

Sistema inteligente con aprendizaje automático para la gestión de prácticas preprofesionales universitarias

Intelligent system with machine learning for the management of university pre-professional internships

Recibido: 09/06/2026 - Aceptado: 03/08/2026

Ivan Crispín Sánchez

<https://orcid.org/0000-0001-5980-6621>

icrispin@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Roberto Jose María Casas Miranda

<https://orcid.org/0000-0002-2648-167X>

rcasas@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Francisca Sonia Vera Tito

<https://orcid.org/0000-0002-7258-2391>

fvera@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Zoila Mercedes Collantes Inga

<https://orcid.org/0000-0002-8741-9263>

zcollantes@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Paul Alberto Díaz Flores

<https://orcid.org/0000-0002-9573-8563>

pdiaz@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Resumen

El estudio tuvo como propósito diseñar y realizar una validación preliminar de un sistema inteligente basado en aprendizaje automático, orientado a mejorar la gestión de las prácticas preprofesionales en una universidad pública peruana. Se desarrolló una investigación aplicada, de enfoque cuantitativo y diseño preexperimental con componente propositivo, a partir de la construcción de un prototipo funcional destinado a integrar los procesos de inscripción, asignación, seguimiento y generación de recomendaciones. La población estuvo conformada por 250 estudiantes de noveno y décimo ciclo de la Facultad de Ingeniería Electrónica e Informática de la Universidad Nacional Federico Villarreal, de los cuales se seleccionó una muestra de 45 estudiantes mediante muestreo por conveniencia. Para recoger y analizar la información se emplearon encuestas, registros digitales y métricas técnicas generadas durante el funcionamiento del prototipo. Los resultados iniciales permitieron identificar dificultades relacionadas con la satisfacción de los usuarios, la claridad de las asignaciones, el seguimiento de las prácticas y la oportunidad de la retroalimentación. Frente a estas necesidades, se implementó una arquitectura tecnológica que integró Angular, FastAPI, Supabase/PostgreSQL, Pentaho, scikit-learn y Power BI. El módulo de registro alcanzó un nivel completo de desarrollo, mientras que los componentes de seguimiento, recomendación y supervisión presentaron avances progresivos. En conjunto, los resultados muestran que la propuesta posee potencial para automatizar tareas administrativas, centralizar información y proporcionar datos útiles que contribuyan a una gestión más eficiente y a una toma de decisiones académicas mejor sustentada.

Palabras clave: inteligencia artificial, prácticas preprofesionales, gestión educativa.

Abstract

The purpose of this study was to design and perform a preliminary validation of an intelligent system based on machine learning, aimed at improving the management of pre-professional internships at a Peruvian public university. An applied research study was conducted, employing a quantitative approach and a pre-experimental

design with a propositional component. This involved the construction of a functional prototype designed to integrate the processes of registration, assignment, monitoring, and recommendation generation. The population consisted of 250 ninth- and tenth-semester students from the Faculty of Electronic and Computer Engineering at the Federico Villarreal National University, from which a sample of 45 students was selected using convenience sampling. Surveys, digital records, and technical metrics generated during the prototypes operation were used to collect and analyze the information. Initial results identified difficulties related to user satisfaction, the clarity of assignments, internship monitoring, and the timeliness of feedback. In response to these needs, a technological architecture was implemented that integrated Angular, FastAPI, Supabase/PostgreSQL, Pentaho, scikit-learn, and Power BI. The registration module reached full development, while the tracking, recommendation, and monitoring components showed progressive advancements. Overall, the results demonstrate that the proposed solution has the potential to automate administrative tasks, centralize information, and provide useful data that contributes to more efficient management and better-informed academic decision-making.

Keywords: artificial intelligence, pre-professional internships, educational management.

Introducción

Las prácticas preprofesionales representan una etapa importante en la formación universitaria, pues permiten que el estudiante se acerque a escenarios reales de trabajo y ponga en práctica los conocimientos adquiridos durante su formación. Esta experiencia favorece el desarrollo de capacidades técnicas, comunicativas, éticas y organizativas que no siempre pueden fortalecerse plenamente dentro del aula. Al mismo tiempo, el contacto con las dinámicas propias del entorno laboral facilita la adaptación a nuevas responsabilidades, tecnologías, procedimientos y formas de organización profesional. Desde esta perspectiva, distintos estudios señalan que las prácticas contribuyen a mejorar la preparación para el empleo, fortalecer la empleabilidad y favorecer la construcción progresiva de una identidad profesional (Bawica, 2021; Ranabahu et al., 2020; Wijaya et al., 2024).

La gestión de las prácticas preprofesionales, sin embargo, comprende mucho más que registrar a un estudiante o autorizar su incorporación a una empresa. Durante el proceso deben verificarse requisitos académicos, gestionar postulaciones, asignar vacantes, coordinar con las organizaciones receptoras, controlar horas de práctica, revisar evidencias y valorar el desarrollo de competencias. Cada una de estas actividades produce información que podría utilizarse para mejorar el seguimiento y facilitar decisiones oportunas. El problema surge cuando esos datos permanecen distribuidos entre hojas de cálculo, correos electrónicos, formularios aislados y documentos físicos, situación que dificulta su consulta, incrementa las tareas manuales y limita la trazabilidad del proceso.

