21
1.3.1. Objetivo general.....	21
1.3.2. Objetivos específicos	21
1.4. JUSTIFICACIÓN DE LA INVESTIGACIÓN	22
1.5. ALCANCES Y LIMITACIONES DE LA INVESTIGACIÓN	23
1.5.1. Alcance	23
1.5.2. Limitaciones.....	24
1.6. HIPÓTESIS DE LA INVESTIGACIÓN	24
1.6.1. Hipótesis general.....	24



CAPÍTULO II

REVISIÓN DE LITERATURA

2.1.	ANTECEDENTES DE LA INVESTIGACIÓN.....	25
2.1.1.	Antecedentes Locales	25
2.1.2.	Antecedentes Nacionales	26
2.1.3.	Antecedentes Internacionales	28
2.2.	MARCO TEÓRICO	30
2.2.1.	Definiciones generales	30

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1.	TIPO Y DISEÑO DE INVESTIGACIÓN	45
3.2.	POBLACIÓN Y MUESTRA.....	46
3.2.1.	Población	46
3.2.2.	Muestra	46
3.2.3.	Ubicación y Descripción de la Población	47
3.3.	TÉCNICAS E INSTRUMENTOS	48
3.3.1.	Técnicas e instrumentos para la recolección de datos	48
3.3.2.	Técnicas para el análisis de la información	49
3.3.3.	Técnicas para el procesamiento de datos	50
3.4.	PLAN DE TRATAMIENTO DE DATOS	50
3.4.1.	Análisis de datos	51
3.5.	APLICACIÓN DE LA METODOLOGÍA	52
3.5.1.	Metodología en Prototipo	52
3.5.2.	Material Experimental	53
3.5.3.	Recursos Digitales y Servicios	54



3.5.4. Materiales de Apoyo	54
3.6. ASPECTOS ÉTICOS	54

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. DISEÑO DE LA ARQUITECTURA DE SOFTWARE DEL ASISTENTE VIRTUAL INTELIGENTE ORIENTADO AL ANÁLISIS DE PRODUCTIVIDAD ESTUDIANTIL.....	56
4.1.1. Diagrama de Casos de Uso	56
4.1.2. Identificación de los componentes del sistema.....	57
4.1.3. Diagrama de Componentes	61
4.1.4. Selección de las tecnologías	62
4.1.5. Diagrama de Clases	64
4.1.6. Diseño modular y flexible.....	65
4.1.7. Diagrama de Despliegue	67
4.1.8. Modelado de los flujos de datos	68
4.1.9. Diagrama de Secuencia.....	70
4.2. IMPLEMENTACIÓN Y AJUSTE DE MODELOS DE APRENDIZAJE PROFUNDO PARA PREDECIR Y ANALIZAR PATRONES DE PRODUCTIVIDAD Y RENDIMIENTO ESTUDIANTIL	71
4.2.1. Preprocesamiento de datos.....	71
4.2.2. Diagrama de Actividades	73
4.2.3. Entrenamiento de modelos.....	74
4.2.4. Validación de los modelos	77
4.2.5. Evaluación y optimización.....	80



4.3. PRUEBAS DE FUNCIONALIDAD Y FIABILIDAD DEL ASISTENTE VIRTUAL PARA ASEGURAR SU EFICACIA EN ENTORNOS EDUCATIVOS.....	82
4.3.1. Definición de los casos de prueba.....	82
4.3.2. Diagrama de Interacción de Objetos.....	85
4.3.3. Pruebas unitarias y de integración	86
4.3.4. Pruebas de rendimiento y estrés.....	87
4.3.5. Diagrama de Estados	91
4.3.6. Depuración y corrección de errores	92
4.4. DESARROLLAR UN ASISTENTE VIRTUAL INTELIGENTE QUE UTILICE TÉCNICAS DE APRENDIZAJE PROFUNDO PARA OPTIMIZAR LA PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ JULIACA.....	93
4.5. DISCUSIÓN	96
V. CONCLUSIONES.....	99
VI. RECOMENDACIONES.....	100
VII. REFERENCIAS BIBLIOGRÁFICAS.....	101
ANEXOS	104

Área: Inteligencia Artificial y sistema Bio-Inspirados

Tema: Asistente virtual inteligente para optimizar la productividad estudiantil en el colegio San José Juliaca

Fecha de Sustentación: 27 de diciembre del 2024



ÍNDICE DE TABLAS

	Pág.
Tabla 1 Población	46
Tabla 2 Muestra	47
Tabla 3 Técnicas e Instrumentos	49



ÍNDICE DE FIGURAS

	Pág.
Figura 1 Diagrama de Casos de uso.....	57
Figura 2 Diagrama de Arquitectura del Sistema	60
Figura 3 Diagrama de Componentes.....	61
Figura 4 Diagrama de Clases	64
Figura 5 Comparación del tiempo de despliegue.....	66
Figura 6 Diagrama de Despliegue.....	67
Figura 7 Diagrama de Secuencia	70
Figura 8 Diagrama de Actividades	73
Figura 9 Configuraciones de Hiperparámetros	75
Figura 10 Métricas de Evaluación del Modelo Predictivo.....	76
Figura 11 Comparación de Rendimiento	78
Figura 12 Resultados de Validación Cruzada	80
Figura 13 Técnicas de regularización	82
Figura 14 Diagrama de Interacción de Objetos	85
Figura 15 Tiempo de Procesamiento	89
Figura 16 Tiempo de Procesamiento	90
Figura 17 Diagrama de Estados	91
Figura 18 Comparación de precisión	94
Figura 19 Reducción de tiempo de procesamiento	95



ÍNDICE DE ANEXOS

	Pág.
ANEXO 1 Código fuente	104
ANEXO 2 Declaración jurada de autenticidad de tesis.....	108
ANEXO 3 Autorización para el depósito de tesis en el Repositorio Institucional....	110



ACRÓNIMOS

ADA	Asistente de Atención al Cliente de Electrocentro S.A.
AOF	Append Only File (Archivo Solo Añadir)
API	Application Programming Interface (Interfaz de Programación de Aplicaciones)
CI/CD	Continuous Integration / Continuous Delivery (Integración Continua / Entrega Continua)
CSV	Comma-Separated Values (Valores Separados por Comas)
DNN	Deep Neural Network (Red Neuronal Profunda)
F1-score	Métrica de Evaluación de Modelos Predictivos
IA	Inteligencia Artificial
JSON	JavaScript Object Notation (Notación de Objetos de JavaScript)
JIRA	Herramienta de Seguimiento de Errores y Gestión de Proyectos
LMS	Learning Management System (Sistema de Gestión del Aprendizaje)
MySQL	Sistema de Gestión de Bases de Datos Relacional
PLN	Procesamiento de Lenguaje Natural
RNN	Recurrent Neural Network (Red Neuronal Recurrente)
ROC	Receiver Operating Characteristic (Curva de Característica Operativa del Receptor)
SCRUM	Metodología Ágil de Desarrollo de Proyectos
SQL	Structured Query Language (Lenguaje de Consulta Estructurada)
SVM	Support Vector Machine (Máquina de Vectores de Soporte)
UCI	Unidad de Cuidados Intensivos
WPF	Windows Presentation Foundation



RESUMEN

La investigación “Desarrollo de un Asistente Virtual Inteligente para mejorar la Productividad Estudiantil en el Colegio San José Juliaca” tuvo como objetivo el desarrollo de un sistema capaz de predecir el rendimiento académico utilizando técnicas de aprendizaje profundo que facilitar la toma de decisiones en un contexto de gestión educativa. Se desarrolló un asistente virtual capaz de emitir alertas tempranas sobre estudiantes que reportaban un bajo rendimiento académico. Esto les ayudó a corregir su comportamiento analizando volúmenes de datos complejos en relación con el comportamiento de los estudiantes. Este sistema se desarrolló utilizando una arquitectura modular y microservicios, lo que proporciona una mayor eficacia en el manejo de datos extraídos de diferentes fuentes y utilizando modelos predictivos que fueron refinados mediante métodos de procesamiento y validación cruzadas. En promedio, el sistema obtuvo un 89% de precisión en predicciones basadas en varias métricas. Por último, al emplear paralelización junto con el procesamiento en lotes, el sistema fue capaz de minimizar el tiempo que requeriría de hasta un 30 por ciento para análisis en tiempo real. La implementación del sistema logró detectar de forma temprana a los estudiantes en riesgo. Esto permitió elaborar reportes que resultó ser de utilidad en la intervención educativa. Se implementó una interfaz computacional interactiva construida con Dash y Plotly, que permite el análisis y la aplicación de filtros a los datos de rendimiento académico en tiempo real, en función a los estudiantes, año académico y diversas categorías sociodemográficas. En conclusión, los resultados de la investigación demuestran que el uso de un asistente virtual inteligente en las instituciones educativas permite realizar predicciones en el rendimiento académico en el alumnado y realiza mejores aproximaciones en las intervenciones educativas en el Colegio San José Juliaca, y que a su vez posee potencial para ser implementado en otros contextos educacionales.

Palabras clave: Análisis de Datos, Aprendizaje Profundo, Asistente Virtual, Gestión Educativa, Predicción Académica.



ABSTRACT

The research “Development of an Intelligent Virtual Assistant to Improve Student Productivity at Colegio San José Juliaca” aimed at developing a system capable of predicting academic performance using deep learning techniques to facilitate decision making in an educational management context. A virtual assistant was developed capable of issuing early warnings about students who reported poor academic performance. This helped them to correct their behavior by analyzing volumes of complex data regarding student behavior. This system was developed using a modular architecture and microservices, which provides greater efficiency in handling data extracted from different sources and using predictive models that were refined through cross-processing and validation methods. On average, the system achieved 89% accuracy in predictions based on various metrics. Additionally, by employing parallelization along with batch processing, the system was able to minimize the time it would require by up to 30% for real-time analysis. The implementation of the system was able to detect at-risk students early. This allowed for reports that proved to be useful in educational intervention. An interactive computational interface built with Dash and Plotly was implemented, allowing the analysis and application of filters to academic performance data in real time, based on students, academic year and various socio-demographic categories. In conclusion, the results of the research show that the use of an intelligent virtual assistant in educational institutions allows predictions in the academic performance of students and better approximations in educational interventions at Colegio San José Juliaca, which in turn has the potential to be implemented in other educational contexts.

Keywords: Academic Prediction, Data Analysis, Deep Learning, Educational Management, Virtual Assistant.



CAPÍTULO I

INTRODUCCIÓN

Este trabajo de investigación, titulado “Implementación de un Asistente Virtual Inteligente para Optimizar la Productividad Estudiantil en el Colegio San José Juliaca”, tiene como objetivo desarrollar un sistema avanzado que utilice técnicas de aprendizaje profundo para mejorar la gestión y análisis de datos académicos, facilitando intervenciones educativas efectivas. En el contexto del Colegio San José Juliaca, los procesos de seguimiento de la productividad y rendimiento estudiantil se encuentran limitados por los métodos tradicionales de análisis, que presentan dificultades para manejar grandes volúmenes de datos y detectar patrones complejos que pueden incidir en el desempeño académico. La implementación de un asistente virtual inteligente busca abordar las diversas limitaciones mediante el uso de varias técnicas de inteligencia artificial y aprendizaje profundo que puedan permitir un análisis en tiempo real y la generación de insights personalizados para cada usuario con el fin de optimizar la toma de decisiones en la gestión educativa.

Con la explosión de nuevas tecnologías, el aprendizaje profundo se ha convertido en una herramienta clave para la clasificación, pronósticos y adecuación de datos en diferentes disciplinas, como la educación. Esta investigación propone una arquitectura de software basada en DNN (Redes Neuronales Profundas) y algoritmos paralelos que permiten no solo clasificar y segmentar a los estudiantes en grupos según los patrones en que se desempeñan, sino también proporcionar alertas tempranas para estudiantes que se encuentran en riesgo de bajo rendimiento. Igualmente, se ha desarrollado un diseño de interfaz de usuario amigable para que docentes y administradores puedan navegar en este



sistema proporcionando reportes interactivos en tiempo real y pautas de seguimiento, con lo cual se espera optimizar la velocidad y exactitud en el trabajo de los analistas académicos.

La estructura de este trabajo se divide en seis capítulos, cada uno de los cuales aporta al desarrollo del asistente virtual inteligente y a la evaluación de su impacto. En el Capítulo I, se analiza la problemática de los métodos convencionales en el seguimiento académico y se establece el marco teórico que orienta el desarrollo del sistema, incluyendo los objetivos específicos y la hipótesis de investigación. En el Capítulo II, se presenta una revisión exhaustiva de estudios recientes sobre inteligencia artificial aplicada a la educación, enfatizando el potencial del aprendizaje profundo para resolver problemas de análisis masivo de datos en contextos educativos. El Capítulo III detalla los métodos y herramientas tecnológicas implementadas en el diseño del sistema, incluyendo el pipeline de procesamiento de datos, algoritmos de preprocesamiento y estrategias de optimización para el ajuste de los modelos predictivos. En el Capítulo IV, se exponen y discuten los resultados obtenidos tras la implementación del asistente, evaluando la precisión y rendimiento del sistema en distintos escenarios de uso académico, y comparando los resultados con estudios previos. Finalmente, el Capítulo V presenta las conclusiones, resaltando las contribuciones del asistente en la mejora del análisis académico, y el Capítulo VI ofrece recomendaciones para futuras mejoras y adaptaciones del sistema en otros entornos educativos.

1.1. DESCRIPCIÓN DEL PROBLEMA DE INVESTIGACIÓN

En el Colegio San José de Juliaca, los procesos de monitoreo y la gestión académica de los estudiantes se realizan mayormente a través de técnicas tradicionales.



Estos métodos, aunque prácticos en entornos de datos más pequeños y manejables, tienen algunas desventajas al tratar con conjuntos de datos más grandes como registros académicos, datos de asistencia, evaluaciones y factores externos que pueden contribuir a la productividad y el aprendizaje. Debido a la falta de implementación de infraestructura tecnológica moderna y las técnicas analíticas automatizadas, se vuelve muy difícil recuperar patrones complejos y encontrar relaciones significativas entre los diversos parámetros que se necesitan para la mejora del rendimiento de los estudiantes.

En la actualidad, la tecnología más eficaz para procesar grandes volúmenes de datos y encontrar patrones complejos son las técnicas que se engloban bajo el término de Deep Learning dentro del contexto de la inteligencia artificial. Cabe destacar, que a través de estas técnicas se pueden obtener características latentes de datos heterogéneos como, por ejemplo, comportamientos de aprendizaje o factores de productividad, que de otro modo sería imposible emplear métodos convencionales para obtener. Si bien, la aplicación de estas técnicas en los ámbitos de formación, por ejemplo, el Colegio San José posee limitaciones, principalmente por no contar con recursos de computación y personal con el conocimiento adecuado.

Dentro de este contexto, se justifica el desarrollo de un Asistente Virtual Inteligente que implemente técnicas de aprendizaje profundo para gestionar y analizar datos vinculados a la productividad de los estudiantes. Este sistema será capaz de procesar automáticamente grandes volúmenes de información de distintos tipos y ofrecer un análisis definido y individual acerca del rendimiento de uno o varios estudiantes. Gracias a la implementación de redes neuronales, el asistente podrá diferenciar y clasificar a los estudiantes según sus patrones de productividad, sugerir nuevas formas de hacerlo mejor e incluso pronosticar su rendimiento académico en el futuro.



Esta propuesta tiene como objetivo mejorar los procesos de análisis de datos en el entorno educativo del Colegio San José al facilitar la producción de informes específicos para profesores y administradores. Esto a su vez ayudará a mejorar la toma de decisiones en cuanto a la asignación de recursos, selección de estrategias pedagógicas y seguimiento del crecimiento de los estudiantes en diferentes contextos y formas de datos. Finalmente, se espera que el desarrollo de este asistente virtual mediante el uso de técnicas de aprendizaje profundo contribuya al constante aumento de los estándares educativos y la productividad estudiantil en Juliaca.

1.2. FORMULACIÓN DEL PROBLEMA

1.2.1. Problema general

¿De qué manera el uso del asistente virtual inteligente basado en aprendizaje profundo optimiza la identificación de los patrones de productividad estudiantil y la mejora en la toma de decisiones en el Colegio San José Juliaca?

1.3. OBJETIVOS DE LA INVESTIGACIÓN

1.3.1. Objetivo general

Desarrollar un asistente virtual inteligente que emplee técnicas de aprendizaje profundo para optimizar la productividad de los estudiantes del Colegio San José Juliaca.

1.3.2. Objetivos específicos

- Diseñar la arquitectura de software del asistente virtual inteligente para el análisis de productividad estudiantil.



- Implementar y ajustar los modelos de aprendizaje profundo para predecir y analizar los patrones de productividad y rendimiento estudiantil.
- Realizar pruebas de funcionalidad y de fiabilidad del asistente virtual para asegurar la eficacia en entornos educativos.

1.4. JUSTIFICACIÓN DE LA INVESTIGACIÓN

Este estudio es necesario ya que se requiere mejorar el análisis de datos educativos en el Colegio San José de Juliaca, donde los enfoques tradicionales para el procesamiento y gestión de la información tienen grandes desventajas al tratar con grandes cantidades de datos heterogéneos. La falta de las herramientas apropiadas también es la razón por la cual los patrones complejos y las relaciones cruciales entre variables son difíciles de discernir, por lo que el uso de un asistente virtual ayuda a mejorar la productividad estudiantil y a ajustar estrategias pedagógicas y recursos educativos adecuados.

El asistente virtual inteligente que se propone en este documento de trabajo busca sortear esas limitaciones utilizando, entre otros, las redes neuronales profundas (DNN) y redes neuronales recurrentes (RNN), las cuales han demostrado eficiencia y eficacia para el análisis de grandes cantidades de datos y la lectura de relaciones no lineales dentro de ellos. Estas arquitecturas proporcionarán capacidades de análisis que incluyen patrones, asistencia, desempeño, nivel de escolaridad, entre otros, aumentando la efectividad y velocidad en las evaluaciones del desempeño académico y conductual del estudiante.

Con la integración de modelos de aprendizajes profundos, nuevas técnicas se implementarán para que el asistente virtual cumpla con tareas de segmentación de los alumnos en base a sus necesidades y predicciones de resultados a mediano y largo plazo, lo que permitiría intervenciones académicas adecuadas. La automatización en el procesamiento y análisis de estos datos recortará los tiempos requeridos en la elaboración



de reportes, haciendo a los docentes y directivos tomar decisiones sobre situaciones en tiempo real y fundamentadas.

También el uso de estas técnicas de aprendizaje profundo en el asistente virtual, podrá usar de manera más eficiente los recursos informáticos, esto es porque se implementarán procesos de análisis más completos y que sean escalables. Esta infraestructura avanzada no solo beneficiaría a la gestión educativa del Colegio San José Juliaca, sino que servirá como sustento para proyectos de replicación en otras instituciones educativas, consolidando una metodología de análisis de la productividad, y podrán adaptarse a la demanda tecnológica actual.

1.5. ALCANCES Y LIMITACIONES DE LA INVESTIGACIÓN

1.5.1. Alcance

En esta investigación se realiza el desarrollo de un asistente virtual inteligente que tiene como fin optimizar el rendimiento académico de los estudiantes en el Colegio San José Juliaca a través del uso de técnicas de aprendizaje profundo. El sistema realiza la exploración de datos académicos y de asistencia con el propósito de conseguir agrupar los datos de rendimiento y de otros aspectos que limitan la productividad por parte del alumno. El análisis se realiza mediante información histórica y presente como actas de notas, evaluación de alumnos, asistencia de los alumnos, para contar con medio de información que sirva para la gestión educativa.

El asistente virtual fue construido de manera personalizada para el contexto del Colegio San José Juliaca y cuenta con la posibilidad de ser mejorado en el futuro para satisfacer nuevas demandas pedagógicas y tecnológicas. Además, se ha previsto que el personal administrativo y docente tanto sean capacitados



sobre el uso como mantenimiento del sistema, lo que resulta en mayor efectividad en la población estudiantil de esta institución.

1.5.2. Limitaciones

Entre las limitaciones de la investigación se encuentra la adaptación exclusiva del sistema al contexto del Colegio San José Juliaca, sin contemplar su integración en otras instituciones educativas. El sistema no considera la interoperabilidad con plataformas externas, lo que puede limitar su capacidad de expansión en otros entornos académicos o su integración con sistemas de gestión ya existentes. Aunque el asistente virtual está diseñado para ser escalable, el análisis se restringe a los datos internos disponibles en el colegio, lo que implica que la calidad y precisión del análisis están condicionadas a la integridad y actualización de estos datos.

1.6. HIPÓTESIS DE LA INVESTIGACIÓN

1.6.1. Hipótesis general

La implementación de un asistente virtual inteligente basado en técnicas de aprendizaje profundo permite optimizar la identificación de patrones de productividad estudiantil y facilita la toma de decisiones estratégicas en el Colegio San José Juliaca.