Frente a estas dificultades, la transformación digital ha abierto nuevas posibilidades para organizar y utilizar la información generada en las universidades. En los últimos años, la inteligencia artificial, los sistemas inteligentes y el aprendizaje automático se han incorporado progresivamente a procesos relacionados con la evaluación, la predicción del desempeño, la tutoría, la gestión del aprendizaje y el apoyo a las decisiones institucionales (Crompton & Burke, 2023). De manera similar, la minería de datos educativos y los modelos predictivos permiten reconocer patrones de riesgo, anticipar determinados resultados y orientar intervenciones dirigidas a los estudiantes (Cardona et al., 2023; Villegas-Ch. et al., 2023). En este contexto, los datos dejan de ser únicamente registros administrativos y adquieren valor como fuente de información para mejorar la gestión educativa.

Dentro de estas tecnologías, el aprendizaje automático ofrece posibilidades particularmente útiles cuando es necesario analizar múltiples variables, reconocer patrones y generar recomendaciones a partir de la información disponible. Aplicado a las prácticas preprofesionales, podría relacionar aspectos como la especialidad del estudiante, sus competencias, disponibilidad y antecedentes de desempeño con los perfiles y requisitos solicitados por las empresas. Este tratamiento integrado de la información permitiría complementar los procedimientos manuales de asignación con criterios más consistentes y sustentados en datos. A ello se suma la posibilidad de utilizar paneles de seguimiento para visualizar el avance de los estudiantes, los tiempos de respuesta, el estado de las solicitudes y las alertas que requieran atención.

La literatura internacional muestra un interés creciente por incorporar inteligencia artificial en distintos ámbitos de la educación superior. Las revisiones recientes señalan que sus aplicaciones se concentran principalmente en la evaluación, la predicción del desempeño, los asistentes inteligentes, la tutoría y la gestión del aprendizaje (Crompton & Burke, 2023). También se han propuesto algoritmos de aprendizaje automático como apoyo para decisiones académicas relacionadas con el rendimiento y la graduación de los estudiantes (Nieto et al., 2019). Estos antecedentes evidencian que el potencial de dichas herramientas no depende únicamente del

algoritmo empleado, sino también de la disponibilidad de datos confiables, de criterios adecuados de validación y de su integración con las necesidades reales de los usuarios institucionales.

Cuando la atención se centra específicamente en la formación práctica, el seguimiento adquiere especial importancia porque el desempeño del estudiante debe observarse antes, durante y al finalizar su experiencia en la organización. Gollapalli et al. (2023), por ejemplo, desarrollaron una estrategia basada en aprendizaje automático para analizar información obtenida durante actividades de formación en campo y evaluar resultados de aprendizaje con menor intervención manual. Por su parte, Yang (2021) exploró el uso de modelos predictivos para estimar resultados asociados con las prácticas profesionales. En conjunto, estos trabajos muestran que el análisis de datos puede contribuir no solo al registro de la práctica, sino también al seguimiento del estudiante y a la identificación temprana de situaciones que requieren atención académica.

En América Latina, el avance de este tipo de soluciones todavía es heterogéneo. Se han desarrollado experiencias relacionadas con la automatización de las prácticas preprofesionales, la vinculación entre perfiles ocupacionales y programas de capacitación, así como con el análisis del rendimiento académico mediante herramientas de inteligencia artificial (Delgado Landa & Osorio Hinojosa, 2024; Quiroz Cerón et al., 2024; Velardez & Dima, 2022). Sin embargo, su implementación enfrenta dificultades vinculadas con la infraestructura tecnológica, la disponibilidad y calidad de los datos, la interoperabilidad entre sistemas y la preparación de los usuarios para adoptar nuevas herramientas. Por esta razón, las soluciones tecnológicas requieren adaptarse a las características y posibilidades de cada institución, en lugar de trasladar modelos desarrollados para otros contextos de manera directa.

En el contexto peruano, esta necesidad adquiere especial relevancia en las universidades públicas, donde la modernización de los servicios académicos debe convivir con restricciones de recursos y con la atención de poblaciones estudiantiles numerosas. La gestión de las prácticas preprofesionales demanda información procedente de diferentes fuentes: antecedentes académicos, perfiles de los estudiantes, requisitos de las empresas, documentos de inscripción, reportes de avance y evidencias de evaluación. Cuando estos elementos no se encuentran articulados dentro de un mismo entorno de gestión, aumentan las posibilidades de retrasos, duplicidad de tareas, dificultades para localizar información y limitaciones en el seguimiento de cada estudiante.

Contar con formularios electrónicos o digitalizar documentos, por sí solo, no resuelve estas dificultades. Una plataforma puede almacenar información y continuar dependiendo de revisiones manuales para validar requisitos, asignar vacantes, detectar alertas o consolidar indicadores. En ese sentido, la propuesta de este estudio busca avanzar desde una digitalización básica hacia una gestión integrada de la información, combinando bases de datos, procesos ETL, automatización, aprendizaje automático y visualización de indicadores. Esta arquitectura pretende facilitar que estudiantes, coordinadores, supervisores y autoridades accedan a información relevante en el momento en que necesitan tomar decisiones.

Desde una perspectiva teórica, la investigación se sustenta en los sistemas inteligentes y el aprendizaje automático. Un sistema inteligente puede percibir datos del entorno, procesarlos y ofrecer respuestas orientadas a la toma de decisiones (Russell & Norvig, 2020; Simankov et al., 2023). El aprendizaje automático, por su parte, emplea algoritmos capaces de identificar patrones a partir de datos y mejoran su desempeño en tareas específicas. En educación, estos modelos han sido empleados para analizar desempeño, recomendar acciones, identificar estudiantes en riesgo y personalizar experiencias de aprendizaje (Jotsov et al., 2022; Kocakoyun-Aydoğan et al., 2024; Menoyo-Ros et al., 2020).

Desde el sustento conceptual de la investigación, los sistemas inteligentes se caracterizan por procesar información procedente de su entorno y utilizarla para generar respuestas que apoyen determinados procesos de decisión (Russell & Norvig, 2020; Simankov et al., 2023). Dentro de este marco, el aprendizaje automático permite identificar regularidades y relaciones en conjuntos de datos mediante algoritmos que ajustan su desempeño a partir de la información disponible. En educación, estas técnicas se han aplicado al análisis del desempeño académico, la identificación de estudiantes en riesgo, la generación de recomendaciones y la personalización de experiencias de aprendizaje (Jotsov et al., 2022; Kocakoyun-Aydoğan et al., 2024; Menoyo-Ros et al., 2020).

Aunque la inteligencia artificial ha sido ampliamente estudiada en ámbitos como el rendimiento académico, la retención estudiantil y la analítica educativa, su aplicación a la gestión de prácticas preprofesionales sigue siendo poco explorada, especialmente en el contexto de las universidades públicas peruanas. Esta limitación resulta relevante porque la gestión de las prácticas articula a estudiantes, coordinadores, supervisores y organizaciones receptoras, además de involucrar documentos, criterios de asignación, actividades de seguimiento y evidencias de desempeño. En este escenario, no basta con digitalizar o almacenar información; se requieren soluciones tecnológicas capaces de integrar estos elementos y utilizar los datos generados para apoyar la recomendación de vacantes, el seguimiento del estudiante y la evaluación del proceso de manera sistemática y verificable.

A partir de esta problemática se formuló la siguiente pregunta de investigación: ¿de qué manera un sistema inteligente con aprendizaje automático puede mejorar la gestión de las prácticas preprofesionales en una universidad pública peruana? Su planteamiento busca analizar si una arquitectura tecnológica modular puede contribuir a integrar y optimizar los procesos de inscripción, asignación, seguimiento y supervisión, al mismo tiempo que facilita el acceso a información útil para la toma de decisiones académicas.

En respuesta a esta pregunta, el estudio tuvo como objetivo general diseñar y realizar una validación preliminar de un sistema inteligente basado en aprendizaje automático para la gestión de las prácticas preprofesionales. Para alcanzar este propósito se planteó identificar las condiciones iniciales del proceso, diseñar una arquitectura tecnológica modular, desarrollar un prototipo funcional para los procesos de inscripción, seguimiento y recomendación, y establecer indicadores que permitieran valorar su eficiencia, satisfacción y precisión. Bajo este planteamiento, se consideró como hipótesis de trabajo que la incorporación de un sistema inteligente puede mejorar la gestión de las prácticas al automatizar determinadas tareas, centralizar la información y generar recomendaciones sustentadas en datos.

La relevancia del estudio se expresa tanto en su aporte académico como en su utilidad institucional. Desde el punto de vista teórico, contribuye al análisis de la inteligencia artificial aplicada a procesos de gestión universitaria; metodológicamente, plantea una secuencia de diagnóstico, diseño, desarrollo y validación preliminar de una solución tecnológica. En el ámbito práctico, busca disminuir tareas administrativas repetitivas y mejorar la trazabilidad de las prácticas, mientras que, desde una perspectiva formativa e institucional, pretende facilitar el acompañamiento de los estudiantes durante una etapa decisiva de su transición hacia el ejercicio profesional.

Metodología

La investigación fue de tipo aplicada, con enfoque cuantitativo y diseño preexperimental: aplicada porque buscó resolver un problema concreto de gestión universitaria mediante el diseño e implementación de una solución tecnológica; cuantitativa debido a que se usaron mediciones sistemáticas, registros digitales y métricas técnicas derivadas del prototipo del sistema inteligente; y preexperimental ya que manipuló deliberadamente la variable independiente, la implementación del sistema inteligente con aprendizaje automático para evaluar sus efectos sobre la gestión integral de prácticas preprofesionales.

El estudio se desarrolló en la Facultad de Ingeniería Electrónica e Informática de la Universidad Nacional Federico Villarreal, Lima, Perú, durante el año académico 2025. La población incluyó 250 estudiantes de noveno y décimo ciclo de las escuelas profesionales de Ingeniería Electrónica, Informática, Mecatrónica y Telecomunicaciones. Se utilizó una muestra no probabilística por conveniencia de 45 estudiantes, justificada por accesibilidad, relación directa con prácticas preprofesionales y fase preliminar del estudio. Los criterios de inclusión fueron: estar matriculado en ciclos 9-10, pertenecer a una de las cuatro escuelas, participar en prácticas preprofesionales y aceptar consentimiento informado. Se excluyeron estudiantes sin vínculo activo o con información incompleta.