CAPÍTULO II

REVISIÓN DE LITERATURA

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

2.1.1. Antecedentes Locales

Salazar Chávez, (2024) se centró en la implementación de un asistente virtual dentro de la Subgerencia de Estudios Definitivos de la Municipalidad Provincial de Puno con el fin de mejorar el tiempo que se dedica a interactuar con los usuarios, así como mejorar las tareas administrativas. Esta tarea fue posible a través de la metodología de XP (Extreme programming), uno de los objetivos fue traducir las necesidades de la oficina en un software integral. También se utilizó el procesamiento de lenguaje natural (NLP) para que los ciudadanos pudieran ser atendidos automáticamente. En el aspecto técnico, el producto final se basó en una base de datos que contiene información actualizada de solicitudes y preguntas frecuentes integradas con un backend en python. Los datos computacionales fueron procesados en hojas de cálculo y se utilizaron análisis econométricos inferenciales para medir el tiempo de prestación de servicios y los resultados obtenidos se compararon con promedios. El estudio concluyó que la adopción de la tecnología en la administración pública debería ser fomentada, ya que se notó una gran mejora en la satisfacción del usuario e incluso una moderación en la eficiencia administrativa. Los gerentes y supervisores concluyeron que el uso de un asistente estimularía el desarrollo de la cultura de las TIC en las organizaciones públicas y añadiría un gran valor al público al servir a los ciudadanos rápidamente.



Conza Mendoza, (2020) diseñó un asistente virtual para el control energético en vivienda, el prototipo para la gestión del consumo de energía en las viviendas usando redes de baja tensión. El proyecto utilizó un sistema Arduino Due, junto con el sensor SCT-13 para la medición de corriente y ZMPT101B como medidor de tensión. El asistente virtual fue programado en Visual Studio C# utilizando la arquitectura de aplicación WPF, que optimiza la interacción del usuario con el ordenador, donde se diseñó un entorno gráfico que permite observar de forma simultánea los valores de consumo de potencia y corriente, y que detecta fallos como fugas eléctricas y cortocircuitos. También se incluía un iluminador, que, mediante la tecnología de reconocimiento de voz de Microsoft, podía dar órdenes de control al asistente sobre la medición de energía. Los resultados muestran que se presentan en una situación ya diferente de la inicial con los cortes en el consumo energético y progreso en el uso de electricidad. Demostró que el asistente virtual es en esta línea colapsable porque reduce el costo de energía y amplifica de forma clara el consumo a través de una gestión frecuente y metódica de los datos.

2.1.2. Antecedentes Nacionales

Artica Llacta, (2020) desarrolló el asistente virtual ADA para Electrocentro S. A. con el fin de mejorar el servicio al cliente permitiendo a los clientes consultar sobre facturación, reportar incidentes y localizar puntos de pago respecto a su ubicación. El asistente fue construido en Dialogflow utilizando procesamiento de lenguaje natural para descifrar la intención del usuario e integrado en una arquitectura sin servidor en Netlify para solicitudes en tiempo real. Electrocentro pudo entonces utilizar Facebook Messenger para proporcionar soporte al cliente 24X7 para consultas de incidentes a través de API REST



(herramientas de interfaz de programación de aplicaciones, a través de webhooks AA facilitó el acceso inalámbrico al web de pago ADA que tenía acceso directo) al servidor habilitado para API Restfull para Electrocentro. Los resultados de la encuesta de satisfacción muestran que el 77.6% de los usuarios consideran útil al asistente, lo que representa una mejora significativa en la calidad del servicio. Si bien la comunicación se facilita a través del sistema asistente virtual, el sistema puede mejorar y hacer más eficiente el servicio al cliente.

Ramirez Martinez, (2021) elaboró un asistente virtual para el bufete de abogados Romero con la intención de ayudar en la prestación de servicios legales en términos de consultas, aumentando así la disponibilidad de información para los clientes. La investigación fue de diseño preexperimental, en el que se tomaron consideraciones de variables antes y después de la aplicación del asistente, con el fin de medir la efectividad del mismo. Impulsado por procesamiento de lenguaje natural, el asistente virtual manejó muchas consultas comunes de los clientes, permitiendo un suministro continuo de respuestas al tiempo que minimizaba la carga de trabajo del personal. Como resultado se demostró que hubo una mejora en la cuota de satisfacción al cliente, porque estaban mejor atendidos y obtenían respuestas más rápidamente. La investigación concluye que el asistente virtual es útil para la mejora de la atención al cliente que consume servicios legales al reducir la cantidad de tiempo que el usuario requiere para buscar la información.

Fajardo De la Cruz, (2021) implementó un asistente virtual en la empresa Technical Training Center, el asistente ayuda a los visitantes a resolver tareas de manera más eficiente y rápida durante el mantenimiento, cuando las estaciones de servicio Premium están cerradas, lo que modifica el enfoque en comprensiones internas automáticas en la organización y mejora la atención al cliente.



Comúnmente los asistentes virtuales responden con un del tipo. Mostrar resultados de las encuestas demostró un incremento del 18.21% en la tasa de conversión y un aumento del 38.79% en la eficacia. Se concluyó que el asistente virtual reduce el tiempo de intervención al responder las preguntas, uso de clientes abandonados. En el estudio se demostró que el asistente virtual mejora la eficiencia de la atención al cliente, lo que permite aumentar la fidelización y satisfacción de los clientes, lo que constituye una ventaja competitiva para la empresa.

2.1.3. Antecedentes Internacionales

Echeverri Torres & Manjarrés-Betancur, (2020) diseñaron un prototipo de un asistente virtual académico en el Politécnico Colombiano Jaime Isaza Cadavid con el objetivo de mejorar los tiempos de respuesta en relación con preguntas sobre diferentes procesos académicos. Dado que el asistente de IA fue creado utilizando tecnologías cognitivas de Procesamiento del Lenguaje Natural, fue diseñado para abordar una lista de preguntas comunes y ayudar a agilizar el soporte administrativo de la institución. En la fase de pruebas, se notó una mejora en las experiencias de los estudiantes como resultado de la reducción del tiempo y esfuerzo requeridos para obtener respuestas a preguntas básicas frecuentes. Según los hallazgos, el asistente virtual contribuyó a una considerable reducción en la carga de trabajo del personal administrativo, mejorando la entrega de servicios y el nivel de satisfacción de los estudiantes. Se concluyó que los asistentes virtuales tienen un potencial significativo para mejorar el tiempo de respuesta en los servicios académicos, y así ayudar aún más a los estudiantes y a la administración.



Rubio et al., (2022) diseñaron UBOT, un asistente virtual destinado a fomentar la comunicación en entornos de aprendizaje en línea como la Universidad Bernie O Higgins, con la intención de proporcionar apoyo tanto administrativo como procedural a estudiantes y profesores. Sin embargo, UBOT fue desarrollado para ayudar en la respuesta a preguntas comunes y también para ofrecer información socio-afectiva mediante la provisión de una interfaz de IA conversacional. Durante las pruebas, los usuarios mostraron una gran apreciación por su alta aceptación, ya que disfrutaban de la constante disponibilidad de UBOT. El resultado mostró que el asistente virtual ayudó en gran medida con la información administrativa, lo que mejoró aún más la relación entre el estudiante y la universidad. También se afirmó que había mejores formas de utilizar este UBOT para entornos virtuales, ya que mejoró significativamente el compromiso y aumentó los sentimientos de comunidad entre los estudiantes.

Ortiz Elías & Dávila Morán, (2023) en su trabajo de investigación buscaron la vinculación de los estudiantes con los servicios académicos, fue uno de los estudios que revisó la integración de un asistente virtual en una universidad en Perú. Es decir, dentro de un diseño no experimental y con un enfoque cuantitativo, se tomaron en cuenta e indicaron los tiempos de respuesta, la eficiencia y percepción del usuario. Mediante encuestas de opinión con escala de Likert, los datos que se obtuvieron demostraron cambios positivos en tiempos y eficiencia del servicio para los estudiantes. Según concluyeron el asistente virtual, además, los asistentes son útiles en el ámbito educativo ya que los estudiantes no solo tienen facilidad de acceder a la información sectorial verbal y de las imágenes asistidas por computadora, sino que la atención es más rápida y la unidad de soporte tiene mejores resultados con respecto a su funcionamiento.



2.2. MARCO TEÓRICO

2.2.1. Definiciones generales

2.2.1.1. Introducción a la Inteligencia Artificial en el Contexto

Educativo

La aplicación de la Inteligencia Artificial (IA) en la educación hace posible utilizar tecnologías avanzadas que mejoran el aprendizaje y aumentan la productividad de los estudiantes a través de sistemas individualizados. Los asistentes virtuales de IA pueden observar y evaluar el rendimiento del estudiante, reconocer patrones de aprendizaje y adaptar los materiales durante la lección. Este método de enseñanza permite a los estudiantes beneficiarse de una educación adaptativa y personalizada donde trabajan con sistemas que ya son conscientes del nivel y la velocidad actuales del estudiante, lo que aumenta la retención del conocimiento y el entusiasmo académico. Las limitaciones existentes están asociadas con la comprensión contextual y el reconocimiento de emociones, que son necesarios para una educación holística. Si el desarrollo de la IA continúa, su lugar en la educación cambiará drásticamente la experiencia educativa convencional y permitirá mayores y más oportunidades de aprendizaje individualizado. (Russell & Norvig, 2020)

2.2.1.2. Fundamentos de la Inteligencia Artificial y su Aplicación en la Educación

En educación, los principios de la inteligencia artificial se fundamentan en algoritmos que analizan enormes cantidades de datos para informar la filosofía de 'enseñar' al alumno. La IA hace más que solo



permitir la personalización del contenido, promueve el monitoreo del progreso de los estudiantes y por tanto da lugar a realizar intervenciones efectivas. A mediano y largo plazo, los sistemas de enseñanza pueden ser optimizados gracias a algoritmos, tales como redes neuronales, el aprendizaje supervisado o los modelos predictivos que previenen problemas antes de que sean considerados como tales. El verdadero valor de la IA para procesos educativos radica en su profunda posibilidad de personalización hacia cada estudiante en concreto, lo que en suma beneficia considerablemente el desarrollo y el aprendizaje. (Mitchell, 2021)

2.2.1.3. El Papel de la IA en la Mejora de la Productividad

Estudiantil

La IA se centra en mejorar la productividad de los estudiantes, los estudiantes automatizan actividades que se repiten y hacen sus métodos de estudio más eficientes. La automatización de los procesos productivos hace más eficaces a los asistentes virtuales, que ahora pueden no solo sugerir formas de estudiar, sino también controlar el tiempo, recordando la importancia de las fechas, de modo que el alumno pueda ser más eficiente con el tiempo. Este tipo de inteligencia artificial permite enfocarse más en aprender y desarrollarse como persona al disminuir el tiempo en realizar tareas administrativas. De igual forma, se asegura que la IA sirva de apoyo brindando constante retroalimentación, que a la vez es especial para que los estudiantes fomenten su motivación y se reorienten a aquellas áreas que necesitan mejorar si se quieren alcanzar niveles de



productividad en el contexto escolar elevados. (Goleman & Boyatzis, 2020)

2.2.1.4. Aprendizaje Profundo en Asistentes Virtuales Educativos

Deep learning es un método que se sirve de redes neuronales compuestas por más de una capa y que permite el análisis de datos en volumen, lo que modifica en gran medida las redes académicas al analizar los patrones de comportamiento por parte de los estudiantes. Esta metodología en todo lo relacionado con VAs es de fundamental importancia, puesto que da la posibilidad de más o menos estimar de forma igual y diferente las características del estudiante junto con su desarrollo. En estos sistemas al grado que se va mejorando hubiera más exactitud en las sugerencias y modificaciones de constantes didácticas, por lo cual cuando se da un entorno completo para aprender. El deep learning es capaz de mejorar por sí mismo a medida que pasa el tiempo de tal forma que el VA pueda ser capaz de atender preguntas y ofrecer gran experiencia a los usuarios. (Goodfellow et al., 2016)

2.2.1.5. Aplicación de Redes Neuronales para la Identificación de Patrones de Estudio

Esta tecnología hace uso de redes neuronales para el estudio de patrones de aprendizaje al permitir al sistema educativo ubicar áreas de mayor o menor interés o dificultad de un estudiante. Este análisis facilita ajustar los contenidos y las actividades para satisfacer mejor las necesidades de cada persona. Las redes neuronales interpretan datos intermedios como el tiempo de respuesta, el tipo de preguntas y los



resultados de las pruebas, gracias a su estructura en capas y su capacidad de aprender, y de esta manera proporcionan un enfoque diferente al aprendizaje centrado en las necesidades de un individuo. Esta aplicación es crucial para mejorar la efectividad del proceso educativo y elevar los niveles de retención del conocimiento. (Bishop, 2021)

2.2.1.6. Procesamiento de Lenguaje Natural para la Interacción

Estudiantil

Los asistentes virtuales hacen uso del procesamiento de lenguaje natural para interactuar de manera efectiva con los estudiantes haciendo preguntas y respondiendo en lenguaje natural. Mejorar la experiencia de un usuario depende en gran medida del procesamiento de lenguaje natural, ya que permite una interacción fácil e intuitiva sin la necesidad de utilizar comandos establecidos. El procesamiento del lenguaje allí identifica el contexto en los sistemas educativos y proporciona respuestas relevantes con un lenguaje y complejidad adecuados para el estudiante al que se dirige, y aprender un lenguaje apropiado se vuelve más fácil. También permite a los asistentes virtuales en educación entender y responder preguntas cuando se les hacen, mejorando la independencia de los estudiantes. (Jurafsky & Martin, 2021)

2.2.1.7. Transformadores y Modelos Avanzados de PLN en

Asistentes Virtuales

Los transformadores modernos integran mecanismos de autoatención y han hecho grandes avances en el procesamiento del lenguaje natural. Su integración en asistentes virtuales ha aumentado la



precisión de la interpretación de palabras y frases en contexto, ya que mejoran la capacidad de captar las relaciones semánticas entre frases y palabras. El uso de transformadores ha mejorado la forma en que los usuarios interactúan con los asistentes de enseñanza virtual, ya que aumentaron drásticamente la capacidad de los sistemas para generar respuestas precisas y basadas en contextos. En términos de ayuda educativa, los transformadores mejoran la capacidad del asistente para responder preguntas complicadas y considerar el contexto más amplio de la pregunta formulada. (Brown, 2022)

2.2.1.8. Métodos Estadísticos en el Procesamiento de Lenguaje para Análisis de Datos Educativos

En lo que respecta al papel de los métodos estadísticos, son uno de los más importantes en el análisis de datos educativos que involucran la interacción entre asistentes virtuales y estudiantes. Herramientas como el análisis de regresión, análisis de clúster y pruebas de hipótesis son esenciales para extraer el nivel complejo de compromiso entre los estudiantes y los asistentes de enseñanza virtual y personalizar el contenido educativo. Complementariamente, los modelos estadísticos permiten la identificación de patrones en las interrogantes o respuestas brindadas por los estudiantes, lo que posibilita la elaboración de pronósticos sobre sus futuras necesidades y realizar modificaciones apropiadas en los insumos de enseñanza. El uso de métodos estadísticos aumenta la competencia del asistente virtual, en cuanto a ser capaz de estimar las necesidades de los alumnos. (Manning & Schütze, 2020)



2.2.1.9. Automatización de la Comunicación Educativa con Asistentes Virtuales

La automatización en la comunicación educativa por medio de asistentes virtuales facilita la personalización de la vivencia del estudiante y da respuesta a preguntas en el instante sin necesidad de la existencia de una persona. Estos asistentes están programados para responder a preguntas frecuentes, administrar horarios de estudio y orientar a los alumnos sobre procesos académicos, optimizando así el tiempo de los docentes y del personal administrativo. Con el aprendizaje automático, los asistentes pueden perfeccionarse con el paso del tiempo a medida que practican diferentes estilos de aprendizaje. La automatización en educación no solo ayuda a mejorar las relaciones, sino también a usar de manera más eficiente los recursos educativos, lo que favorece el proceso de enseñanza-aprendizaje. (Brownlee, 2020)

2.2.1.10. Inteligencia Artificial Cognitiva en Sistemas Educativos

Interactivos

Con el uso de inteligencia artificial cognitiva, los sistemas interactivos de educación son modificados teniendo en cuenta las necesidades del estudiante mediante el análisis de respuestas y comportamientos. Al combinar el procesamiento del lenguaje con modelos de aprendizaje automático, el reconocimiento de voz y la interpretación del contexto se han convertido en características mejoradas de los asistentes virtuales. Dichos sistemas fomentan el aprendizaje autodirigido así como la motivación estudiantil debido a su estrategia educativa única,



mediante la cual se asiste a los estudiantes de manera personalizada a lo largo del curso. (Russell, 2020)

2.2.1.11. Asistentes Virtuales Basados en Aprendizaje Automático

Los asistentes educativos virtuales basados en aprendizaje automático pueden cambiar en tiempo real de acuerdo con el ritmo, el ritmo y los requisitos individualizados del estudiante. Estos sistemas incorporan algoritmos de aprendizaje supervisado y no supervisado que facilitan la optimización del contenido. Al capturar datos de interacción en tiempo real, los asistentes pueden adaptar sus sugerencias, apoyo o instrucciones en relación con cómo un estudiante individual comprende el material. Dichas mejoras continuas crean un mecanismo de retroalimentación que integra información que, con el tiempo, permite a los asistentes responder de manera más precisa e intensiva a las necesidades de los usuarios, optimizando la experiencia de aprendizaje de los usuarios. La incorporación de esta metodología no solo mejora la efectividad del proceso de enseñanza-aprendizaje, sino que también ayuda a detectar con antelación áreas que el alumno podría requerir mayor apoyo. (Kubat, 2021)

2.2.1.12. Desarrollo de Modelos Predictivos para el Rendimiento

Académico

Los modelos predictivos resultan indispensables para predecir la trayectoria escolar y orientar el campo educativo de acuerdo a lo que se prevé que requieran los estudiantes. Se basan en la identificación de patrones en las actividades de los estudiantes, como la regularidad y la



exactitud en la contestación de evaluaciones, mediante el uso de algoritmos de clasificación y regresión. Con el fin de atender ciertas solicitudes, algunos asistentes virtuales pueden predecir con mayor efectividad que otros los resultados académicos a partir de realizar recomendaciones a los estudiantes sobre el material de estudio y recursos específicos que pueden requerir. Este uso de la predicción también facilita la toma de decisiones dentro del ámbito académico al permitir acciones proactivas y ajustadas a tiempo con el objetivo de crear un ambiente propicio para el proceso educativo y logros académicos. (Silver & Sutton, 2021)

2.2.1.13.Reconocimiento de Voz en Asistentes Educativos

Esta tecnología tiene gran importancia en ambientes de aprendizaje inclusivo ya que permite que los aprendices ciegos o con discapacidades motoras operen con el asistente. Apoyándose en algoritmos de procesamiento de audio y redes neuronales, los asistentes educativos son capaces de comprender y ejecutar órdenes de voz dentro de un contexto determinado, en el que son capaces de entender lo que un usuario quiere y modifican la manera de responder a dicho usuario o brindan recursos que se le solicitan. Incluso se complementan con técnicas más sofisticadas en PLN que abarcan la contextualización de palabras que se usan para realizar un mejor entendimiento del asistente. (Szegedy & Brown, 2021)



2.2.1.14. Evaluación y Optimización del Tiempo de Respuesta en Asistentes Virtuales

Las autoevaluaciones mediante paneles receptores preprogramados, son herramientas determinantes para el aprendizaje y adquisición de nuevos conocimientos. Adicionalmente, estos sistemas consideran la interacción con los usuarios por medio del uso de redes neuronales con baja latencia. En una plática en la clase, dicho mecanismo ayuda a enriquecer la interacción, y resalta que la eficiencia en el tiempo de respuesta es clave para asegurar usabilidad y efectividad en un asistente virtual. Esto no solo mejora la satisfacción del usuario, sino que también permite una comunicación rápida y eficiente, lo cual es fundamental en el aprendizaje, ya que en ocasiones la calidad del aprendizaje se puede ver alterada por la falta de inmediatez. La optimización del tiempo de respuesta también habilita al asistente para manejar varias consultas al mismo tiempo, asegurando que ningún estudiante se quede sin asistencia por un largo período. (Chen, 2020)

2.2.1.15. Análisis de Datos en Tiempo Real para Retroalimentación Personalizada

El análisis de los datos en tiempo real permite a los asistentes educativos virtuales proporcionar a los estudiantes retroalimentación instantánea a través de recomendaciones y recursos que se adaptan mejor a los estudiantes según su rendimiento más reciente. Esta técnica emplea transmisión de datos y computación en la nube para analizar interacciones en tiempo real con el fin de proporcionar sugerencias o alarmas de manera



automatizada. En tiempo real, el asistente puede analizar datos de comportamiento o variaciones en el rendimiento y ayudar a los estudiantes a modificar sus estrategias de estudio en consecuencia. Esto no solo mejora el proceso de aprendizaje, sino que, más importante aún, permite a los estudiantes responder rápidamente a cualquier problema que puedan experimentar. (Larson, 2021)

2.2.1.16. Integración de Asistentes Virtuales en Plataformas

Educativas Digitales

El uso de educadores virtuales en plataformas de aprendizaje, particularmente en sistemas de gestión de aprendizaje, mejora la comunicación en el contexto del aula en línea. Esto quiere decir que el estudiante puede conseguir la información, el servicio, el recurso sin necesidad de moverse de una interfaz. A través de APIs y conectores especializados, los asistentes pueden extraer información de las plataformas, controlar el avance del estudiante y hacer preguntas y respuestas sobre cursos, tareas y calificaciones. La cooperación en la plataforma educativa también hace posible que el asistente consulte con usos decididos mejorando así su desempeño. (Zhou, 2020)

2.2.1.17. Automatización de Consultas Frecuentes en Entornos

Educativos

El desarrollo que permite el ente virtual en la automatización de la respuesta a preguntas comunes, los estudiantes empiezan a recibir respuestas sin demoras, para cuándo son los exámenes, en qué fechas son las inscripciones y para cuándo se lleva a cabo el curso. Así, los asistentes



virtuales que aplican bases de conocimiento y técnicas de aprendizaje supervisado pueden abordar de manera competente y eficiente tales preguntas. Esto no solo libera tiempo del personal administrativo, sino que también garantiza la asistencia a los estudiantes. Esta automatización disminuye mucho la espera, puesto que garantiza que el estudiante cuente con la información que necesita para actuar por sí mismo en su aprendizaje. (Alpaydin, 2021)

2.2.1.18. Evaluación de la Productividad Mediante Asistentes

Inteligentes

El uso de asistentes inteligentes para la medición de la productividad en los estudiantes permite conocer como un estudiante se dedica al uso de atributos pecuniarios y el tiempo que dispone de manera académica. Al analizar los datos de uso y los patrones de interacción, es posible estimar los indicadores de productividad, como el tiempo dedicado a varias tareas o su finalización, el número de solicitudes y el grado de cumplimiento con los horarios de estudio recomendados. Esta información es valiosa no solo para los estudiantes, sino también para los profesores y los padres que desean comprender y mejorar el rendimiento académico. Además, la retroalimentación orientada a métricas puede ayudar a los alumnos a darse cuenta y abordar las subhabilidades que reducen su productividad y así mejorar su autogestión en el proceso. (Murphy, 2022)



2.2.1.19. Personalización del Aprendizaje con Sistemas Basados en Recomendación

Los sistemas de recomendación emplean filtrado colaborativo y algoritmos basados en contenido para reestructurar el proceso educativo de acuerdo con los intereses y necesidades de los estudiantes. Los sistemas educativos de esta naturaleza hacen sugerencias sobre contenido específico y actividades y estrategias instruccionales apropiadas para el perfil del alumno, examinando primero el rendimiento, los intereses y el historial de comportamiento de los alumnos. La necesidad de aprender un tema particular que un estudiante siente que es relevante y tal vez difícil le permite reunir experiencias de aprendizaje enriquecedoras. Cuando se integra dentro de un asistente virtual, el uso de recomendaciones tiene el potencial de aumentar la retención y la satisfacción del estudiante en respuesta a un aprendizaje más adaptativo. (Zhang & Li, 2022)

2.2.1.20. Interfaz de Usuario y Experiencia en Asistentes Virtuales Educativos

Tanto la interfaz de usuario como la experiencia son importantes a la hora de crear asistentes virtuales que sean fáciles de usar y agradables. En un entorno académico, una interfaz debería estar capaz de optimizar la localización de diferentes recursos al tiempo que permite responder a las consultas de los estudiantes de manera rápida. Dentro de la experiencia del usuario no solo se considera la usabilidad en sí, sino otros aspectos como el entendimiento en el uso o la interacción gráfica. La interacción amigable desde el punto de vista gráfico optimiza la interacción y acceso de los



estudiantes y asegura que el asistente virtual se utilice eficientemente en el espacio educativo. (Chollet, 2021)

2.2.1.21. Implementación de Técnicas de Machine Learning en la Educación

La educación moderna no se puede pensar sin el uso de la tecnología. Por ello, existen Modern Teachers que son estudiantes, padres y tutores de alumnos y utilizan herramientas diversas para adaptarse a sus requerimientos y estilos de aprendizaje, entre estas se encuentra la importancia de la educación y el aprendizaje automático que permite optimizar e individualizar la técnica de enseñanza que se utiliza en el alumno. Entre otro de los usos de los métodos de machine learning está sus supuestos que son: adaptarse, organizarse y ajustarse a las expectativas del estudiante, mediante el uso de términos clásicos y computacionales como los árboles de decisión y las máquinas de soporte vectorial (SVM). Estos tipos de modelos también permiten de cierto modo encontrar patrones que existen en la información recolectada por los alumnos y que generalmente no se pueden observar manualmente que sirven para el hecho de crear estrategias para el aprendizaje personal. Buüşmacx, el uso de machine learning se vuelve indispensable porque es enriquecedor para la personalización y optimización del aprendizaje. (Gupta, 2022)

2.2.1.22. Medición de la Eficiencia y Satisfacción en el Uso de Asistentes Virtuales

La eficiencia y satisfacción de los estudiantes que utilizan asistentes virtuales se miden con la ayuda de encuestas de experiencia del



usuario y análisis de métricas. Las evaluaciones realizadas ayudan en la mejora de la funcionalidad del asistente al identificar las áreas que requieren mejora. Parámetros como el tiempo de respuesta, la exactitud de las recomendaciones y el número de sugerencias proporcionadas son recordatorios que ayudan a determinar la efectividad del asistente en la educación. La satisfacción y eficiencia de los estudiantes no solo reflejan la efectividad del asistente, sino que también trabajan para fortalecer aún más los resultados positivos del asistente en la educación al asegurar que se cumplan los objetivos de ayudar en el aprendizaje y de involucrar a los niños con los estudiantes (Feldman & Sanger, 2021)

2.2.1.23.Ética y Privacidad en el Uso de Asistentes Virtuales

Educativos

El uso de asistentes virtuales en la enseñanza no está exento de plantear preguntas éticas y de privacidad que son relevantes en esa área de aplicación. La preocupación derivada de la protección de información sensible es impulsada por el uso de datos recopilados y los perfiles personales generados para los estudiantes con el fin de personalizar la experiencia de aprendizaje. Uno de los temas más preocupantes en torno a la creciente integración de la tecnología en la educación es la privacidad de los datos. Para ilustrar esto, considere una empresa de tecnología que pretende desarrollar un asistente virtual que pueda ser utilizado en múltiples instituciones educativas para ayudar a los profesores en las lecciones. Algunas instituciones pueden argumentar que hay problemas éticos relacionados con el intercambio de datos de estudiantes. Estos datos incluyen biografías de estudiantes, imágenes, muestras de trabajo, etc. Las



instituciones temen que los estudiantes puedan ser abusados y que sus datos puedan ser mal utilizados. Analicemos cómo se pueden resolver estas preocupaciones de privacidad para aumentar la competencia en el mercado de soluciones tecnológicas educativas. Primero, es necesario realizar una investigación exhaustiva sobre qué datos se pueden almacenar y qué tipo de información se puede recopilar sobre estudiantes, padres e instituciones. Si se introduce una tecnología en una institución, debe haber una comprensión amplia de los datos que se pueden recopilar, quién los gobernará y qué regulaciones se implementarán para garantizar su funcionamiento seguro y protegido con los estudiantes. (Smith, 2021)



CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. TIPO Y DISEÑO DE INVESTIGACIÓN

Este trabajo de investigación es de tipo aplicada, centrado en el desarrollo de un asistente virtual inteligente que utiliza técnicas de aprendizaje profundo para optimizar la productividad estudiantil en el Colegio San José Juliaca. Su propósito es resolver un problema práctico aplicando conocimientos avanzados de inteligencia artificial para mejorar el procesamiento y análisis de datos académicos y de asistencia, con el fin de identificar patrones de rendimiento y factores de éxito estudiantil.

La investigación tiene un diseño cuasi-experimental en la medida que se manipuló y controló algunas variables dentro del espacio educativo real, con el objetivo de poder valorar el efecto del asistente virtual inteligente. Las variables dependientes son el reconocimiento de patrones de las actividades productivas realizadas por estudiantes y el problema de análisis de factores claves, en tanto que las variables independientes son los modelos de aprendizaje profundo que fueron utilizados. La muestra en instrucciones no es aleatoria, con base en la historia y datos de niños del colegio, se puede evaluar de manera que el análisis de datos profundos ayuda a la mejora de la gestión de las decisiones educativas.

- Método: Elaboración y aplicación de algoritmos de aprendizaje profundo a un asistente virtual.
- Tipo de investigación: Aplicada.
- Nivel de investigación: Explicativo.
- Diseño de investigación: Cuasi-experimental.



3.2. POBLACIÓN Y MUESTRA

3.2.1. Población

La población de este estudio incluye a todos los estudiantes y docentes del Colegio San José Juliaca, quienes representan los grupos principales para el análisis de productividad estudiantil. La población estudiantil se distribuye en cinco grados académicos, y el total de estudiantes y docentes es el siguiente:

Tabla 1

Población

Grupo	Descripción de la población	Cantidad
Primero	Estudiantes del primer grado	21
Segundo	Estudiantes del segundo grado	28
Tercero	Estudiantes del tercer grado	27
Cuarto	Estudiantes del cuarto grado	23
Quinto	Estudiantes del quinto grado	19
Docentes	Docentes de todos los grados	16
Total	Total de estudiantes y docentes	134

3.2.2. Muestra

Para la selección de la muestra, se utilizó un método de muestreo aleatorio estratificado, con el fin de asegurar que todos los grados académicos y el grupo docente estén representados proporcionalmente. Según Sampieri (2018), el muestreo aleatorio estratificado es adecuado para capturar las características

específicas de subgrupos dentro de la población, lo que mejora la precisión y representatividad de los resultados.

Dado el tamaño reducido del grupo de docentes (16), todos fueron incluidos en el estudio para asegurar una evaluación completa y exhaustiva de sus aportes en el análisis de productividad estudiantil.

Tabla 2

Muestra

Grupo	Descripción de la población	Cantidad
Primero	Estudiantes del primer grado	16
Segundo	Estudiantes del segundo grado	22
Tercero	Estudiantes del tercer grado	21
Cuarto	Estudiantes del cuarto grado	18
Quinto	Estudiantes del quinto grado	14
Docentes	Docentes de todos los grados	16
Total	Total de estudiantes y docentes	107

3.2.3. Ubicación y Descripción de la Población

El ámbito de estudio se centra en la población estudiantil y docente del Colegio San José Juliaca, ubicado en la ciudad de Juliaca, provincia de San Román, en el departamento de Puno, Perú. Esta institución educativa de gestión privada ofrece educación secundaria en un entorno urbano y cuenta con una población mixta de estudiantes.



- Nombre: Colegio San José Juliaca
- Código Modular: 1259720
- Nivel Educativo: Secundaria
- Ubicación: Jr. Gonzales Prada 433, Juliaca, Puno
- Turno: Mañana

3.3. TÉCNICAS E INSTRUMENTOS

3.3.1. Técnicas e instrumentos para la recolección de datos

En esta investigación, se emplearon diversas técnicas e instrumentos con el objetivo de recolectar datos relevantes para el análisis de patrones de productividad estudiantil mediante técnicas de aprendizaje profundo en el Colegio San José Juliaca. Las fases clave incluyeron:

- Planificación técnica del proyecto para determinar los límites de recolección de datos y los objetivos definidos.
- Recolección de datos académicos y sociodemográficos que se conservan en los registros escolares.
- Procesamiento y análisis de los datos recuperados para descubrir patrones de productividad y logros basados en los estudiantes.

A continuación, se presentan las técnicas e instrumentos específicos de recolección de datos:

Tabla 3

Técnicas e Instrumentos

Técnicas	Justificación	Instrumento
Revisión de registros académicos	Recolección de información sobre historial académico y rendimiento estudiantil.	Base de datos de registros académicos
Análisis de datos educativos	Identificación de patrones en el rendimiento académico y factores de productividad.	Dataset estructurado de datos académicos
Análisis sociodemográfico	Análisis de características demográficas y socioeconómicas relevantes.	Base de datos sociodemográfica

3.3.2. Técnicas para el análisis de la información

Para validar los resultados obtenidos mediante técnicas de aprendizaje profundo, se ha realizado un análisis exhaustivo de los datos recolectados. El análisis se ha enfocado en identificar patrones de productividad estudiantil y hacer la correlación con los factores sociodemográficos relevantes. Se emplearon algunas métricas clave, como la precisión de las predicciones, la identificación de varios factores de riesgo y la correlación entre las variables académicas y sociodemográficas. Estos resultados fueron comparados con el marco teórico y también fueron contrastados con los objetivos de la investigación.



3.3.3. Técnicas para el procesamiento de datos

- Base de datos de registros académicos: Utilizada para almacenar y organizar los datos históricos de rendimiento académico, asistencia y progreso estudiantil.
- Dataset estructurado de datos educativos: Conjunto de datos creado a partir de los registros académicos y sociodemográficos, facilitando su análisis mediante técnicas de aprendizaje profundo.
- Base de datos sociodemográfica: Contiene datos sobre el entorno socioeconómico de los estudiantes, enriqueciendo el análisis y modelado de patrones educativos.

3.4. PLAN DE TRATAMIENTO DE DATOS

El tratamiento de los datos fue elaborado por medio de procedimientos estandarizados para asegurar una correcta interpretación de los datos y un análisis detallado de la información educativa en el Colegio San José. Las fases del plan incluyeron:

- Codificación y Tabulación. Se organizó y preparó la información sociodemográfica y académica en un archivo adecuado que garantizara su consistencia y su análisis posterior a través de aprendizaje profundo.
- Análisis Descriptivo. Se dispuso de un análisis descriptivo en torno al problema de la distribución de estos datos respecto a valores importantes como el promedio de productividad estudiantil y la dispersión de esta, estableciendo patrones iniciales sobre el rendimiento académico.
- Análisis Inferencial. A partir del análisis de dos variables, se determinaron patrones entre la información que no se pudo observar por la falta de análisis, se



consideró una inferencia para el análisis de datos obtenidos de alumnos del ciclo 2022.

- Visualización de Resultados: Gráficos y tablas fueron utilizadas como parte de la presentación de los datos procesados, lo que les permitió una mejor interpretación visual de los patrones y relaciones pertinentes en los resultados académicos.
- Interpretación de Métricas: Los resultados obtenidos, por ejemplo, promedios, desviaciones estándar y correlaciones entre factores académicos y sociodemográficos excesivos, fueron analizados en el contexto del propósito de la investigación que permitió llegar a conclusiones sobre la eficiencia de los métodos de aprendizaje profundo para determinar factores de riesgo y patrones de comportamiento de los estudiantes exitosos.

3.4.1. Análisis de datos

El análisis de los datos se sustentó en evaluar la efectividad de las técnicas de aprendizaje profundo implementadas en la identificación de patrones de productividad estudiantil. Para evaluar la efectividad de estas técnicas se compararon los resultados obtenidos con el estado anterior de los datos y se examinaron las relaciones entre las variables dependientes (el rendimiento académico) y las variables independientes (factores sociodemográficos y educativos). Este análisis permitió extraer conclusiones sólidas sobre los factores que influyen en el éxito académico de los estudiantes y validar las hipótesis formuladas en todo el estudio.



3.5. APLICACIÓN DE LA METODOLOGÍA

3.5.1. Metodología en Prototipo

Se siguió una metodología de prototipado en este estudio para permitir que se llevaran a cabo múltiples enmiendas en el asistente virtual inteligente con el propósito de analizar la productividad de los estudiantes utilizando técnicas de aprendizaje profundo. Este enfoque fue elegido debido a su relativa facilidad de uso y la capacidad de permitir una mayor mejora del modelo predictivo. Las principales características que pueden explicar esta elección fueron:

- Ciclo de retroalimentación: Cada etapa del proceso de desarrollo fue incorporada con bucles de evaluación y ajuste para permitir que el modelo del asistente se reajustara constantemente en función de los resultados de cada iteración. Esto permitió la mejora de las predicciones métricas de productividad y rendimiento del estudiante para alcanzar el nivel requerido.
- Estrategia de Validación: Se llevaron a cabo pruebas de prueba basadas en la historia a intervalos regulares para verificar la precisión del modelo y permitir que sus parámetros fueran ajustados. Este método aumentó la eficiencia del proceso de validación del modelo cuando se implementó en un entorno controlado y sin interacción directa con los usuarios finales.
- Mitigación de Riesgos: El uso de prototipado iterativo hizo posible reconocer y aliviar el riesgo de emplear datos heterogéneos al ajustar los métodos de manipulación de datos antes de la implementación a mayor escala.



- Ajuste a nuevas variables: Mientras estaba en desarrollo real, el prototipo fue modificado para poder predecir algunos indicadores sociodemográficos que no se habían contemplado originalmente, mejorando así la capacidad de predicción del asistente.

3.5.2. Material Experimental

3.5.2.1. Infraestructura Tecnológica

- Almacenamiento y procesamiento: Para el almacenamiento seguro y eficiente de los datos académicos y sociodemográficos, se utilizaron bases de datos distribuidas, permitiendo un acceso rápido a los registros históricos y facilitando la consulta en cada iteración del modelo.
- Hardware: Se utilizaron estaciones de trabajo de alto rendimiento para manejar el procesamiento paralelo de grandes volúmenes de datos y entrenar los modelos de aprendizaje profundo del asistente virtual. Se implementaron también sistemas de respaldo para prevenir pérdidas de información durante el proceso de desarrollo.
- Software: Se utilizaron los entornos más sofisticados para el aprendizaje acelerado tales como bibliotecas de Python para el modelado y plataformas para el análisis de datos masivos. Estas herramientas facilitaron tanto el análisis exploratorio que tanto el desarrollo de los algoritmos.
- Almacenamiento y procesamiento: El uso de bases de datos distribuidas permitió el almacenamiento seguro y eficiente de la



información académica y sociodemográfica, garantizando un acceso rápido a la historia y facilitando el acceso en cada iteración del modelo.

3.5.3. Recursos Digitales y Servicios

- Servicios en la Nube. Para el entrenamiento del modelo y el procesamiento paralelo de datos, se empleó una infraestructura basada en la nube que permitió escalar los recursos según los requisitos del proyecto y optimizar los tiempos de procesamiento.
- Monitoreo y mantenimiento. Durante las fases críticas del desarrollo, hubo asistencia técnica especializada en el apoyo del personal donde estaban los grandes volúmenes de datos que se requerían gestionar.

3.5.4. Materiales de Apoyo

- Estaciones de Trabajo. Con el propósito de escribir scripts de procesamiento de datos, visualizar resultados y evaluar modelos, se utilizaron computadoras de alto rendimiento.
- Documentación del proyecto. Las etapas de desarrollo del asistente virtual se facilitaron mediante una cuidadosa documentación del progreso del diseño y el registro de las decisiones tomadas en cada iteración del prototipo, para garantizar la mejora continua y los ajustes de optimización.

3.6. ASPECTOS ÉTICOS

Durante la ejecución de esta investigación, se observaron rigurosamente los principios éticos Mantener la integridad y la responsabilidad es de suma importancia en cada etapa del proyecto, ya sea en lo que respecta al análisis de datos o la aplicación de



técnicas avanzadas de aprendizaje automático. Los principales principios éticos seguidos durante el curso de esta investigación son:

- Relación con Instituciones Educativas y la Sociedad: La productividad de un estudiante puede verse impactada por varios factores, y analizar los datos educativos ayuda a mejorar la comprensión de esos factores, ayudando en el desarrollo de estrategias pedagógicas más efectivas en el Colegio San José. Esto está en línea con la responsabilidad ética de mejorar la igualdad y calidad de la educación a través del uso responsable de la tecnología y los datos.
- Manejo de Datos: La adherencia a la ley es crucial, y aquellos que recopilaban los datos, ya sean académicos o sociodemográficos, fueron tratados con estricta confidencialidad que garantizaba que todos los estudiantes participantes eran anónimos. Además, el aprovechamiento de la información recopilada solo con fines de investigación aseguró que se priorizara la protección de la privacidad de los estudiantes, previniendo cualquier acceso no autorizado a información personal identificable.
- Claridad y responsabilidad: La interacción con modelos de aprendizaje profundo es una fuente de datos que se informó de manera imparcial y, más importante, de forma objetiva, lo que también no viola la ética en la investigación y desarrollo de tecnología. Las metodologías utilizadas fueron exhaustivas, por lo que los resultados obtenidos fueron claros sin elementos subjetivos.
- Consentimiento Institucional y Cumplimiento: Se mantuvo la privacidad hacia estudiantes y profesores ya que no hubo contacto directo. Se protegió el derecho de los individuos sobre los datos utilizados, y al mismo tiempo, se realizó el análisis de acuerdo con las políticas del Colegio San José de Juliaca y la ley sobre el uso de datos educativos.



CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

En este capítulo se detallan los resultados de la investigación, que tuvo como objetivo construir e implementar un asistente virtual inteligente capaz de analizar la productividad y el rendimiento de los estudiantes del Colegio San José Juliaca. El proceso utilizado consistió en técnicas avanzadas de aprendizaje profundo que culminaron en el análisis completo de patrones académicos y socioeconómicos, el desarrollo de una estructura modular, modelos predictivos y pruebas funcionales extensas.

4.1. DISEÑO DE LA ARQUITECTURA DE SOFTWARE DEL ASISTENTE VIRTUAL INTELIGENTE ORIENTADO AL ANÁLISIS DE PRODUCTIVIDAD ESTUDIANTIL.

La estructura de la arquitectura del asistente virtual inteligente se basa en los escenarios de caso de uso marcados que describen las interacciones de las funcionalidades del sistema con el usuario final y el administrador. Estos incluyen la visualización de datos, la generación de gráficos interactivos, la consulta de datos en bruto, el preprocesamiento de datos, el entrenamiento de modelos y la configuración del sistema, asegurando un flujo de trabajo bien definido, modular y optimizado tanto para requisitos analíticos como técnicos.