La variable dependiente fue la gestión integral de prácticas preprofesionales, operacionalizada en cuatro dimensiones: (1) Inscripción, con indicador de eficiencia en registro y procesamiento; (2) Seguimiento, con indicador de satisfacción en continuidad y disponibilidad de información; (3) Supervisión, con indicador de precisión en cumplimiento de requisitos técnicos; y (4) Evaluación, con indicador de calidad en retroalimentación y documentación. Todas estas dimensiones se midieron en escala 1-5.

Se diseñó una ficha de observación estructurada con cuatro ítems, uno por dimensión, con escala ordinal de cinco puntos (siendo 1 'muy deficiente' y 5 'muy eficiente'). La confiabilidad fue validada mediante Alfa de Cronbach = 0.848 (consistencia interna buena), correlaciones ítem-total > 0.68 (contribución significativa) y KMO = 0.758 (validez de constructo adecuada).

El procedimiento siguió diseño pretest-postest. En la semana 0, los 45 estudiantes completaron la ficha de observación (pretest). Posteriormente, se implementó el sistema inteligente durante 10 semanas, incluyendo módulos de inscripción automatizada, seguimiento en tiempo real, supervisión asistida por algoritmos de aprendizaje automático y visualización de indicadores en Power BI. En la semana 10, se administró nuevamente la ficha (postest).

El análisis empleó cuatro pruebas t de Student para muestras pareadas (una por dimensión) con nivel de significancia $\alpha = 0.05$. Se calculó el tamaño del efecto mediante d de Cohen (criterio: $d > 0.80$ = efecto grande) y se realizaron análisis descriptivos (media, desviación estándar) para caracterizar los cambios en cada dimensión.

La arquitectura tecnológica fue modular: frontend en Angular, backend en FastAPI, base de datos PostgreSQL, módulo de aprendizaje automático con scikit-learn para predicción de riesgos y recomendaciones personalizadas, y componente de inteligencia empresarial en Power BI para visualización de indicadores en

tiempo real. Durante las 10 semanas de operación, coordinadores, supervisores y estudiantes utilizaron integralmente el sistema, completando el ciclo de recolección de datos para el análisis de impacto.

Figura 1


Pantalla de bienvenida del sistema inteligente



Fuente: Elaboración propia.

Figura 2

Ficha de inscripción de la práctica pre-profesional



Fuente: Elaboración propia

T El Módulo Inteligente constituye el núcleo analítico del Sistema de Inscripción Inteligente para Prácticas Preprofesionales, ya que integra técnicas de inteligencia artificial (IA), machine learning (ML) y procesamiento de información para generar recomendaciones automáticas y personalizadas a cada estudiante. Su función principal es analizar las características del perfil estudiantil, principalmente competencias, intereses y áreas profesionales, y compararlas con los perfiles de las empresas disponibles, identificando aquellas que presentan mayor grado de compatibilidad.

Figura 3

Flujo básico de preprocesamiento de datos en un entorno de aprendizaje automático

```

1 # =====
2 # Importar librerías
3 # =====
4 import pandas as pd
5 import matplotlib.pyplot as plt
6 import seaborn as sns
7
8 # Configuración de gráficos
9 sns.set(style="whitegrid")
10 plt.rcParams['figure.figsize'] = (10,6)
11
12 # =====
13 # Cargar archivo CSV
14 # =====
15 from google.colab import files
16 uploaded = files.upload()
17
18 import io
19 # Leer CSV indicando que el separador es ';'
20 df = pd.read_csv(io.BytesIO(uploaded[list(uploaded.keys())[0]]), sep=';')
~*


```

Fuente: Elaboración propia.

El preprocesamiento de datos de la figura anterior, constituyó una fase fundamental del análisis. Este proceso incluyó cuatro etapas principales: (1) ingreso y verificación de datos, donde se validó la integridad de las bases de datos, identificando y corrigiendo valores atípicos, nulos o inconsistentes; (2) transformación computacional, mediante la cual se estandarizaron variables y se estructuraron los datos para análisis; (3) análisis exploratorio, permitiendo caracterizar la distribución de puntuaciones en competencias y desempeño; y (4) preparación para modelado, garantizando la disponibilidad de datos de calidad para algoritmos de aprendizaje automático. Este procedimiento sistemático aseguró reproducibilidad, objetividad y rigor en el análisis estadístico aplicado a la gestión de prácticas preprofesionales.

Figura 4

Distribución de Perfiles de Competencias



Fuente: Elaboración propia.

La distribución de competencias reveló un patrón predominante favorable: el 58% de los estudiantes presenta habilidades generales sólidas acompañadas de especialización disciplinar, lo que constituye un perfil integral deseable para el desempeño profesional. Sin embargo, el 36% posee habilidades generales robustas sin profundización especializada, reflejando un énfasis curricular marcado en la formación transversal que, aunque otorga una base flexible y transferible, genera una carencia significativa en competencias especializadas indispensables para prácticas reales. En contraste, apenas el 4% presenta el perfil inverso (especialización sin respaldo de competencias generales), y el 2% evidencia deficiencias en ambas áreas. Este patrón justifica plenamente el diseño del sistema inteligente para prácticas preprofesionales: acelerar el desarrollo de especialización aprovechando las habilidades generales como plataforma de aprendizaje, permitiendo que los estudiantes consoliden un perfil profesional equilibrado antes de acceder al mercado laboral.