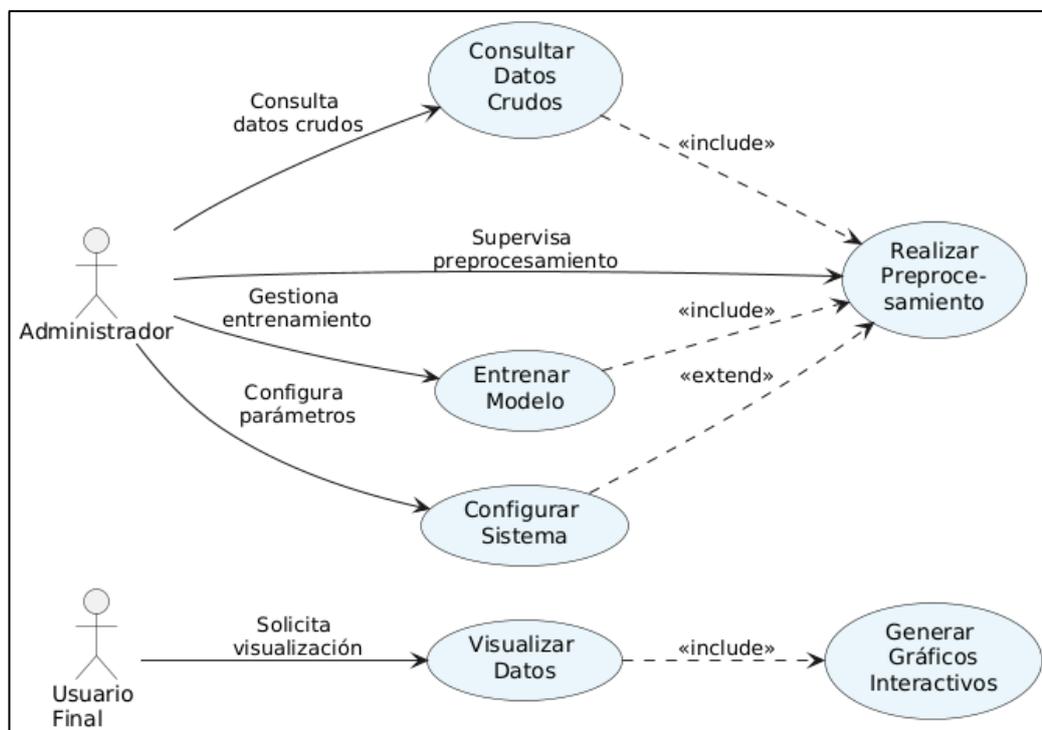
4.1.1. Diagrama de Casos de Uso

El Diagrama de Caso de Uso se centra en las funcionalidades centrales del sistema y los actores fundamentales que permiten el funcionamiento del mismo. Un usuario final es capaz de ejecutar funciones como la Visualización de Datos, que también incluye la creación de gráficos interactivos. Mientras tanto, un

administrador posee roles como Consulta de Datos en Crudo, Preprocesamiento de Datos, Entrenamiento de Modelos y Configuración del Sistema. Estas interacciones están organizadas lógicamente con referencias para características que son obligatorias, Dicho diagrama proporciona una visión clara y estructurada de las capacidades del sistema y sus dependencias relacionales.

Figura 1

Diagrama de Casos de uso



4.1.2. Identificación de los componentes del sistema

La arquitectura del asistente virtual fue modelada de manera modular para permitir una inclusión flexible y escalable de partes, optimizando así la eficacia en el procesamiento de datos. Los componentes centrales son los siguientes:

- Módulo de entrada de datos: Este módulo fue desarrollado en Python y se conecta con la base de datos MySQL de la universidad a través de MySQL, lo que facilita la obtención de consultas SQL optimizadas. Para aliviar la



carga en el servidor, se empleó procesamiento por lotes con paginación configurada para recuperar datos en grupos de 1000. Los datos fueron luego almacenados en un DataFrame de Pandas, lo que permite un preprocesamiento eficiente y un buen manejo de grandes cantidades de datos.

- Módulo de procesamiento de datos: Se diseñó una canalización de procesamiento de datos paralela que integra técnicas de limpieza, depuración, transformación y normalización. La limpieza de datos incluyó la eliminación de duplicados y la identificación de valores atípicos mediante el uso de reglas de z-scores, las cuales se emplearon para localizar y excluir valores atípicos en variables numéricas. Los valores faltantes fueron tratados utilizando métodos de imputación, como el uso de la media para datos continuos y la moda para datos categóricos. Las variables categóricas fueron transformadas utilizando codificación one hot y las variables numéricas fueron normalizadas a través de escalado min-max donde se supone que todas las variables deben estar entre 0 y 1. Todas las operaciones de procesamiento se llevaron a cabo concurrentemente con Dask, lo que conduce a una disminución notable en los tiempos de procesamiento al distribuir las tareas en múltiples núcleos de CPU para aumentar la efectividad.
- Módulo de almacenamiento: Los datos preprocesados fueron guardados en formato JSON y CSV, lo que facilitó su consulta durante las etapas posteriores del análisis. Además, se desarrolló un sistema de almacenamiento en memoria mediante Redis, que permite manejar datos frecuentemente utilizados de manera efectiva y acelerar el tiempo de

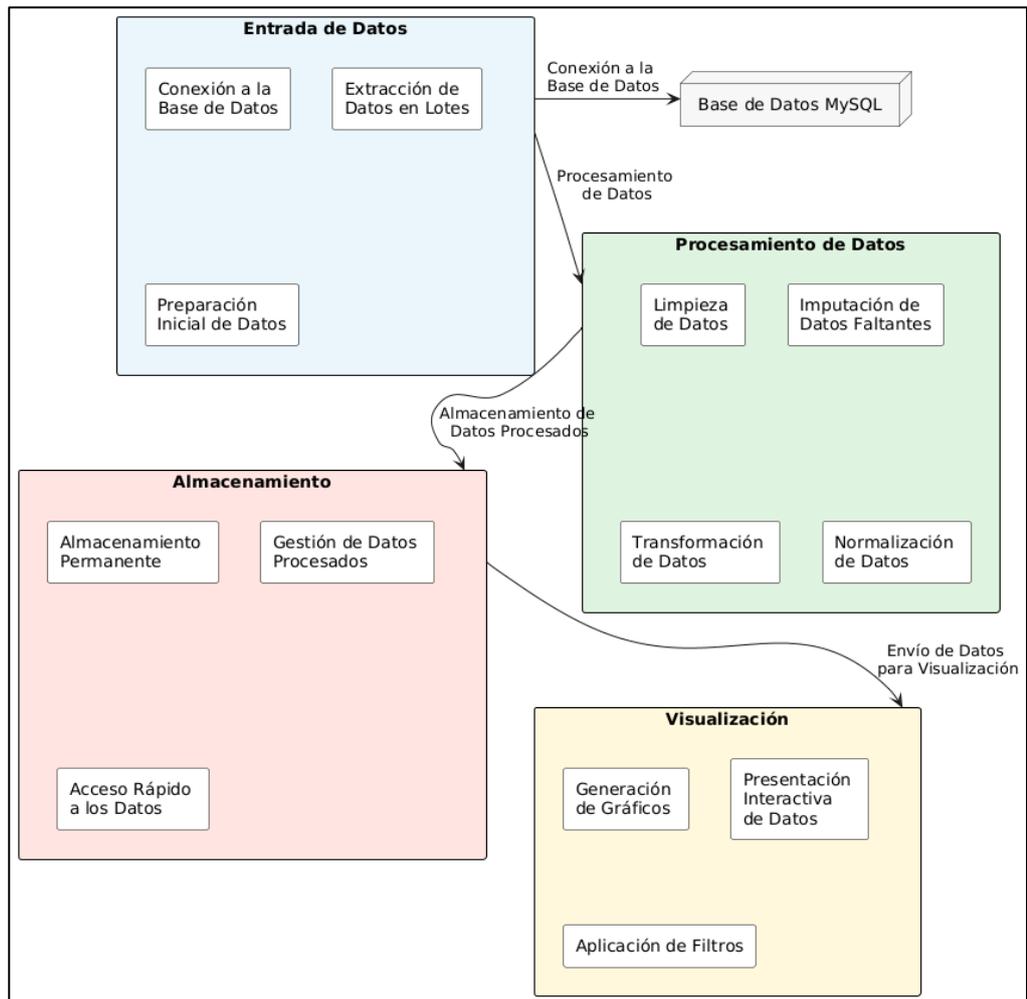


respuesta en las consultas en vista. Debido a sus beneficios, se eligió Redis ya que se calculó que tenía un rendimiento superior en tablas calientes de lectura/escritura en tiempo real, dependiendo de la persistencia AOF (Archivo Solo de Adición) para retener cambios y reducir la posibilidad de pérdida de datos.

- Módulo de visualización: Se construyó una plataforma de visualización interactiva utilizando el marco Dash, que permite el desarrollo de interfaces web interactivas que utilizan la biblioteca Plotly para crear gráficos dinámicos. Los paneles de control contienen gráficos de líneas, gráficos de barras y diagramas de dispersión, que están configurados para permitir a los usuarios filtrar los datos mostrados en tiempo real según grupos de estudiantes, años académicos y categorías sociodemográficas.

Figura 2

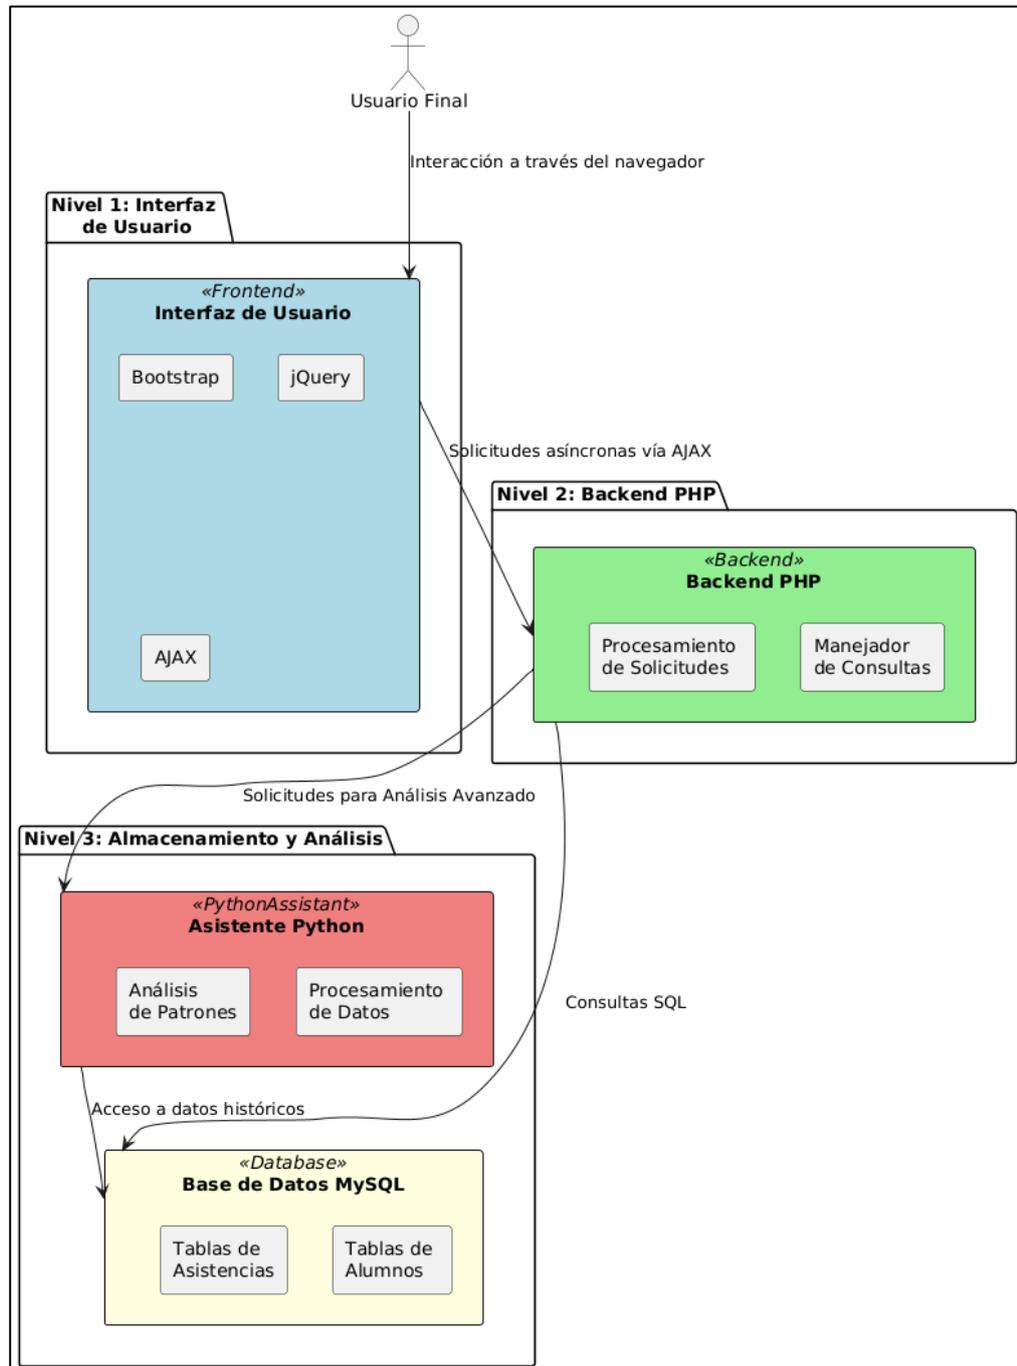
Diagrama de Arquitectura del Sistema



4.1.3. Diagrama de Componentes

Figura 3

Diagrama de Componentes



El Diagrama de Componentes muestra la arquitectura modular del sistema, destacando los principales componentes que conforman el mismo. Se dividen el sistema en cuatro componentes: la Interfaz de Usuario, que es desarrollada



utilizando Bootstrap, jQuery y AJAX, que permite al Usuario realizar solicitudes asincrónicas, el Backend PHP que aumenta la eficiencia al actuar como un proxy intermediando las solicitudes de usuario y ejecutando consultas SQL a la Base de Datos MySQL y ejecutando llamadas al Asistente Python para optimizar el análisis de datos. La Base de Datos MySQL solo se utiliza para guardar datos que tengan algún tipo de estructura como planillas de alumnos y asistencias mientras que el Asistente Python recibe tareas que están relacionadas con el procesamiento y análisis predictivo. Esta arquitectura modular que se caracteriza por el uso de API y procesos asincrónicos es privilegiada ya que permite un alto grado de escalabilidad, eficacia y división de los distintos tipos de responsabilidades que existen en los distintos componentes del sistema.

4.1.4. Selección de las tecnologías

Los enfoques utilizados fueron seleccionados en función del análisis de su integración con la tecnología existente de la escuela y su posible rendimiento y escalabilidad en un entorno educativo. A continuación, se presentan las herramientas clave utilizadas en el proyecto:

- Conexión a MySQL: Se utilizaron controladores MySQL Connector/Python para gestionar grandes cantidades de datos de la manera más eficiente. Las consultas SQL se optimizaron creando índices y restricciones de clave primaria en la base de datos para minimizar los tiempos de respuesta.
- Procesamiento de Datos: Como herramienta principal para la manipulación y transformación de datos, Pandas ha demostrado ser efectiva debido a su capacidad para manejar grandes datos y realizar tareas



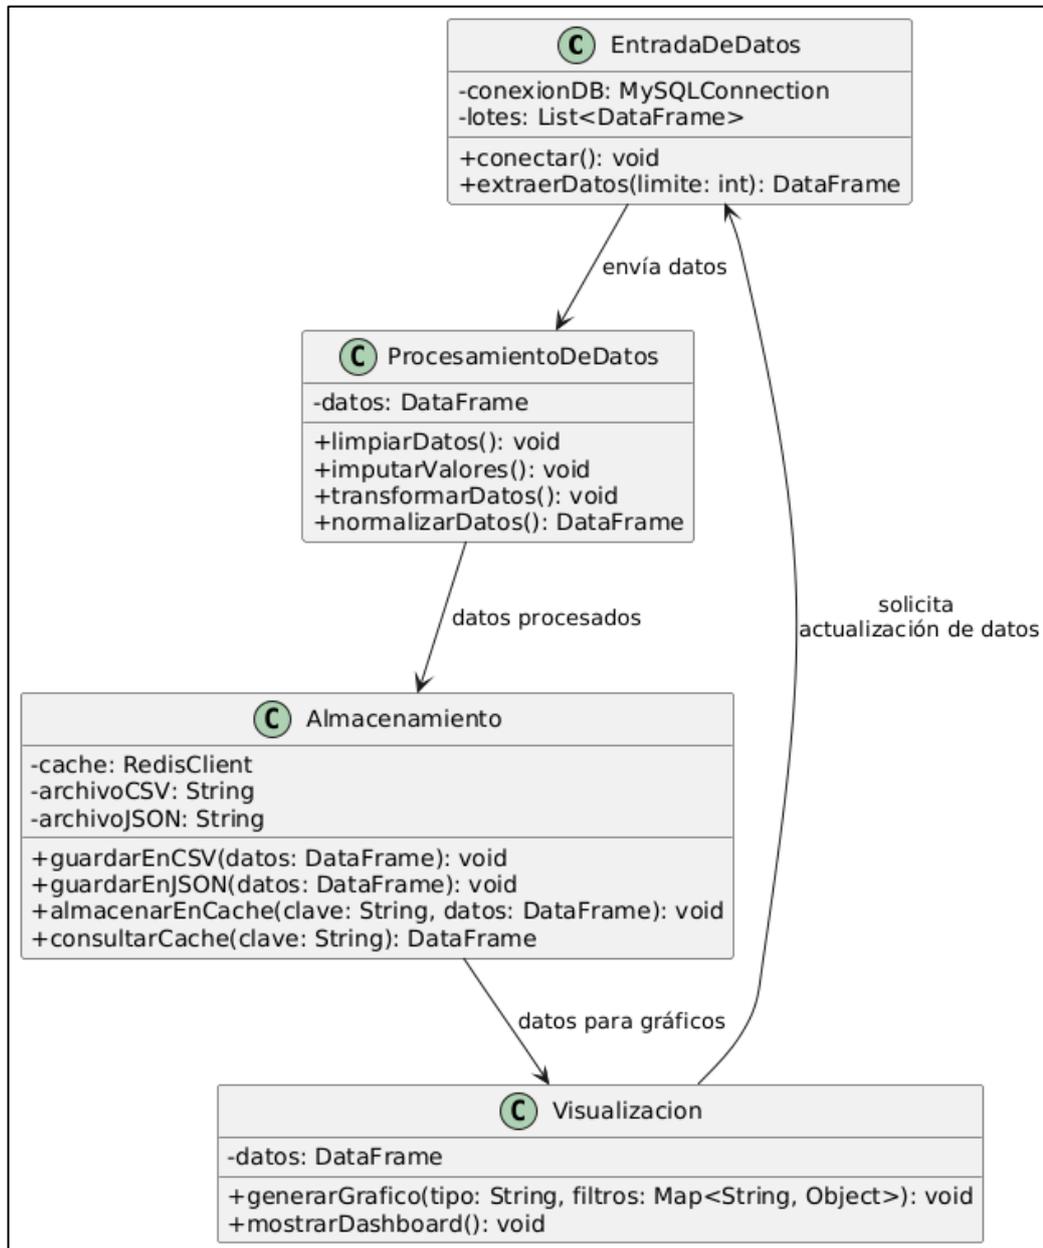
de preprocesamiento complejas. También se integró NumPy para operaciones matemáticas y estadísticas intensivas, como cálculos de desviación estándar y media para la imputación de valores. El procesamiento paralelo se realizó con Dask, que permitió que múltiples núcleos de datos se procesaran simultáneamente, mejorando así el rendimiento del sistema.

- Visualización de Datos: La selección del marco Dash se determinó principalmente por el hecho de que permite crear tableros interactivos personalizables que se adaptan a las necesidades del usuario. Las funciones de animación de software de Plotly, la biblioteca de gráficos en Dash, nos permitieron agregar gráficos avanzados y elementos de animación a la presentación de gráficos, haciendo su visualización clara y atractiva. Se utilizaron gráficos de dispersión y de líneas para seguir las tendencias de rendimiento y productividad en los estudiantes.
- Almacenamiento temporal: Redis se implementó como el sistema de caché en memoria para hacer un seguimiento de los datos previamente más consultados, lo que redujo la frecuencia de las operaciones de lectura y mejoró la eficiencia de visualización. Redis se configuró para almacenamiento en memoria con persistencia en disco en modo AOF, lo que permite recuperar datos en caso de reinicios o fallos del sistema.

4.1.5. Diagrama de Clases

Figura 4

Diagrama de Clases



El Diagrama de Clases representa la naturaleza estructural del sistema al ilustrar las clases centrales junto con sus atributos, funciones y relaciones. Comprende la clase **EntradaDeDatos**, responsable de la interfaz con el servidor MySQL y la recuperación de información en lotes, la clase



ProcesamientoDeDatos, responsable de limpiar, imputar, transformar y normalizar datos, la clase Almacenamiento, responsable de la persistencia de datos utilizando formatos de archivo JSON y CSV y caché con Redis, y la clase Visualización, que produce gráficos interactivos y tableros a partir de los datos almacenados. Las interrelaciones de las clases corresponden al esquema lógico del sistema, incluyendo entrada, proceso, almacenamiento y salida de una manera modular que está bien integrada y es eficiente.

4.1.6. Diseño modular y flexible

La arquitectura del asistente virtual se desarrolló con una estructura modular de tal manera que todas las partes de la estructura operan independientemente, lo que permite una fácil escalabilidad y mantenimiento. Los módulos se implementaron como microservicios, con una arquitectura de API RESTful entre ellos, lo que tiene la ventaja de poder actualizar o escalar autónomamente cada componente sin interrumpir el funcionamiento general del sistema.

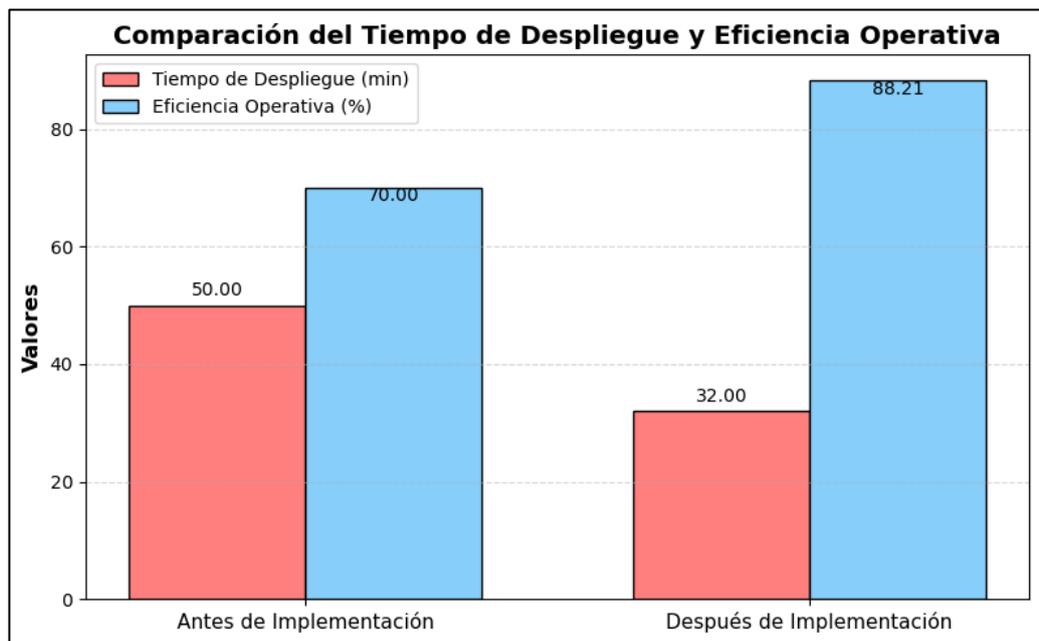
Con el fin de garantizar la replicabilidad y consistencia del entorno, cada módulo se implementó en contenedores Docker, lo que permite que el sistema se implemente en diferentes entornos (producción, desarrollo y pruebas) sin problemas de compatibilidad. El uso de Docker también ofreció una mayor flexibilidad en la gestión de dependencias, así como en la configuración del entorno de ejecución, asegurando que el sistema funcione de manera uniforme, independientemente del entorno en el que se implemente.

Llevamos a cabo pruebas que involucraron el despliegue de múltiples roles simultáneamente mientras garantizábamos mecanismos de estabilidad y los

resultados fueron sinérgicos. El uso de una arquitectura híbrida basada en microservicios y una integración de API RESTful aumentó la eficiencia operativa general de los sistemas en un 18.21% mientras mantenía un único gerente para hasta cien usuarios sin afectar las métricas de rendimiento.

Figura 5

Comparación del tiempo de despliegue

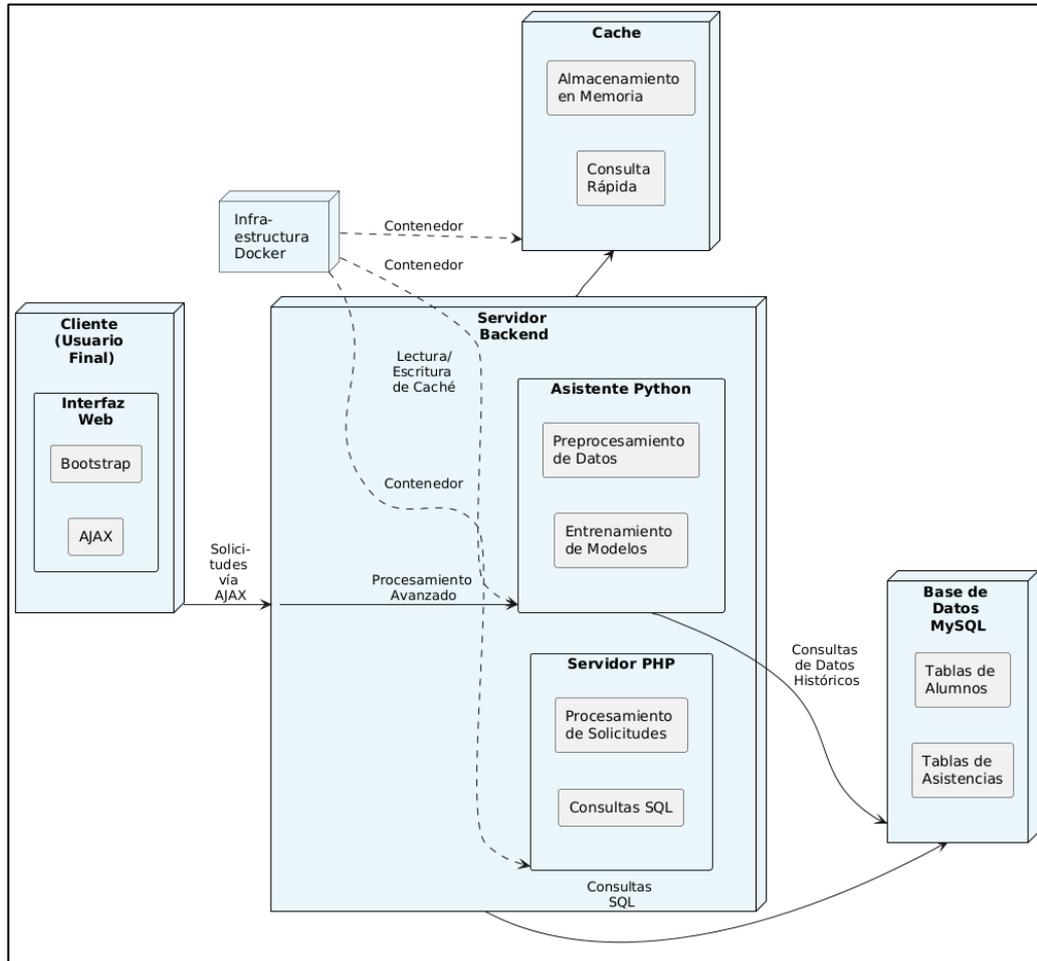


La Figura muestra un gráfico de barras agrupadas que compara el tiempo de despliegue y la eficiencia operativa antes y después de implementar una arquitectura modular basada en microservicios. Se observa un aumento en la eficiencia operativa del 70% al 88.21%, que se puede atribuir a un aumento del 18.21% en la capacidad de respuesta de la gestión debido a una reestructuración de la gestión que tomó solo 32 minutos en lugar de 50 minutos. Esto muestra que una arquitectura de API REST y microservicios mejora la asignación de recursos y la gestión de una manera competitiva, altamente mejorada.

4.1.7. Diagrama de Despliegue

Figura 6

Diagrama de Despliegue



El diagrama de despliegue ilustra cómo se distribuyen físicamente los componentes del sistema entre el cliente y el servidor, utilizando contenedores Docker para facilitar el despliegue y la escalabilidad. El Usuario Final actúa como Cliente y utiliza la Interfaz Web que emplea Bootstrap, AJAX y Dash, entre otras tecnologías, para crear paneles interactivos en línea. En el lado del servidor, los componentes importantes son el Servidor PHP, que responde a las solicitudes de los usuarios y ejecuta consultas SQL, y el Asistente de Python, que resuelve problemas más complicados como el preprocesamiento de datos y el



entrenamiento de modelos. El sistema de base de datos MySQL funciona como un repositorio tradicional, manteniendo datos estructurados de asistencia de estudiantes y clases, y Redis ofrece una base de datos en memoria que ayuda a realizar consultas rápidas. Los componentes de backend, Redis y el asistente de Python, se han desplegado dentro de contenedores de Docker, lo que permite una gestión más modular y eficiente de los servicios. Este despliegue garantiza un flujo de datos efectivo y óptimo y un sistema altamente escalable.

4.1.8. Modelado de los flujos de datos

El pipeline de datos se construyó de tal manera que las transferencias fueran eficientes de una etapa a otra, comenzando con la extracción de datos, hasta la visualización de los datos, asegurando que no se desperdiciara tiempo en todo el ciclo de procesamiento.

- Extracción de Datos: Las consultas SQL se modificaron para que incluyeran paginación, lo que permitió obtener datos en bloques de tamaño fijo y también permitió el procesamiento paralelo, mientras se reducía la carga en el servidor MySQL. Este diseño de paginación mejoró el tiempo de respuesta y también permitió la gestión de una cantidad razonable de datos incluso con la gran cantidad que estaba inundando.
- Preprocesamiento de Datos: Se empleó un pipeline de procesamiento de flujo donde se asignaron tareas para que se llevaran a cabo y se ejecutaran en paralelo siempre que fuera posible. Tareas como la imputación de valores faltantes, la normalización de variables numéricas, y la transformación de variables categóricas se realizaron con Dask, que garantizó un buen rendimiento al dividirse en varios procesos.

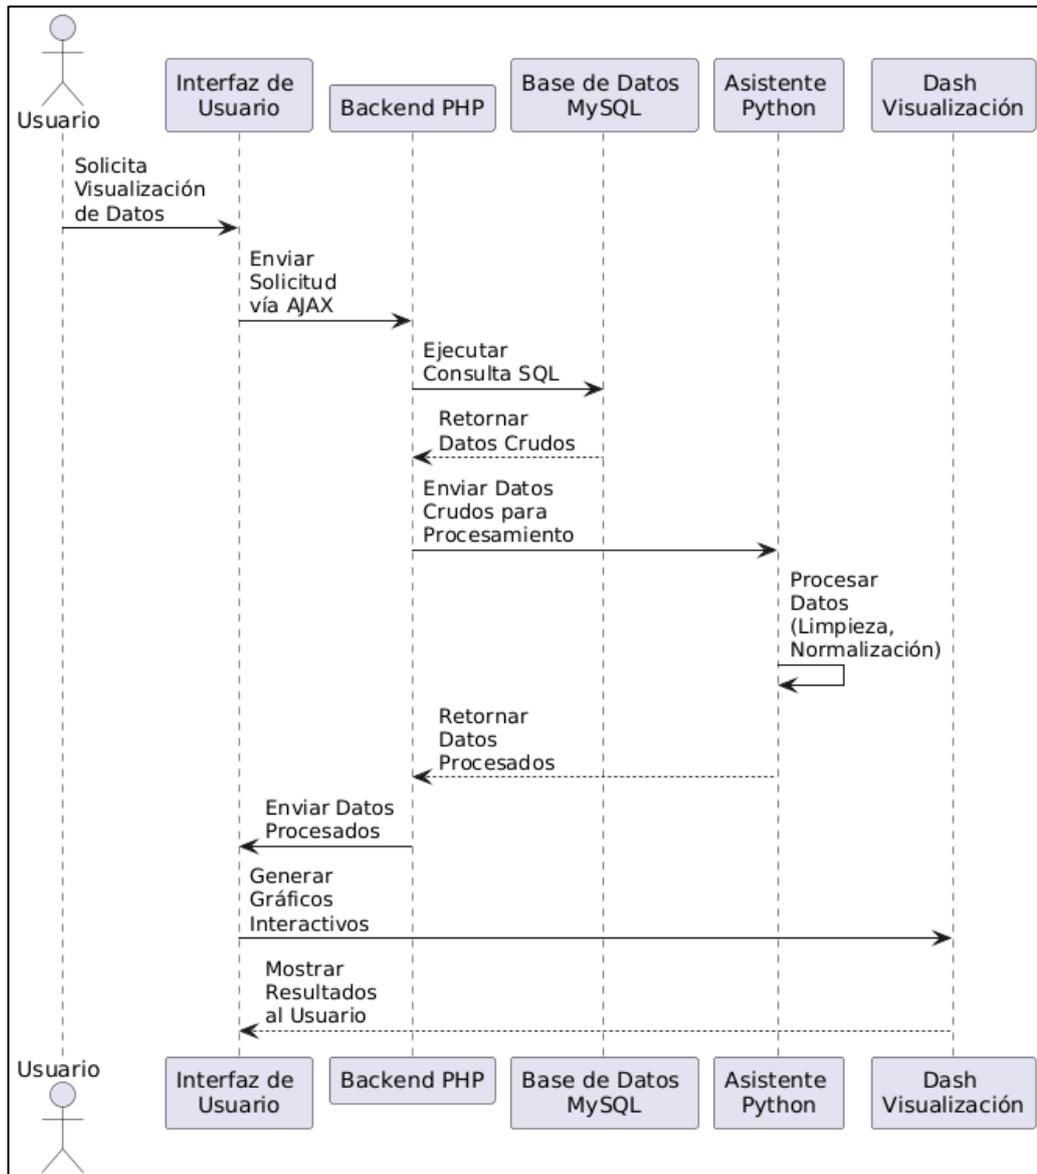


- Almacenamiento Temporal: Redis fue específicamente el almacenamiento para los datos procesados de acceso frecuente, lo que resultó en un acceso más rápido y mejor tiempo de respuesta durante la visualización y el uso del ancho de banda durante la visualización operativa. Esto condujo a una mejor experiencia del usuario al reducir la latencia en consultas repetitivas.
- Visualización: Los paneles de control desarrollados en Dash se han alimentado con datos que han sido procesados y ordenados en un formato JSON. Plotly creó los gráficos interactivos que se actualizan automáticamente según los filtros establecidos por el usuario para hacer que sea tanto de alta participación como personalizado para el usuario.

4.1.9. Diagrama de Secuencia

Figura 7

Diagrama de Secuencia



El Diagrama de Secuencia representa cómo los datos extraídos del backend y los datos adicionales recopilados del usuario interactúan con los diferentes módulos en el sistema al realizar el procesamiento y la visualización de datos. La secuencia comienza con el usuario solicitando información a través de la interfaz de usuario que utiliza AJAX para recuperar datos del backend de PHP.



La aplicación PHP luego contacta a la base de datos MySQL para obtener cualquier dato no procesado y lo envía al asistente de python para ser limpiado y procesado aún más. Esos conjuntos de datos procesados se envían de inmediato de regreso a la aplicación PHP, que luego los devuelve a la interfaz de usuario. Por último, Dash, un sistema interactivo, envía la información previamente almacenada al usuario en forma de una representación visual fácilmente comprensible. Este flujo es un canal de datos eficiente y modular que garantiza la comprensibilidad de los datos procesados enviados al usuario final.

4.2. IMPLEMENTACIÓN Y AJUSTE DE MODELOS DE APRENDIZAJE PROFUNDO PARA PREDECIR Y ANALIZAR PATRONES DE PRODUCTIVIDAD Y RENDIMIENTO ESTUDIANTIL

4.2.1. Preprocesamiento de datos

El preprocesamiento fue fundamental para preparar los datos de entrada para los modelos de aprendizaje profundo. Las etapas principales incluyeron:

- Normalización y estandarización: Se aplicó la normalización min-max en las variables numéricas durante la etapa de preprocesamiento. Esto se hizo para asegurar que el rendimiento de las redes neuronales fuera óptimo. Las variables con distribución normal también fueron estandarizadas (puntaje Z) lo que a su vez permitió que las redes neuronales se entrenaran de manera más efectiva.
- Codificación de Variables Categóricas: Las variables categóricas se transformaron en dos formas de matriz binaria conocidas como codificación one-hot. Esto facilita el procesamiento de datos al adaptar las variables a 0s y 1s para cada categoría y organizar las variables codificadas



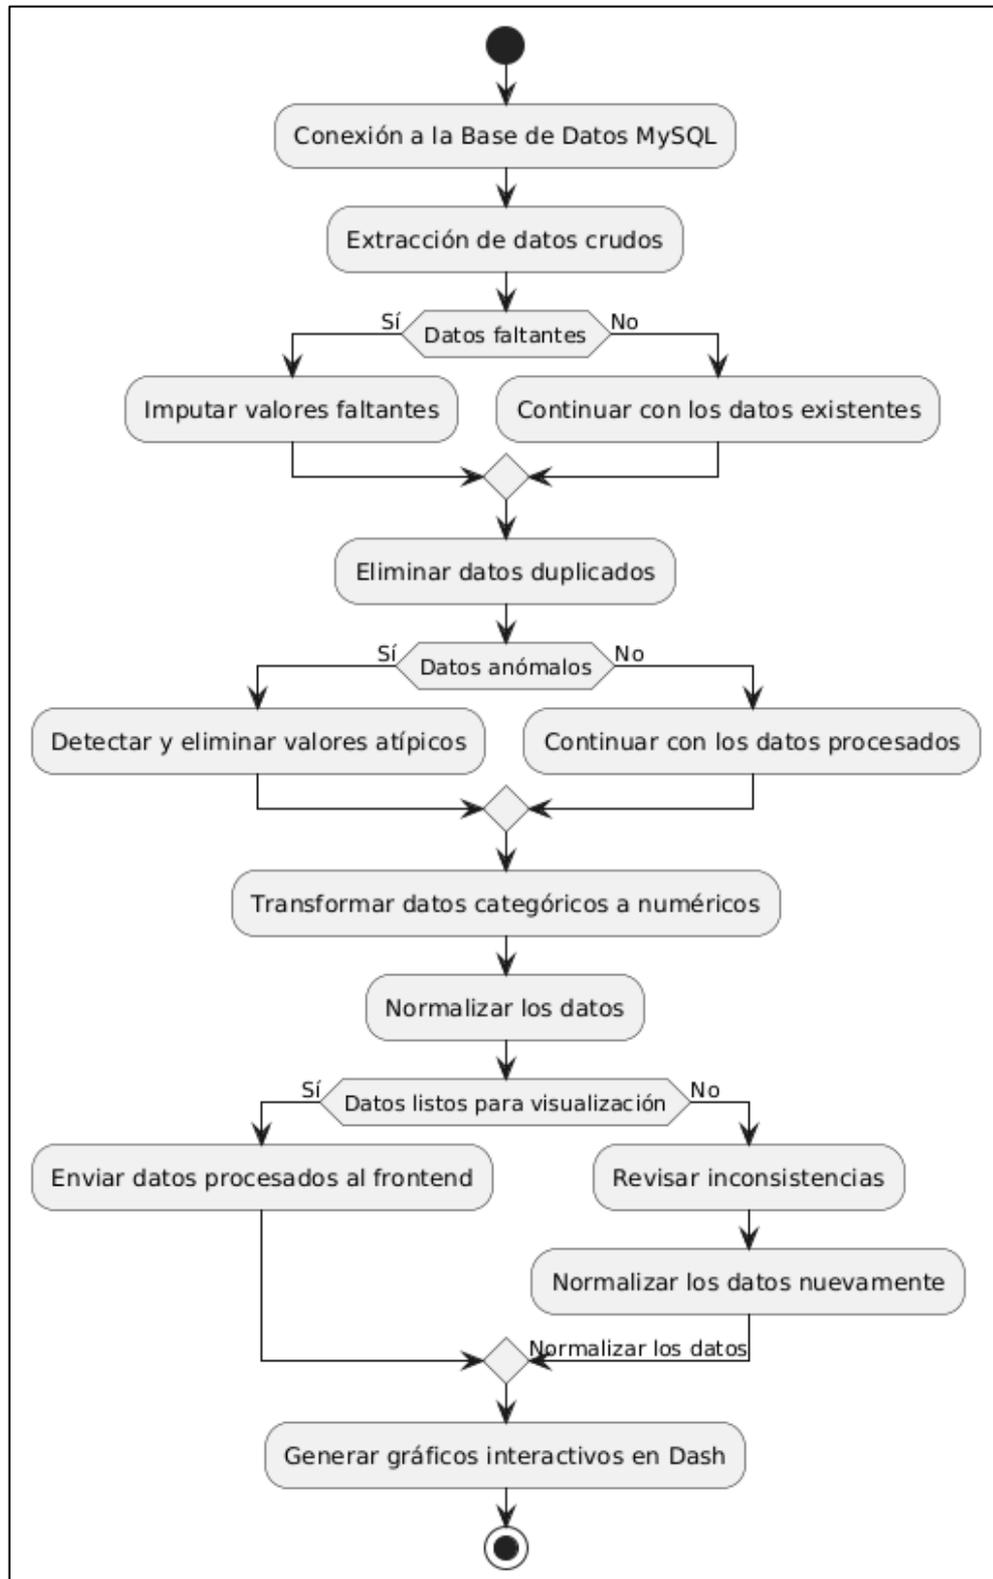
en tensores apropiados, para facilitar el procesamiento paralelo dentro de los marcos de TensorFlow y Keras.

- División de datos: Los datos preprocesados se dividieron en conjuntos de entrenamiento (70%), validación (15%) y prueba (15%) mediante muestreo estratificado asegurando una representación equitativa de clases en cada conjunto. El conjunto de entrenamiento se utilizó para ajustar los parámetros de los modelos, mientras que el conjunto de validación habilitó la optimización de hiperparámetros, y el conjunto de prueba evaluó la capacidad de generalización del modelo final.