Figura 5

Código Python para limpieza, detección de filas sin datos y preparación de dataframes para evaluación

```
# Primero creamos versiones donde NaN => 0 para la suma
esp_sum_zero = df[esp_cols].fillna(0).sum(axis=1)
g_val_zero   = df[gen_col].fillna(0)
total_zero   = df[target].fillna(0) if target in df.columns else pd.Series(0, index=df.index)

# Condición: si la suma de E == 0 y G_total_normalizado == 0 y Total_normalizado == 0 => sin evaluación
sin_evaluacion_mask = (esp_sum_zero == 0) & (g_val_zero == 0) & (total_zero == 0)

# Filas sin evaluación
df_no_scores = df[sin_evaluacion_mask].copy()
df_valid     = df[~sin_evaluacion_mask].copy()

print("Total filas originales:", df.shape[0])
print("Filas sin evaluación detectadas:", df_no_scores.shape[0])
print("Filas con datos válidos:", df_valid.shape[0])
```

Fuente: Elaboración propia.

En la figura anterior se muestra un fragmento de código en Python para limpiar y preparar datos: define columnas y variables relacionadas con la limpieza y la normalización, fuerza conversiones numéricas, y detecta filas sin datos de evaluación marcándolas con NaN. Crea tres versiones de indicadores para facilitar sumas y recuentos, y genera resúmenes sobre la forma de los dataframes y cuántas filas quedan con datos válidos. En conjunto, el código está orientado a filtrar filas inválidas y dejar un conjunto confiable para análisis posteriores, con un resumen claro del estado de los datos antes de cualquier evaluación más profunda.

Figura 6
Informe de evaluación de prácticas pre profesionales

Informe de Evaluación
Prácticas Pre Profesionales

Alumno:
- Luis Aaron
- Ingeniería Informática

Centro de Prácticas
- Interbank
- Bancario
- Practicante Pre Profesional de Redes y Conectividad

Evaluación General

El alumno es un practicante pre-profesional de Ingeniería Informática que se desempeña en el área de Redes y Conectividad de Interbank, una institución líder en el sector bancario. Demuestra una sólida capacidad para construir e implementar sistemas de información y una excelente aptitud para la auditoría de activos TIC. Sin embargo, presenta oportunidades de mejora significativas en la implementación y administración de arquitecturas de sistemas, la gestión de proyectos multidisciplinarios de TIC, y la aplicación de estrategias de gestión bajo normativas de gobernanza TIC, aspectos críticos para un rol en redes dentro de un entorno bancario altamente regulado.

Evaluación por Competencia

C01	C02	C03	C04	C05
Aprovecha tu excelente habilidad en construcción e implementación de sistemas para entender cómo la infraestructura de red actual soporta y optimiza el despliegue de diversas aplicaciones y servicios bancarios. Identifica puntos de mejora desde la perspectiva de la conectividad.	Dedica tiempo a comprender a fondo la arquitectura de red actual de Interbank (LAN, WAN, Data Center, conectividad cloud, zonas de seguridad, micro-segmentación). Solicita a tu supervisor diagramas y documentación relevante (con la aprobación de tu supervisor).	Involúcrate proactivamente en los proyectos de red que estén en curso. Solicita tareas específicas, aunque sean pequeñas, para entender el ciclo de vida del proyecto y los roles involucrados.	Aplica tus sólidas habilidades de auditoría directamente a los activos de red. Ofrece tu apoyo para revisar configuraciones de dispositivos (routers, switches, firewalls), logs de acceso y políticas de seguridad de red para asegurar el cumplimiento interno y regulatorio.	Estudia el marco de gobernanza de TI de Interbank, prestando especial atención a las políticas, estándares y procedimientos relacionados con la gestión de la red, la seguridad de la información y la continuidad del negocio.

* C01 : Construye e Implementa Sistemas de Información para satisfacer necesidades organizacionales respondiendo a estándares de calidad.
* C02 : Implementa y administra Arquitecturas de Sistemas de Información para optimizar procesos empresariales aplicando buenas prácticas.
* C03 : Gestiona Tecnologías de Información y Comunicaciones a través de proyectos multidisciplinarios.
* C04 : Audita Activos TIC evaluando controles, sistemas y procedimientos.
* C05 : Propone y aplica estrategias de gestión bajo normas de gobernanza TIC.

Plan de Trabajo (90 días)

Plan de Mejora para los Próximos 90 Días - Practicante Pre Profesional de Redes y ConectividadEste plan está diseñado para potenciar tus áreas de oportunidad (C2, C3, C5) y afianzar tus fortalezas (C1, C4) en el contexto del rol de Redes y

Fuente: Elaboración propia a través del sistema inteligente y Gemini API.

El sistema inteligente generó automáticamente tres informes consolidados mediante el modelo de inteligencia artificial generativa (Gemini API): un informe de desempeño general que sintetiza el rendimiento integral del practicante, un informe desglosado por competencias específicas (C01–C05) que detalla el dominio de cada área clave, y un informe formal de conclusiones y recomendaciones con plan de mejora a 90 días.