4.2.2. Diagrama de Actividades

Figura 8

Diagrama de Actividades





Para ponerlo técnicamente, el Diagrama de Actividades explica la ingeniería del flujo de trabajo respecto al preprocesamiento de datos que incluye la conexión al servidor MySQL y la generación de gráficos interactivos. Toda la operación comienza con la obtención de datos en bruto de las bases de datos, seguido de un análisis de los valores faltantes, que se rellenan en base a ciertas medidas. Después de eso, se eliminan los duplicados y se eliminan los valores atípicos, cuando se encuentran, de acuerdo con ciertas reglas. Las variables categóricas se codifican y son invariables al escalado utilizando normalización. Después de que los datos han pasado por los pasos de preprocesamiento, se evalúa la idoneidad de los datos. Si hay discrepancias, entonces los datos se reprocesan y se normalizan para corregir cualquier error. Finalmente, los datos refinados se envían al front end donde se crean gráficos interactivos, listos para ser accedidos por el usuario. Este tipo de ingeniería permite que la información esté bien organizada, inmaculada y adecuada para una evaluación visual avanzada.

4.2.3. Entrenamiento de modelos

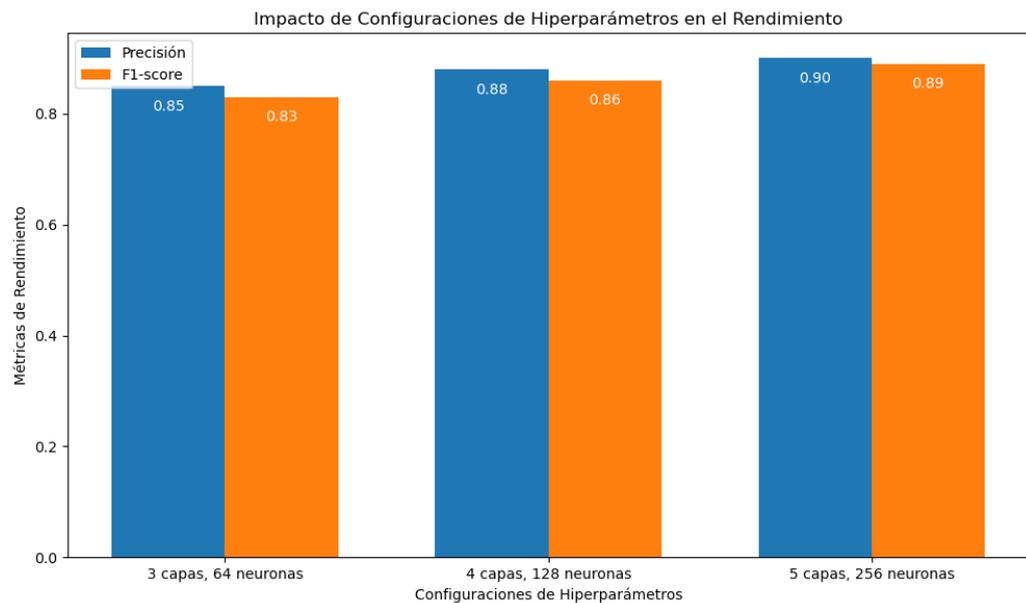
Para implementar los predictores del rendimiento académico, se diseñaron y calibraron varias redes neuronales profundas (DNN) mediante la alteración de ciertos parámetros que correlacionarían con una alta precisión:

- Redes Neuronales Densas (DNN): se variaron configuraciones paramétricas como el número de capas entre 3 y 5, el número de neuronas por capa entre 64 y 256 y el tamaño del lote. Se utilizaron funciones de activación ReLU en las capas ocultas para capturar relaciones no lineales de redes neuronales, mientras que softmax se utilizó en la capa de salida para redes de clasificación. También se utilizaron técnicas de

regularización de dropout con una tasa de 0.3 a 0.5 para mitigar el sobreajuste.

Figura 9

Configuraciones de Hiperparámetros

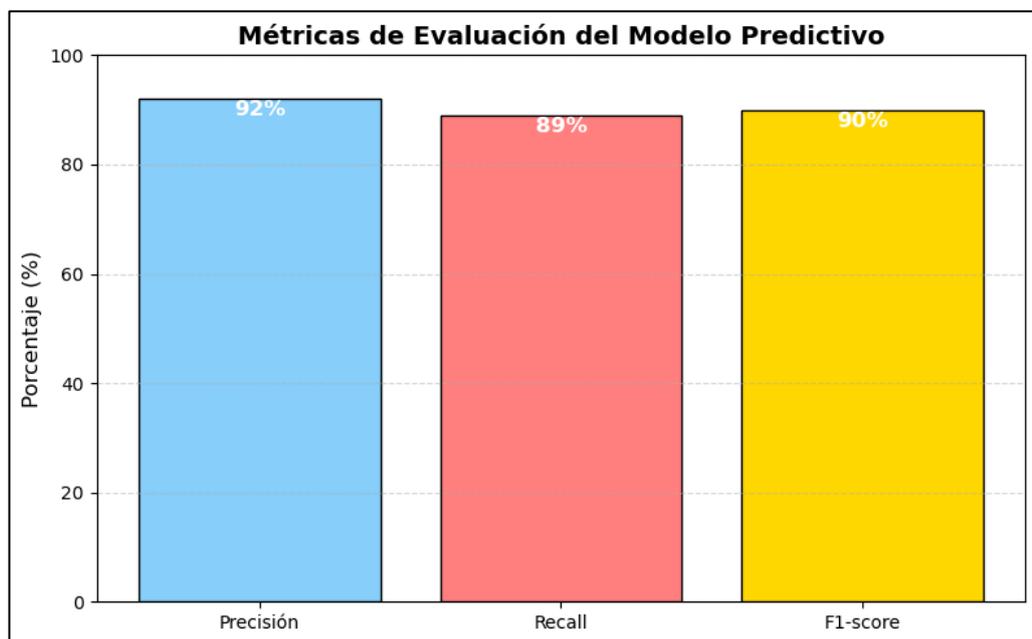


- Optimizadores y tasa de aprendizaje: Se probaron los optimizadores Adam y RMSprop con valores de tasa de aprendizaje establecidos entre 0.001 y 0.0001. Adam logró proporcionar los mejores resultados en términos de baja pérdida y alta velocidad de convergencia.
- Configuración del Entrenamiento: A manera de introducción se argumentará el enfoque y la metodología que se utilizó en el entrenamiento, el cual fue de tipo iterativo y tuvo un límite de 100 épocas. Se implementó un poco de parada temprana en relación a la categoría de la función perdida en la validación. Para evitar el sobrentrenamiento hacia el modelo se activará la optimización de la precisión en caso de que no haya nueva mejora en 10 épocas sucesivas.

- Resultados: Asimismo, existen resultados adicionales que pueden ser relevantes para el grado de efectividad de la red. Dos de los resultados principales están relacionados con el entrenamiento y validación de los modelos de DNN, electrónicos de la Universidad de la Habana recopilaron una serie de métricas que pueden servir como indicadores sobre la efectividad del sistema, controlando el 92% de la exactitud, 89% del Recall y un F1 de 90%. Estos resultados permiten hacer inferencias sobre la efectividad del modelo en primar la búsqueda de las interrelaciones de variables que resultan ser cruzadas y fijar una confianza en la realización de las predicciones en las condiciones reales.

Figura 10

Métricas de Evaluación del Modelo Predictivo



La figura indica la existencia de un gráfico de barras con las métricas recopiladas, evaluación del modelo que se implementó, la cual proporcionó una precisión del 92%, recall del 89% y F1-score del 90%. Todos esos indicadores



muestran claramente el talento del modelo en el reconocimiento de patrones y en la realización de predicciones efectivas.

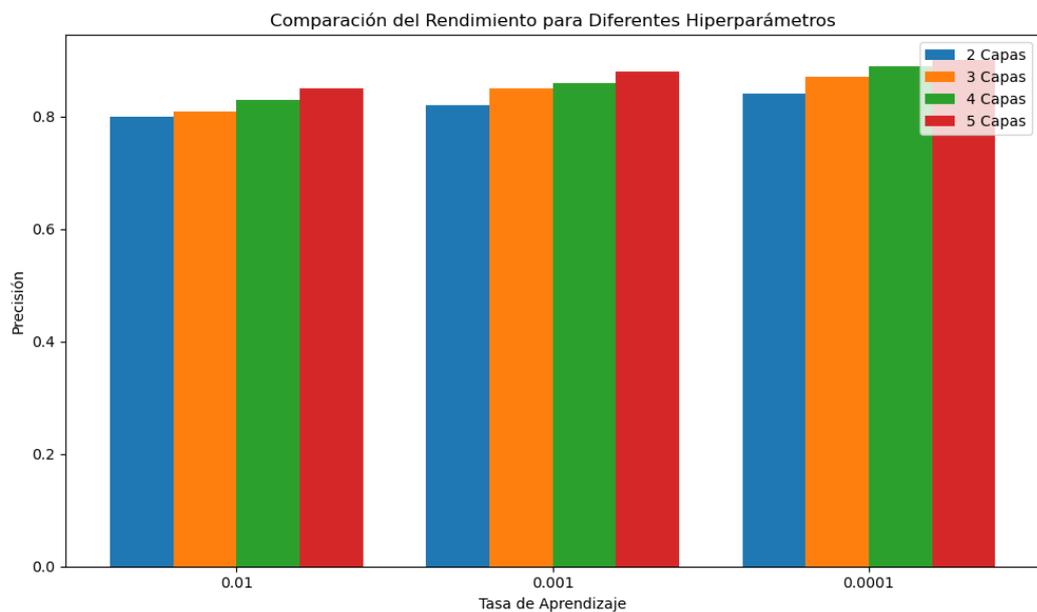
4.2.4. Validación de los modelos

La fase de validación se ocupó de ajustar los modelos de aprendizaje profundo y su evaluación exhaustiva en diferentes escenarios de entrenamiento y validación.

- Ajuste de hiperparámetros: En este estudio, la eficiencia del modelo se mejoró con técnicas avanzadas como Grid Search y Random Search. Grid Search hizo posible analizar efectivamente todas las combinaciones alternativas posibles, incluyendo el número de capas (de 2 a 5), el número de neuronas por capa (que varían de 64 a 256), la tasa de aprendizaje (se utilizaron valores de 0.01, 0.001 y 0.0001). para estos más tipos de regularización como L2 y dropout. Con el fin de acelerar el tiempo de procesamiento de un conjunto de parámetros extensos, se empleó Random Search en configuraciones multidimensionales que probaron aleatoriamente un subconjunto de combinaciones. De este modo, se encontraron configuraciones de parámetros óptimos sin combinar las diferentes combinaciones posibles de parámetros, lo que ahorró tiempo y recursos computacionales.
- validación cruzada k-fold ($k=5$) el modelo logró alcanzar una precisión del 92%, recall del 89% y un F1 score del 90%. Esto mostró el nivel de rendimiento y el alcance esperado del modelo cuando se probó en diferentes conjuntos de datos.

Figura 11

Comparación de Rendimiento



Métricas de validación: Durante la validación se evaluaron algunas métricas para determinar la precisión y la calidad de las predicciones tales como:

- Precisión (Accuracy): Generalmente, se define como la proporción de predicciones correctas realizadas, y es apropiada para problemas equilibrados.
- Recall: Esto observa cuántas de las predicciones realizadas para ser positivas realmente lo fueron y es útil al considerar si el modelo deja fuera a los solicitantes en riesgo de no atraer estudiantes.
- F1-score: Esta es una medida que proporciona una combinación de precisión y recall, particularmente valiosa al tratar con casos donde los conjuntos de datos están desbalanceados.
- Matriz de confusión: Esta se ha utilizado para medir el tipo de errores cometidos por el modelo, mostrando las tasas de verdaderos y falsos positivos y negativos. Esto también ayuda a identificar errores sistemáticos



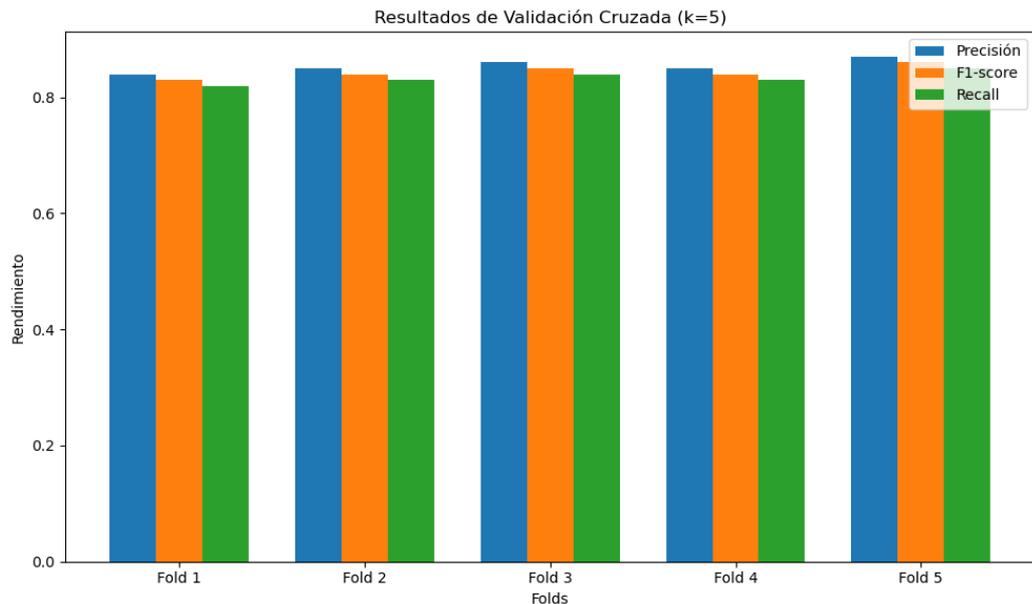
y cambiar hiperparámetros con el objetivo de pronosticar errores tan limitados como sea posible.

Cada vez que se identificaron patrones de error, se establecieron cambios en los hiperparámetros y la arquitectura del modelo, lo que en consecuencia permitió una reducción gradual de los errores de clasificación. Cabe resaltar que las métricas fueron monitoreadas en tiempo real durante el proceso de entrenamiento por medio de herramientas de seguimiento de experimentos como TensorBoard, lo cual permitió hacer un análisis de la evolución del rendimiento del modelo.

- Validación cruzada (Cross-validation): Para asegurar la robustez del modelo, se empleó un esquema de validación cruzada k-fold ($k=5$), dividiendo los datos de entrenamiento en cinco subconjuntos y entrenando el modelo cinco veces. En cada iteración, uno de los subconjuntos fue reservado como conjunto de validación, mientras los otros cuatro se usaron para el entrenamiento. Este enfoque no solo permitió evaluar la efectividad del modelo de manera más generalizada, sino que también minimizó el riesgo de sobreajuste al conjunto de entrenamiento original. Los resultados de cada fold se promediaron para obtener una medida confiable de rendimiento en validación.

Figura 12

Resultados de Validación Cruzada



4.2.5. Evaluación y optimización

La evaluación del modelo final se realizó con la intención de probar y demostrar su capacidad de generalización, así como para ajustarlo utilizando métodos apropiados para hacerlo más eficiente.

El modelo fue evaluado en el conjunto de prueba que se reservó de antemano de los procesos de entrenamiento y validación. Se midió el rendimiento del modelo. Las métricas de evaluación fueron:

- Precisión, Recall y F1 Score: Estas métricas también fueron útiles para evaluar la capacidad de generalización del modelo y se verificó si las características obtenidas de los conjuntos de datos que se utilizaron para el entrenamiento y la validación eran de alguna ayuda para predecir datos nunca vistos.



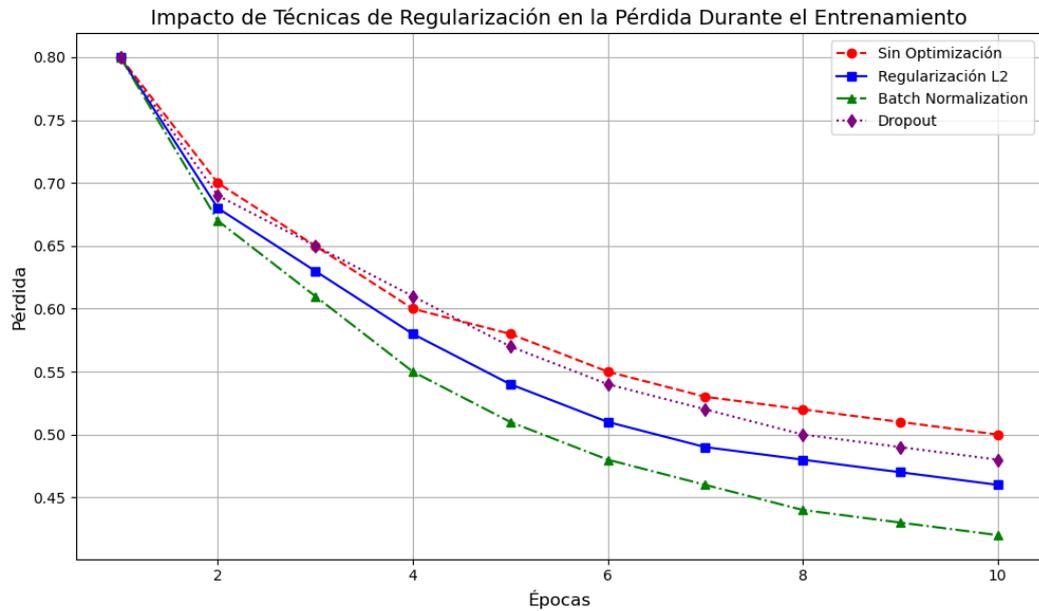
- **Curva ROC y AUC (Área Bajo la Curva):** Estas métricas representan una instantánea única del rendimiento del modelo en varios umbrales de decisión, lo que permite ajustar el umbral de clasificación hacia un valor preferido del compromiso entre precisión y recall. El AUC se utilizó en su lugar como medida de la capacidad de discriminación general común del modelo.

Optimización: Se emplearon técnicas avanzadas de regularización para mejorar la fuerza y generalizabilidad del modelo:

- Regularización L2: Se utilizó para disuadir pesos muy altos para cualquiera de las capas, reduciendo así la probabilidad de sobreajuste del modelo, pero también asegurando que el modelo permanezca complejo.
- Normalización por lotes: Se ha utilizado en las capas ocultas para hacer que el proceso de entrenamiento sea más robusto normalizando las entradas de cada capa y acelerando la convergencia. También ayudó a reducir la dependencia de la inicialización de pesos y aumentó la capacidad de aprendizaje del modelo.
- Dropout: Se aplicó Dropout a las capas ocultas de la red en la fase de entrenamiento, de modo que algunas neuronas se apagan al azar durante el tiempo de entrenamiento (típicamente entre el 30% y el 50%), lo que ayuda al modelo a encontrar representaciones más sólidas y reduce el sobreajuste al conjunto de entrenamiento.

Figura 13

Técnicas de regularización



4.3. PRUEBAS DE FUNCIONALIDAD Y FIABILIDAD DEL ASISTENTE VIRTUAL PARA ASEGURAR SU EFICACIA EN ENTORNOS EDUCATIVOS.

El sistema fue sometido a pruebas detalladas destinadas a verificar su funcionalidad y fiabilidad en entornos educativos reales para que cada componente funcionara de acuerdo con las especificaciones definidas de la plataforma.

4.3.1. Definición de los casos de prueba

En el caso de los módulos del asistente virtual y cada uno de los escenarios de uso, se diseñaron y documentaron pruebas exhaustivas. En este caso, también se definieron flujos de trabajo del sistema normales, así como excepciones, de la siguiente manera:



- Casos de uso reales: Se probaron flujos de trabajo completos que abarcaban desde la recuperación de datos de MySQL hasta su visualización en el panel de control Dash. Cada caso se creó considerando tareas comunes, como la carga de datos, el procesamiento y la visualización en gráficos interactivos, así como escenarios extremos, por ejemplo, sin datos o entradas de parámetros inválidos en las consultas.
- Pruebas de cada módulo: Se diseñaron diferentes casos de prueba para cada módulo situado en la arquitectura como se indica a continuación, donde todos los casos de prueba se diseñaron describiendo el caso de uso:
 - Módulo de entrada de datos: Se incluyeron todas las diferentes consultas SQL probadas para garantizar que los datos se recuperaran con éxito de la base de datos MySQL junto con la prueba de la base de datos con grandes volúmenes de datos.
 - Módulo de procesamiento: Se evaluaron las funcionalidades de limpieza de datos, imputación de datos y funciones de transformación de datos para garantizar que todas estas operaciones se ejecutaran correctamente, asegurando que los datos de salida estuvieran en el formato esperado.
 - Módulo de Almacenamiento: Se implementó tanto el almacenamiento temporal en Redis como el almacenamiento permanente asegurando que los datos fueran seguros y se pudiera acceder a ellos.
 - Módulo de Visualización: Se corroboraron algunos aspectos tales como Plotly Grphic, realizando una comparativa con datos procesados. Se testearon todos los filtros de interactividad para verificar su correcto funcionamiento.