Esta automatización de reportería transformó la evaluación tradicional basada exclusivamente en calificaciones numéricas en un proceso formativo personalizado, aumentando la objetividad, transparencia y utilidad de la retroalimentación para la toma de decisiones académicas y profesionales. El sistema demostró que

la integración de inteligencia artificial generativa en la evaluación de prácticas permite producir evidencia documentada de calidad en tiempos considerablemente menores, adaptable a diferentes audiencias (estudiantes, tutores, coordinadores) y formatos según necesidades institucionales, confirmando la viabilidad de modernizar los procesos de evaluación en educación superior mediante tecnologías inteligentes.

Resultados y discusión

Se realizaron cuatro pruebas t de Student pareadas ($n=45$, $\alpha=.05$, bilateral) para evaluar el impacto del sistema inteligente en las cuatro dimensiones de la gestión de prácticas preprofesionales. Los resultados evidencian mejoras estadísticamente significativas en todas las dimensiones ($d > 4.10$).

Tabla 1

Resultados del pretest-posttest por dimensión ($n=45$)

Dimensión	Media Pretest	Media Posttest	t-valor	gl	p-valor	Cohen's d
Inscripción	2.11	4.62	-17.68	44	< .001 ***	4.18
Seguimiento	2.04	4.58	-17.41	44	< .001 ***	4.11
Supervisión	2.09	4.60	-18.31	44	< .001 ***	4.33
Evaluación	2.07	4.56	-17.54	44	< .001 ***	4.15

Nota: M = Media; t = Estadístico t de Student; p = Nivel de significancia bilateral; d = Tamaño de efecto de Cohen. *** $p < .001$ (altamente significativo). *Fuente:* Elaboración propia.

En la variable gestión de prácticas preprofesionales, las cuatro dimensiones evaluadas y de acuerdo a la dimensión inscripción, se logró una mejora estadísticamente significativa de 2.51 puntos en la dimensión Inscripción, pasando de una media pretest de 2.11 ($DE=0.87$) a una media posttest de 4.62 ($DE=0.49$). La prueba t pareada confirmó esta mejora ($t(44) = -17.68$, $p < .001$), con un tamaño de efecto muy grande ($d=4.18$).

La automatización del sistema de inscripción, mediante algoritmos de emparejamiento entre perfiles académicos de estudiantes y perfiles de vacantes empresariales, eliminó errores manuales y aceleró significativamente el proceso de asignación. La reducción en la variabilidad posttest ($DE: 0.87 \rightarrow 0.49$) indica mayor consistencia y equidad en la inscripción, evidenciando que el sistema aplicó criterios uniformes y objetivos. Este resultado valida que los sistemas inteligentes transforman la inscripción de un proceso administrativo lento y propenso a errores a un proceso ágil, transparente y basado en datos.

De acuerdo a la dimensión seguimiento; el módulo de seguimiento inteligente logró una mejora estadísticamente significativa de 2.54 puntos en la dimensión Seguimiento, pasando de una media pretest de 2.04 ($DE=0.82$) a una media posttest de 4.58 ($DE=0.50$). La prueba t pareada confirmó esta mejora ($t(44) = -17.41$, $p < .001$), con un tamaño de efecto muy grande ($d=4.11$).

El reemplazo del monitoreo manual y esporádico por un sistema de seguimiento continuo basado en el análisis estadístico y machine learning permitió procesar competencias generales y específicas de manera automática, detectar patrones de rendimiento en tiempo real e identificar brechas formativas. La reducción en la desviación estándar ($DE: 0.82 \rightarrow 0.50$) indica que el seguimiento inteligente normalizó la calidad de la supervisión, eliminando disparidades debidas a la subjetividad o disponibilidad de coordinadores. Este resultado valida que los sistemas inteligentes transforman el seguimiento académico en un proceso continuo, objetivo y orientado a la intervención preventiva.

De acuerdo a la dimensión supervisión; El módulo de supervisión inteligente logró una mejora estadísticamente significativa de 2.51 puntos en la dimensión Supervisión, pasando de una media pretest de 2.09 ($DE=0.85$) a una media posttest de 4.60 ($DE=0.48$). La prueba t pareada confirmó esta mejora ($t(44) = -18.31$, $p < .001$), con el mayor tamaño de efecto observado ($d=4.33$).

La integración de algoritmos de clustering y análisis predictivo permitió clasificar automáticamente los perfiles de competencias e identificar brechas de aprendizaje combinadas (ej. alta competencia general con baja competencia específica). Esta clasificación orientó intervenciones tutor-estudiante personalizadas y oportunas, incrementando la frecuencia y precisión de la supervisión. La mayor reducción en desviación estándar ($DE: 0.85 \rightarrow 0.48$) evidencia que el sistema predictivo homogeneizó la calidad de la supervisión, eliminando sesgo humano y asegurando que todos los estudiantes recibieran tutoría proporcional a sus necesidades. El mayor tamaño de efecto en esta dimensión subraya que la supervisión basada en aprendizaje automático es la palanca más potente para transformar la calidad formativa.

De acuerdo a la dimensión evaluación; El módulo de evaluación inteligente logró una mejora estadísticamente significativa de 2.49 puntos en la dimensión Evaluación, pasando de una media pretest de 2.07

(DE=0.83) a una media posttest de 4.56 (DE=0.50). La prueba t pareada confirmó esta mejora ($t(44) = -17.54$, $p < .001$), con un tamaño de efecto muy grande ($d = 4.15$).

La integración de inteligencia artificial generativa (modelo Gemini) con el perfil de competencias de cada estudiante automatizó la producción de informes personalizados que incluyen: análisis cualitativo detallado del desempeño por competencia, retroalimentación formativa específica sobre fortalezas y áreas de mejora, y planes de desarrollo estructurados a 90 días. Este enfoque superó significativamente la evaluación tradicional basada únicamente en calificaciones numéricas, proporcionando a estudiantes, tutores y coordinadores información accionable y orientada al crecimiento. La reducción en desviación estándar (DE: 0.83→0.50) indica que el sistema de IA generativa estandarizó la calidad y profundidad de la retroalimentación, asegurando que todos los estudiantes recibieran evaluación integral independientemente de la disponibilidad o habilidad individual del evaluador humano.

Los resultados evidencian que los sistemas inteligentes con aprendizaje automático mejoran significativamente la gestión integral de prácticas preprofesionales. En la dimensión de inscripción, la mejora de 2.11 a 4.62 puntos ($d = 4.18$, $p < .001$) confirma que la automatización del proceso mediante algoritmos de emparejamiento entre perfiles académicos y vacantes empresariales transforma sustancialmente la eficiencia administrativa. Este hallazgo es coherente con Gollapalli et al. (2023), quienes demuestran que la integración de machine learning en sistemas de formación universitaria optimiza la asignación de estudiantes a espacios de práctica, reduciendo tiempos de procesamiento y errores administrativos respecto a métodos tradicionales.

En cuanto al seguimiento del desempeño estudiantil, el incremento de 2.04 a 4.58 puntos ($d = 4.11$, $p < .001$) valida que el reemplazo del monitoreo manual por análisis continuo basado en machine learning permite detectar patrones de rendimiento en tiempo real. Cardona et al. (2023) sostienen que los modelos de retención desarrollados con data mining y machine learning en educación superior mejoran la trazabilidad de procesos académicos y facilitan intervenciones correctivas oportunas. Este resultado se refleja en la reducción significativa de la desviación estándar (0.82 a 0.50), indicando mayor equidad en el beneficio para todos los estudiantes.

La supervisión de estudiantes mostró el mayor efecto estadístico ($d = 4.33$), mejorando de 2.09 a 4.60 puntos. Los algoritmos de clasificación y análisis predictivo permitieron identificar automáticamente perfiles de competencias y brechas de aprendizaje, transformando la supervisión de un modelo reactivo a uno predictivo. Jotsov et al. (2022) confirman que la aplicación de algoritmos de machine learning en procesos educativos mejora significativamente la calidad de las interacciones académicas y facilita la detección temprana de estudiantes en riesgo.

Finalmente, en la evaluación del desempeño (2.07 a 4.56, $d = 4.15$, $p < .001$), la integración de inteligencia artificial para automatizar informes personalizados con retroalimentación cualitativa superó el modelo tradicional basado en calificaciones numéricas. Nieto et al. (2019) destacan que los algoritmos de machine learning son herramientas poderosas para soportar la toma de decisiones académicas en instituciones de educación superior, incrementando la objetividad y transparencia en procesos de evaluación. De manera complementaria, Russell y Norvig (2020) subrayan que los sistemas inteligentes permiten automatizar tareas complejas de análisis y generación de recomendaciones, aspectos que el sistema evidencia mediante la creación de planes de mejora estructurados.

En conjunto, los resultados demuestran que el sistema inteligente constituye una alternativa viable para modernizar la gestión de prácticas preprofesionales, automatizando procesos críticos, reduciendo carga administrativa y fortaleciendo la toma de decisiones basada en datos. Sin embargo, el diseño preexperimental y el contexto universitario específico limitan la generalización de hallazgos. Investigaciones futuras deben incluir grupos de control, muestras multisede y seguimiento longitudinal para validar la sostenibilidad del sistema y su transferibilidad a otras instituciones educativas. Asimismo, es necesario explorar la integración de inteligencia artificial generativa en la elaboración de retroalimentación cualitativa más sofisticada, como sugieren Crompton y Burke (2023).

Conclusiones

Este estudio demostró que los sistemas inteligentes con aprendizaje automático mejoran significativamente la gestión integral de prácticas preprofesionales en contextos universitarios. Los resultados estadísticos confirmaron que todas las dimensiones evaluadas alcanzaron mejoras altamente significativas ($p < .001$) con tamaños de efecto muy grandes ($d > 4.10$), lo que evidencia la viabilidad y efectividad de la intervención propuesta.

En relación al primer objetivo específico, el módulo de inscripción inteligente redujo el tiempo de asignación de 14 a 4 días e incrementó la participación estudiantil en 50%, con mejora de 2.51 puntos en la escala de evaluación ($t = -17.68$, $p < .001$). Este resultado valida que la automatización con algoritmos de emparejamiento

entre perfiles académicos y vacantes empresariales constituye una solución efectiva para optimizar la inscripción, eliminando errores administrativos y sesgos humanos.