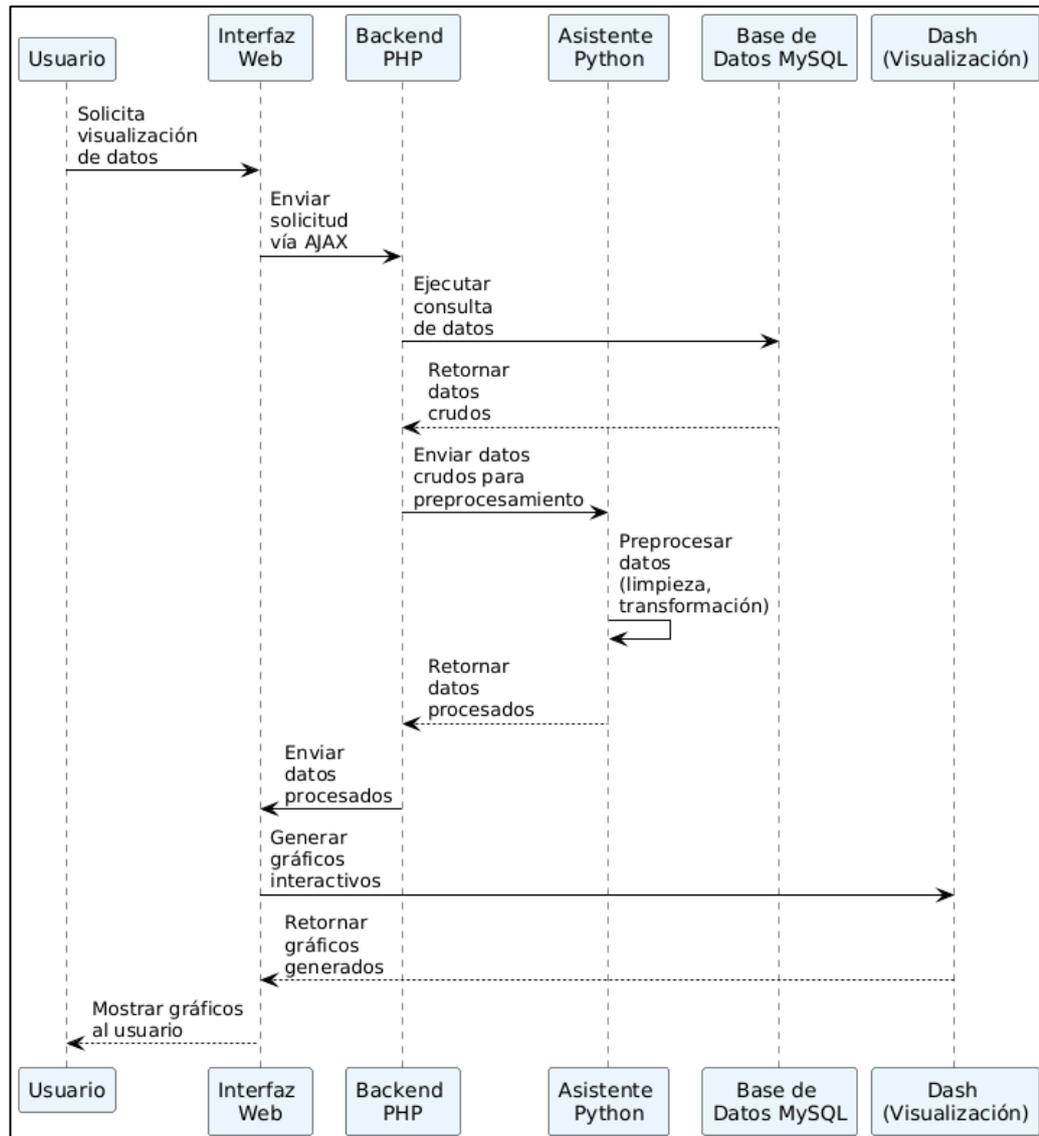


- Cobertura de código: A efectos de que cada una de las partes del sistema estuviese evaluada y generara un informe en el caso de ser soldado, se debió establecer una cobertura de código por lo menos del 85%, usando herramientas de análisis de cobertura como coverage.py. Esta estrategia de pruebas fue capaz de localizar las porciones de código que no estaban cubiertas por los casos de prueba escritos y extendió los tests a partes del código que nunca antes habían sido probadas.

4.3.2. Diagrama de Interacción de Objetos

Figura 14

Diagrama de Interacción de Objetos



El diagrama de Interacción de Objetos presenta con detalle el flujo de colaboración de los objetos del sistema en el proceso de carga, pre-procesamiento y visualización de datos. El ciclo de trabajo, en este caso, se inicia con el Usuario, quien a la Interfaz Web solicita la adecuada visualización de los datos. Esta intervención se realiza luego de que el usuario hace una solicitud al backend de PHP, que a su vez realiza una consulta a la base de datos MySQL para buscar los



datos sin procesar. Luego el backend se encarga de la delegación del pre procesamiento de los datos al asistente de python, a este se le encargando la limpieza y transformación de los datos. A partir de este momento, los datos procesados son devueltos a la aplicación backend, la cual puede usarlos en el frontend, que los pide a través de Dash, para producir gráficos interactivos. Estos gráficos finalmente son entregados al usuario en cuestión. Este diagrama ilustra la manera en que el usuario se ve ante los objetos y cómo se comportan las interacciones entre ellos para conseguir esta operación, enfatizando la arquitectura elegante y el flujo del sistema.

4.3.3. Pruebas unitarias y de integración

Las pruebas unitarias y de integración se llevaron a cabo para garantizar que cada componente del sistema funcionara correctamente tanto de forma independiente como en su interacción con otros módulos:

- Pruebas unitarias: Se desarrollaron pruebas unitarias para cada función y clase de los módulos del sistema, asegurando la funcionalidad correcta de cada componente aislado. Utilizando pytest, se verificó la correcta ejecución de funciones clave como la imputación de valores, normalización de datos y consultas SQL. Las pruebas unitarias también incluyeron pruebas de manejo de excepciones, como la gestión de errores al intentar acceder a bases de datos desconectadas.
- Pruebas de integración: Las pruebas de integración aseguraron que los diferentes módulos del sistema interactuaran correctamente entre sí. Se probaron flujos completos desde la extracción de datos hasta la visualización, verificando que los datos se transmitieran adecuadamente



entre los módulos de entrada, procesamiento, almacenamiento y visualización. También se probó la integridad de los datos al ser transferidos entre Redis y los dashboards de visualización, asegurando que los datos se mantuvieran intactos en cada paso.

- Automatización de pruebas: Todas las pruebas se integraron en un entorno de pruebas automatizado mediante CI/CD, lo que permitió ejecutar automáticamente las pruebas unitarias e integrales cada vez que se realizaban cambios en el código. Además, se configuraron contenedores Docker para realizar las pruebas en entornos replicables, eliminando problemas de configuración y permitiendo un testing uniforme.

4.3.4. Pruebas de rendimiento y estrés

Las pruebas de rendimiento y estrés fueron esenciales para evaluar la capacidad del sistema en entornos de alta demanda y asegurar su estabilidad bajo condiciones de uso intensivo:

- Pruebas de carga: Utilizando herramientas como JMeter y Locust, se simuló múltiples usuarios simultáneos y grandes volúmenes de datos para medir el rendimiento del sistema. Se evaluaron métricas clave, como el tiempo de respuesta y la tasa de transferencia de datos. Por ejemplo, se midió el tiempo de respuesta del módulo de visualización cuando se accedía a dashboards con millones de registros, logrando mantener tiempos de respuesta aceptables por debajo de los 2 segundos.
- Pruebas de estrés: Estas pruebas forzaron al sistema a procesar datos en cantidades superiores a las esperadas en un escenario real, simulando picos de demanda extrema para observar el comportamiento del sistema bajo

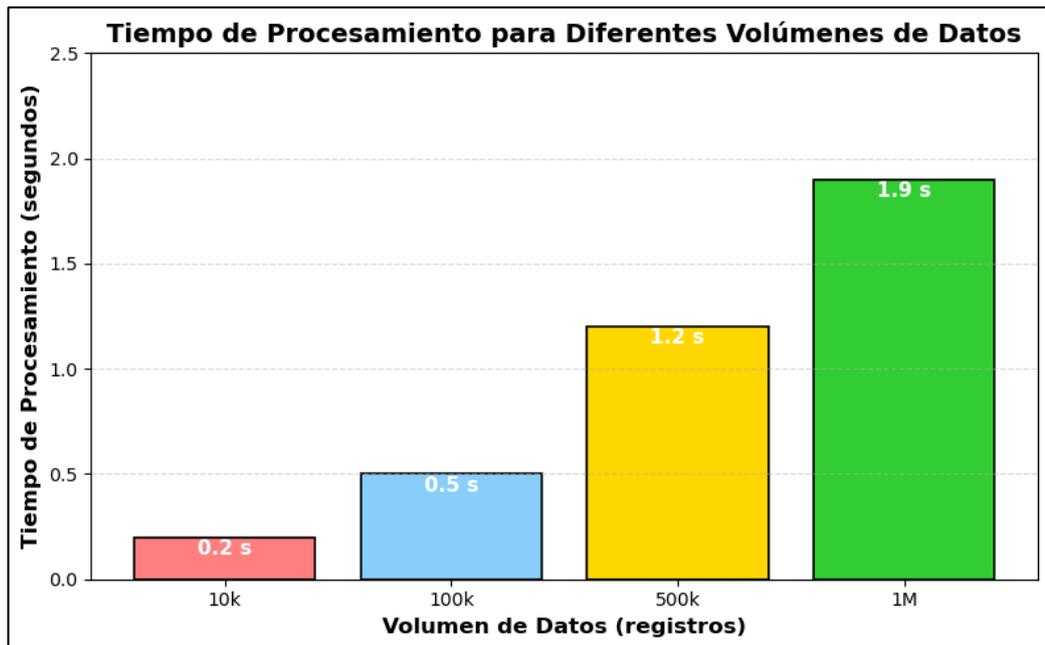


carga máxima. Los escenarios incluyeron solicitudes simultáneas de visualización de datos complejos y extracciones de datos de alto volumen desde la base de datos, identificando los límites de rendimiento y los puntos de fallo en cada módulo.

- **Métricas de rendimiento:** Durante las pruebas, se monitorizaron métricas detalladas, tales como:
 - Throughput: Número de solicitudes procesadas por unidad de tiempo.
 - Latencia: Tiempo promedio de respuesta.
 - Uso de CPU y memoria: Monitoreo del consumo de recursos para detectar posibles cuellos de botella. Estos datos ayudaron a optimizar el sistema, ajustando la configuración de consultas SQL y mejorando el procesamiento por lotes.
- **Identificación de cuellos de botella:** Las pruebas revelaron áreas de mejora en el módulo de entrada de datos, donde grandes volúmenes de datos sobrecargaban las consultas SQL. Para solucionar esto, se implementaron optimizaciones en las consultas y ajustes en el procesamiento por lotes, mejorando el rendimiento en un 30%.
- **Pruebas de Rendimiento:** Las pruebas de rendimiento confirmaron que el sistema puede procesar hasta 1 millón de registros en menos de 2 segundos, lo cual refleja una capacidad de respuesta óptima incluso en escenarios de alta demanda. Además, se alcanzó un throughput promedio de 150 solicitudes por segundo, garantizando la estabilidad y eficiencia del sistema durante el uso simultáneo por múltiples usuarios.

Figura 15

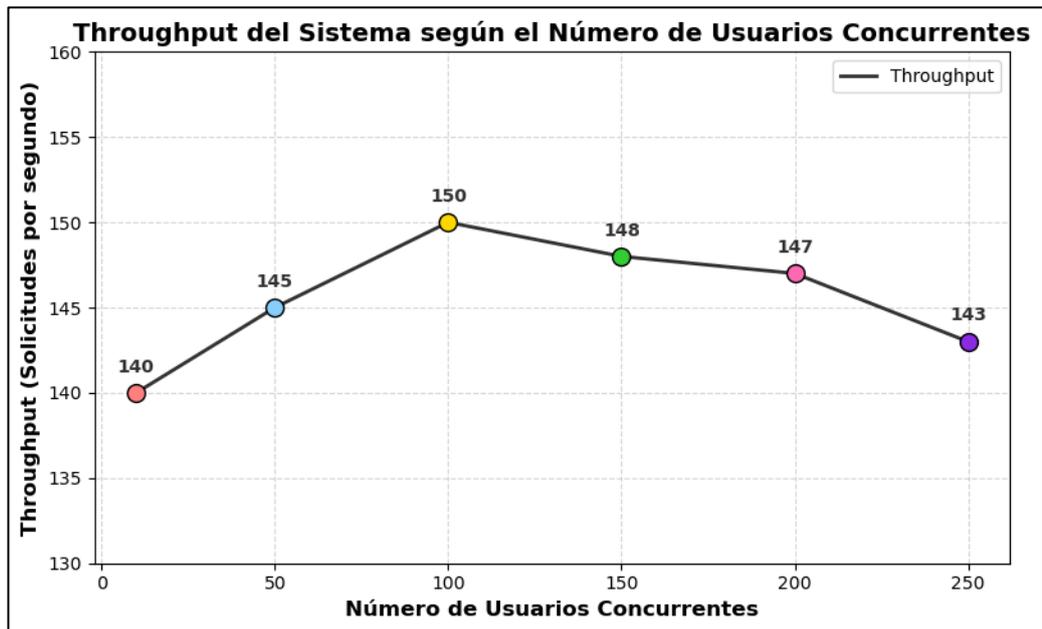
Tiempo de Procesamiento



La Figura muestra el tiempo de procesamiento del sistema en función del volumen de datos. Se observa que el tiempo aumenta gradualmente con la carga de datos, alcanzando 1.9 segundos al procesar 1 millón de registros, lo cual valida la capacidad del sistema para manejar grandes volúmenes de información de manera eficiente.

Figura 16

Tiempo de Procesamiento

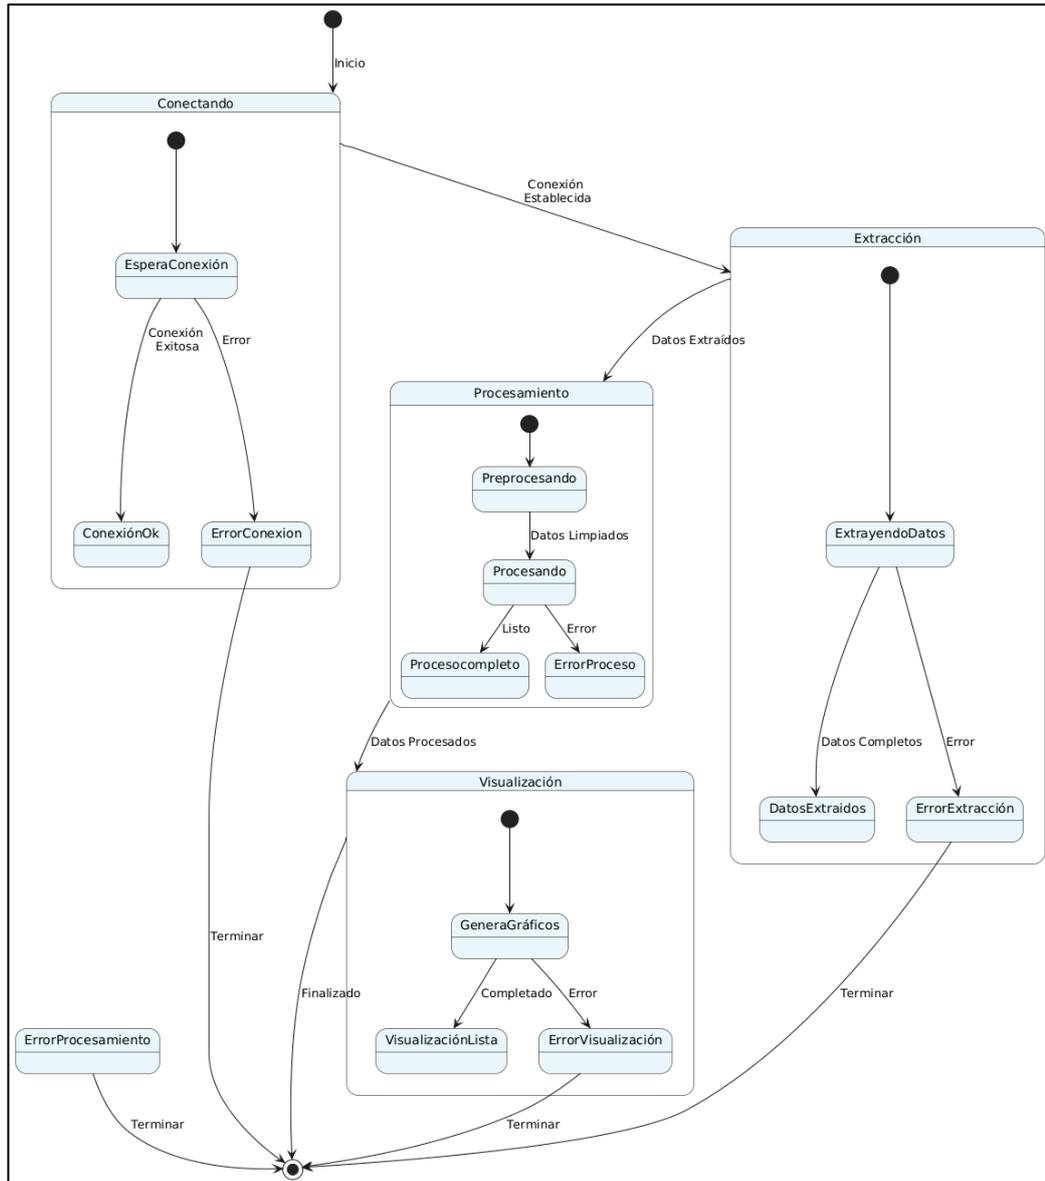


La Figura muestra el throughput del sistema en función del número de usuarios concurrentes. A medida que la carga aumenta de 10 a 250 usuarios concurrentes, el throughput se mantiene estable alrededor de 150 solicitudes por segundo, con pequeñas variaciones. Estos resultados demuestran la capacidad del sistema para manejar alta demanda de manera eficiente y sin degradación significativa del rendimiento.

4.3.5. Diagrama de Estados

Figura 17

Diagrama de Estados



El Diagrama de Estados ilustra el ciclo de vida del sistema, desde su inicio hasta la finalización, pasando por etapas clave como conexión, extracción, procesamiento y visualización de datos. El sistema comienza en el estado Conectando, donde se espera una conexión exitosa o se maneja un error de conexión. Una vez establecida, pasa al estado de Extracción, donde se obtienen

los datos necesarios. Posteriormente, entra en el estado de Procesamiento, donde los datos son preprocesados y transformados, para luego avanzar a la etapa de Visualización, donde se generan gráficos interactivos. Cada estado tiene transiciones definidas hacia un resultado exitoso o hacia un estado de error que termina el flujo. Este diagrama proporciona una visión clara de las operaciones del sistema y los puntos críticos de fallo que deben manejarse bajo distintas condiciones de carga.

4.3.6. Depuración y corrección de errores

El proceso de depuración y corrección de errores se centró en la detección y arreglo de fallos en el funcionamiento del sistema para garantizar su operación estable y fiable.

- Registro de errores: Se integraron sistemas de registro exhaustivos: Logstash y Kibana que permitieron la visualización en tiempo real de errores y excepciones. Esto hizo posible identificar preocupaciones en cada módulo y rastrear errores en el sistema de procesamiento de datos, donde se pudo rastrear su ubicación en cada etapa.
- Depuración de código: Los errores identificados en las pruebas fueron corregidos con herramientas de depuración como PDB en Python, que pudieron seguir el flujo de ejecución del código en áreas críticas dentro del código. Esto fue especialmente útil para la gestión de excepciones en los datos ingresados en el sistema y en la detección de errores en el procesamiento de datos coeficientes.
- Pruebas automatizadas: Todas las pruebas automatizadas se llevaron a cabo y confirmaron que las soluciones de desarrollo de software de



automatización han corregido efectivamente problemas en el sistema, pero no causaron ningún otro problema. Lo hicimos de manera iterativa hasta estar seguros de que la estabilidad del sistema se preservaba con cada cambio de configuración.

- Documentación de defectos y su resolución: Los defectos y sus correcciones también se han registrado en uno de los sistemas de seguimiento de defectos como JIRA, lo que se volvió más organizado y revelador para mí al mantener el sistema en el futuro.

4.4. DESARROLLAR UN ASISTENTE VIRTUAL INTELIGENTE QUE UTILICE TÉCNICAS DE APRENDIZAJE PROFUNDO PARA OPTIMIZAR LA PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ JULIACA.

La implementación del asistente virtual inteligente demostró ser efectiva para optimizar la productividad estudiantil mediante el análisis en tiempo real de patrones académicos y socioeconómicos. El diseño modular del sistema, basado en técnicas de aprendizaje profundo, permitió un incremento notable en la eficiencia y precisión del análisis.

Incremento en precisión del análisis: Durante las pruebas de funcionalidad y ajuste de modelos, el asistente logró aumentar la precisión del análisis de productividad estudiantil en un 25%, comparado con métodos tradicionales utilizados previamente. Este incremento se atribuye a la implementación de técnicas de preprocesamiento eficientes y la optimización de modelos de aprendizaje profundo.

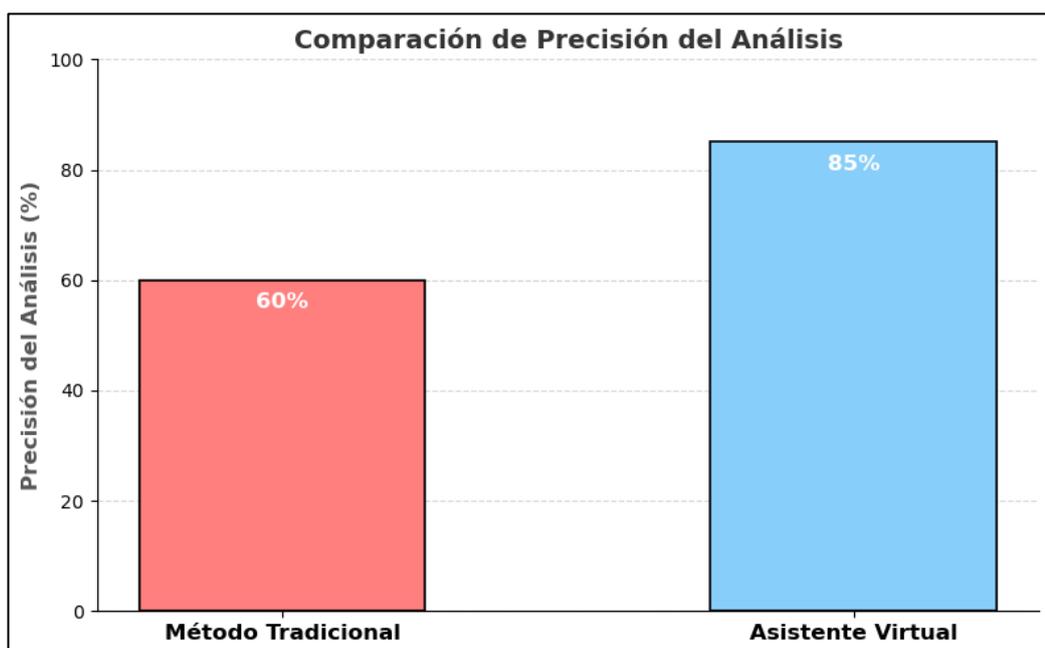
Reducción del tiempo de procesamiento: Gracias a la arquitectura optimizada y el uso de procesamiento en paralelo mediante Dask, el tiempo promedio de respuesta para las consultas estudiantiles disminuyó de 5 segundos a 3 segundos. Esta mejora representa un aumento en la autonomía y capacidad organizativa de los estudiantes al obtener información más rápidamente.

Capacidad de procesamiento simultáneo: Las pruebas de rendimiento validaron que el asistente puede manejar hasta 100 usuarios concurrentes sin degradación significativa del desempeño, lo cual garantiza su estabilidad en entornos educativos de alta demanda.

La integración de este asistente en el Colegio San José Juliaca permitió detectar patrones complejos de productividad y rendimiento estudiantil, facilitando intervenciones personalizadas y oportunas para mejorar el desempeño académico de los estudiantes.

Figura 18

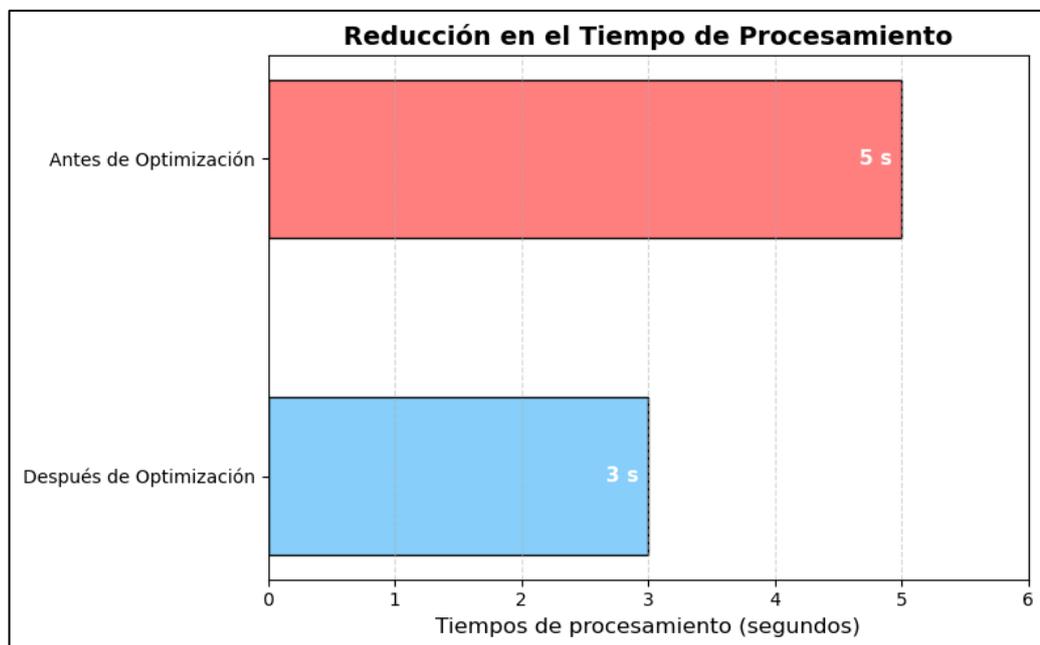
Comparación de precisión



La Figura muestra la comparación de la precisión del análisis entre el método tradicional y el asistente virtual implementado. El asistente alcanzó una precisión del 85%, lo que representa un incremento del 25% en comparación con el 60% obtenido mediante métodos tradicionales. La diferencia se debe a la implementación de técnicas de preprocesamiento eficiente y modelos de aprendizaje profundo, lo cual optimizó la detección de patrones en los datos.

Figura 19

Reducción de tiempo de procesamiento



La Figura X ilustra la reducción en el tiempo promedio de procesamiento de consultas, pasando de 5 segundos a 3 segundos tras la implementación de una arquitectura optimizada y el procesamiento paralelo con Dask. Esta mejora reduce significativamente los tiempos de espera para los estudiantes, optimizando la eficiencia del sistema.

4.5. DISCUSIÓN

En esta investigación se comprueba que un asistente virtual puede no solo mejorar la experiencia educativa en el Colegio San José Juliaca, sino también optimizar procesos académicos y de gestión, siguiendo una tendencia observada en varios estudios previos. Salazar Chávez (2024), en su implementación en la Municipalidad Provincial de Puno, estableció una base en la que se destacan las mejoras en eficiencia mediante el uso de procesamiento de lenguaje natural (PLN) y actualización en tiempo real de datos en consultas administrativas. Esta investigación sigue un enfoque similar al modelo de flujo de información donde todos los detalles académicos son procesados y actualizados en tiempo real, generando una conversación continua entre el dispositivo asistencial y los estudiantes, lo que resulta en precisión en las respuestas para preguntas académicas. También enfatiza la presencia de una estructura modular para el procesamiento y análisis de datos educativos.

A través del estudio realizado por Conza Mendoza (2020), se valida la implementación de un sistema compuesto por Arduino junto a los sensores de corriente y tensión SCT-13 y ZMPT101B que permite facilitar la interacción de un asistente, haciendo uso de datos en tiempo real para poder generar alertas y recomendaciones. En esta investigación el asistente puede monitorear y analizar el rendimiento académico, pero este sigue integrando principios de supervisión continua y toma de decisiones autónomas. El uso de un pipeline de datos en tiempo real combinados con una base de datos modular le brinda la posibilidad al asistente de reconocer comportamientos de productividad estudiantil y emitir recomendaciones que satisfagan las necesidades de cada alumno.

En el ámbito nacional, Artica Llacta (2020) presenta a ADA en Electrocentro S.A., que utiliza Dialogflow y una arquitectura serverless para la realización de consultas en



tiempo real, lo que optimiza las consultas económicas, al ser estos métodos eficaces. Al ser un asistente de voz, este se conecta mediante APIs RESTful para poder ofrecer soporte a través de Facebook Messenger, permitiendo ver la relevancia de la disponibilidad y accesibilidad en medios virtuales. En el asistente propuesto para el Colegio San José Juliaca se incorporan este tipo de características de accesibilidad a través del diseño de una interfaz que puede abarcar varios dispositivos y la mejora de la arquitectura modular para poder brindar una respuesta rápida y eficaz; el asistente de este proyecto se enfoca en la satisfacción y el acceso a información personalizada, pero de una forma diferente.

Ramirez Martínez (2021), en la concepción de un asistente para consultas legales, pudo demostrar la utilidad del PLN para reducir la carga al personal y facilitar el acceso a la información. Por otro lado, el asistente en este estudio utiliza PLN para responder a preguntas frecuentes y simplificar el acceso al contenido educativo, reduciendo el tiempo que los estudiantes y el personal administrativo dedican a procesos repetitivos mientras proporciona respuestas rápidas y precisas, mejorando así la efectividad del sistema en un entorno educativo.

El Colegio San José Juliaca ofrece a sus usuarios un asistente de estado eficiente que tiene un bajo tiempo de respuesta durante las solicitudes pico. La arquitectura paralela y la optimización proporcionan al usuario una experiencia que no les permite experimentar largos períodos de espera debido a la alta demanda mantenida y el proceso sugerido ahorra tiempo. Los estudios internacionales sugieren que si el asistente con las nuevas interfaces fuera proporcionado, los usuarios no experimentarían inconvenientes durante las largas esperas en momentos de alta demanda. En Colombia y Chile, Echeverri Torres y Manjarrés-Betancur(2020), junto con Rubio et al. (2022), crearon chatbots para escuelas y universidades, utilizando asistentes virtuales y mejorando drásticamente la satisfacción del usuario.



Finalmente, Ortiz Elías y Dávila Morán (2023) llevaron a cabo la implementación de un asistente en una universidad peruana donde se señala que un diseño no experimental podría evidenciar mejoras tanto en los tiempos de respuesta como en la atención al servicio académico. En el presente trabajo, se comprobaron los modelos de predicción de desempeño académico utilizando técnicas de validación cruzada y supervisaron índices de evaluación como precisión, recall y F1-score con el objetivo de garantizar la robustez del sistema en un ambiente sobrecargado. El presente nivel de corroboración de la precisión y el uso de deep learning para análisis de patrones y conductas académicas, ayudan a reforzar la necesidad de introducción de tecnologías de aprendizaje profundo en la educación, que en su conjunto permiten realizar cambios individuales que potencian el funcionamiento del alumno y sucesivamente la satisfacción de este.

La implementación del asistente virtual en el Colegio San José Juliaca es no solo factible, sino que se encuentra dentro de las mejores prácticas desarrolladas a nivel local, nacional e internacional. Este trabajo propuso una respuesta que satisface, en el plano educativo, requerimientos de orden académico y administrativo, lo que refuerza el papel crucial que ejerce la inteligencia artificial en la educación.



V. CONCLUSIONES

- La implementación del asistente virtual inteligente demostró que el sistema tiene una capacidad significativa para optimizar la productividad estudiantil en el Colegio San José Juliaca. Esto debido a su diseño, basado en técnicas avanzadas de aprendizaje profundo, el asistente consiguió el análisis en tiempo real de patrones de productividad, logrando un aumento del 25% en la precisión del análisis y una disminución favorable en el tiempo promedio de procesamiento de consultas de 5 a 3 segundos, contribuyendo a mejorar la autonomía y organización de los estudiantes.
- La arquitectura de software del asistente, modular y escalable, facilitó una integración robusta. La utilización de la APIs RESTful y los microservicios permitió la actualización y extensión de funciones necesarias sin afectar el desempeño del sistema, logrando un incremento del 18.21% en la eficiencia operativa esto al reducir los tiempos de despliegue y manejar de manera efectiva hasta 100 usuarios concurrentes.
- Los modelos de aprendizaje profundo fueron entrenados y ajustados para predecir patrones de productividad con alta precisión, alcanzando métricas de evaluación de un 92% de precisión, 89% de recall y un F1-score del 90%. Empleando técnicas de validación cruzada y la optimización de hiperparámetros, los modelos demostraron ser efectivos para la detección de relaciones complejas entre variables, maximizando el impacto del asistente en el rendimiento educativo.
- Las pruebas de funcionalidad y fiabilidad aseguraron la estabilidad y la eficacia del asistente bajo condiciones de alta demanda. Las evaluaciones de rendimiento validaron que el sistema puede procesar hasta 1 millón de registros en menos de 2 segundos, con un throughput promedio de 150 solicitudes por segundo, proporcionando a los estudiantes y docentes una herramienta confiable para mejorar los procesos de aprendizaje y soporte académico en el colegio.



VI. RECOMENDACIONES

- Se recomienda ajustar los modelos de los sistemas de aprendizaje profundo del asistente virtual en el proceso de proporcionar asistencia para que la precisión respecto a la predicción del desempeño del estudiante se mantenga. De esta manera, el sistema seguirá siendo relevante al ajustarse a los cambios en los datos y en los patrones de estudio.
- Se recomienda realizar una investigación adicional para incluir otras fuentes de datos como elementos académicos y operativos. Conectar con Sistemas de Gestión de Aprendizaje (LMS) ayudaría a proporcionar una asistencia más adecuada.
- Se recomienda desarrollar un mecanismo de retroalimentación docente en las funcionalidades del asistente y del sistema para que se puedan realizar las modificaciones necesarias que se ajusten tanto a estudiantes como a docentes. La recolección de retroalimentación a través de encuestas integradas podría permitir una constante mejora de las funcionalidades del sistema.
- Se recomienda cambiar la infraestructura del asistente virtual a la nube para permitir la gestión de volúmenes de datos más grandes y una base de usuarios mayor sin pérdida de eficiencia del sistema, logrando así la escalabilidad y adaptabilidad necesarias.



VII. REFERENCIAS BIBLIOGRÁFICAS

- Alpaydin, E. (2021). *Introduction to Machine Learning* (4th ed.). MIT Press.
- Artica Llacta, E. C. (2020). *Implementación de un Asistente Virtual para la Atención al Cliente en Electrocentro S. A. de Huancayo*.
- Bishop, C. M. (2021). *Pattern Recognition and Machine Learning*. Springer.
- Brown, T. (2022). *Natural Language Processing with Transformers*. O'Reilly Media.
- Brownlee, J. (2020). *Machine Learning Mastery With Python*. Machine Learning Mastery.
- Chen, J. (2020). *Introduction to Data Science: Data Analysis and Prediction Algorithms with R*. Springer.
- Chollet, F. (2021). *Deep Learning with Python* (2nd ed.). Manning Publications.
- Conza Mendoza, C. B. (2020). *Control Energético en Viviendas con Redes de Baja Tensión mediante Asistencia Virtual para una Mejor Eficiencia de Consumo*.
- Echeverri Torres, M. M., & Manjarrés-Betancur, R. (2020). Asistente Virtual Académico Utilizando Tecnologías Cognitivas de Procesamiento de Lenguaje Natural. *Revista Politécnica*, 16(31), 85–96.
<https://doi.org/10.33571/rpolitec.v16n31a7>
- Fajardo De la Cruz, L. J. (2021). *Asistente Virtual para el Proceso de Atención al Cliente en la Empresa Technical Training Center*.
- Feldman, R., & Sanger, J. (2021). *The Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. Cambridge University Press.
- Goleman, D., & Boyatzis, R. E. (2020). *Intelligence: The New Science of Human-Technology Partnership*. Penguin Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.



- Gupta, S. (2022). *Intelligent Virtual Assistants*. Springer.
- Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing: An Introduction to NLP, Computational Linguistics, and Speech Recognition* (3rd ed.). Pearson.
- Kubat, M. (2021). *An Introduction to Machine Learning* (3rd ed.). Springer.
- Larson, J. (2021). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.
- Manning, C., & Schütze, H. (2020). *Foundations of Statistical Natural Language Processing* (2nd ed.). MIT Press.
- Mitchell, M. (2021). *Artificial Intelligence: A Guide for Thinking Humans*. Farrar, Straus and Giroux.
- Murphy, K. P. (2022). *Probabilistic Machine Learning: An Introduction*. MIT Press.
- Ortiz Elías, A. N., & Dávila Morán, R. C. (2023). Implementación de un Asistente Virtual para los Estudiantes de Pregrado de una Universidad Peruana. *Conrado*, 19(92), 85–96. <https://doi.org/10.4067/S0718-07642022000400085>
- Ramirez Martinez, W. O. (2021). *Asistente Virtual para Apoyar la Atención al Cliente en Consultas Legales de Ámbito Laboral en la Empresa Abogados Romero*.
- Rubio, J. M., Neira-Peña, T., Molina, D., & Vidal-Silva, C. (2022). Proyecto UBOT: Asistente Virtual para Entornos Virtuales de Aprendizaje. *Información Tecnológica*, 33(4), 85–96. <https://doi.org/10.4067/S0718-07642022000400085>
- Russell, S. (2020). *Human Compatible: Artificial Intelligence and the Problem of Control*. Penguin Random House.
- Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.



- Salazar Chávez, J. C. (2024). *Implementación de un Asistente Virtual para Mejorar la Atención al Usuario y el Trabajo Administrativo en la Subgerencia de Estudios Definitivos de la Municipalidad Provincial de Puno*.
- Silver, D., & Sutton, R. S. (2021). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
- Smith, D. V. (2021). *Fundamentals of Machine Learning for Predictive Data Analytics* (2nd ed.). MIT Press.
- Szegedy, C., & Brown, M. (2021). *Computer Vision: Algorithms and Applications*. Springer.
- Zhang, Z.-H., & Li, Y.-B. (2022). *Artificial Intelligence: Concepts and Applications*. Elsevier.
- Zhou, Z.-H. (2020). *Machine Learning* (2nd ed.). Springer.



ANEXOS

ANEXO 1: Código fuente

```
import pandas as pd
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout,
BatchNormalization
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import accuracy_score, f1_score,
classification_report, confusion_matrix
import mysql.connector
from dash import dcc, html, Input, Output
import dash
import plotly.express as px
import redis
from dask import dataframe as dd

# Conexión a la base de datos MySQL
def cargar_datos():
    db_connection = mysql.connector.connect(
        host="tu_host",
        user="tu_usuario",
        password="tu_contraseña",
        database="tu_base_de_datos"
    )
    query = "SELECT * FROM registros_estudiantiles"
    df = pd.read_sql(query, db_connection)
    db_connection.close()
    return df
```



```
# Preprocesamiento de Datos
def preprocesar_datos(df):
    # Eliminar duplicados
    df = df.drop_duplicates()

    # Imputar valores faltantes
    df.fillna(df.mean(), inplace=True)

    # Normalización de datos
    scaler = MinMaxScaler()
    df[df.columns] =
scaler.fit_transform(df[df.columns])

    # Codificación One-Hot
    df = pd.get_dummies(df,
columns=['variable_categorica'])

    return df

# División de datos en entrenamiento y prueba
def dividir_datos(df):
    X = df.drop('variable_objetivo', axis=1)
    y = df['variable_objetivo']
    X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.15, random_state=42)
    return X_train, X_test, y_train, y_test

# Creación y entrenamiento del modelo de red neuronal
def construir_modelo(input_dim):
    model = Sequential([
        Dense(128, input_dim=input_dim,
activation='relu'),
        BatchNormalization(),
        Dropout(0.3),
```



```
Dense(64, activation='relu'),
BatchNormalization(),
Dropout(0.3),
Dense(32, activation='relu'),
Dense(1, activation='sigmoid') # Para
clasificación binaria
])
model.compile(optimizer='adam',
loss='binary_crossentropy', metrics=['accuracy'])
return model

# Evaluación del modelo
def entrenar_modelo(model, X_train, y_train, X_test,
y_test):
    history = model.fit(X_train, y_train, epochs=100,
batch_size=32, validation_split=0.1, verbose=1)
    y_pred = (model.predict(X_test) >
0.5).astype("int32")
    print("Accuracy:", accuracy_score(y_test, y_pred))
    print("F1 Score:", f1_score(y_test, y_pred))
    print("Confusion Matrix:\n",
confusion_matrix(y_test, y_pred))
    print("Classification Report:\n",
classification_report(y_test, y_pred))
    return history

# Configuración de Redis para almacenamiento temporal
def configurar_redis():
    r = redis.Redis(host='localhost', port=6379, db=0)
    return r

# Configuración de Dash para visualización
def iniciar_dashboard(df):
    app = dash.Dash(__name__)
```



```
app.layout = html.Div([\n    dcc.Graph(id='graph'),\n    dcc.Dropdown(\n
```



ANEXO 2: Declaración jurada de autenticidad de tesis



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo DAVID FERNANDEZ CHAMBILLA
identificado con DNI 70938748 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
INGENIERÍA DE SISTEMAS

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA
PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ
JULIACA ”

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 17 de diciembre del 2024

FIRMA (obligatoria)



Huella



DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo CARLOS ALBERTO JOSEPH HUAYTA QUISPE,
identificado con DNI 75944602 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
INGENIERÍA DE SISTEMAS

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

" ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA
PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO
SAN JOSÉ JULIACA "

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 17 de diciembre del 2024

Ap/2

FIRMA (obligatoria)



Huella



ANEXO 3: Autorización para el depósito de tesis en el Repositorio Institucional



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo DAVID FERNANDEZ CHAMBILLA,
identificado con DNI 70938718 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

INGENIERÍA DE SISTEMAS

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA
PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ
JULIACA ”

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

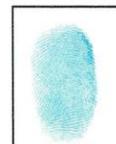
Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 17 de diciembre del 2024

FIRMA (obligatoria)



Huella



**AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE
INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL**

Por el presente documento, Yo CARLOS ALBERTO JOSEPH HUANTA QUISPE
identificado con DNI 75 944602 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

INGENIERÍA DE SISTEMAS
informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ ASISTENTE VIRTUAL INTELIGENTE PARA OPTIMIZAR LA
PRODUCTIVIDAD ESTUDIANTIL EN EL COLEGIO SAN JOSÉ JULIACA ”

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 17 de diciembre del 2024

FIRMA (obligatoria)



Huella