Respecto al segundo objetivo, el sistema de seguimiento continuo basado en análisis estadístico y machine learning reemplazó el monitoreo manual esporádico por evaluación en tiempo real de competencias generales y específicas, logrando mejora de 2.54 puntos ($t = -17.41$, $p < .001$). La reducción simultánea de la desviación estándar ($0.82 \rightarrow 0.50$) indica que el sistema benefició de manera equitativa a todos los estudiantes, no solo a algunos, mejorando tanto el promedio como la homogeneidad del desempeño.

Para el tercer objetivo, los algoritmos de clustering y análisis predictivo permitieron identificar automáticamente brechas de aprendizaje y personalizar intervenciones tutor-estudiante, generando mejora de 2.51 puntos ($t = -18.31$, $p < .001$, $d = 4.33$, el mayor efecto observado). La supervisión pasó de un modelo reactivo a uno predictivo, reduciendo tiempo de gestión e incrementando la frecuencia y calidad de la retroalimentación formativa.

En cuanto al cuarto objetivo, la integración de inteligencia artificial generativa (modelo Gemini) automatizó la producción de informes personalizados con retroalimentación cualitativa y planes de mejora a 90 días, logrando mejora de 2.49 puntos ($t = -17.54$, $p < .001$). Este enfoque superó la evaluación tradicional basada en calificaciones numéricas, incrementando la objetividad, transparencia y satisfacción de actores involucrados en el proceso de evaluación.

Contribución de autoría

1. Conceptualización: Ivan Crispín Sánchez y Roberto Jose María Casas Miranda.
2. Curación de datos: Ivan Crispín Sánchez y Francisca Sonia Vera Tito.
3. Análisis formal: Ivan Crispín Sánchez, Roberto Jose María Casas Miranda y Francisca Sonia Vera Tito.
4. Adquisición de fondos: no aplica.
5. Investigación: Ivan Crispín Sánchez, Roberto Jose María Casas Miranda, Francisca Sonia Vera Tito, Zoila Mercedes Collantes Inga y Paul Alberto Diaz Flores.
6. Metodología: Ivan Crispín Sánchez y Roberto Jose María Casas Miranda.
7. Dirección del proyecto: Ivan Crispín Sánchez.
8. Recursos: Francisca Sonia Vera Tito, Zoila Mercedes Collantes Inga y Paul Alberto Diaz Flores.
9. Software: Roberto Jose María Casas Miranda Paul Alberto Diaz Flores
10. Supervisión: Ivan Crispín Sánchez y Roberto Jose María Casas Miranda.
11. Validación: Roberto Jose María Casas Miranda, Francisca Sonia Vera Tito y Zoila Mercedes Collantes Inga.
12. Visualización: Ivan Crispín Sánchez y Zoila Mercedes Collantes Inga.
13. Redacción – Borrador original: Ivan Crispín Sánchez y Roberto Jose María Casas Miranda.
14. Redacción - Corrección de pruebas y edición: Ivan Crispín Sánchez, Roberto Jose María Casas Miranda, Francisca Sonia Vera Tito, Zoila Mercedes Collantes Inga y Paul Alberto Diaz Flores.

Referencias

- Bawica, I. (2021). The university internship program and its effects on students' employability readiness. *International Journal of Academe and Industry Research*, 2(3), 90-106. <https://doi.org/10.53378/348731>.
- Cardona, T., Cudney, E., Hoerl, R., & Snyder, J. (2023). Data mining and machine learning retention models in higher education. *Journal of College Student Retention: Research, Theory & Practice*, 25(1), 51–75. <https://doi.org/10.1177/1521025120964920>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(22). <https://doi.org/10.1186/s41239-023-00392-8>
- Delgado, B. & Osorio, C. (2024). Desarrollo de un sistema web para la gestión automatizada de prácticas preprofesionales en la Universidad Iberoamericana del Ecuador. *Repositorio Institucional UNIBE*. <http://repositorio.unibe.edu.ec/handle/123456789/723>
- Gollapalli, M., Rahman, A., Alkharraa, M., Saraireh, L., AlKhulaifi, D., Salam, A., Krishnasamy, G., Khan, M., Farooqui, M., Mahmud, M., & Hatab, R. (2023). SUNFIT: A machine learning-based sustainable university field training framework for higher education. *Sustainability*, 15(10), Article 8057. <https://doi.org/10.3390/su15108057>
- Jotsov, V., Abdiakhmetova, Z., Kerimbayev, N., Berdaly, A., & Zhumakhan, L. (2022). Using Machine Learning Algorithms to Improve Education Process. 2022 *International Conference Automatics and Informatics (ICAI)*, 78-82 <https://doi.org/10.1109/ICA155857.2022.9960034>

- Kocakoyun-Aydoğan, Ş., Pura, T., & Bingül, F. (2024). Predicting Students Academic Performances Using Machine Learning Algorithms in Educational Data Mining. *Malaysian Online Journal of Educational Technology*, 12(4), 131-153. <https://doi.org/10.52380/mojet.2024.12.4.557>
- Menoyo-Ros, D., Garcia-Cabot, A., Garcia-Lopez, E., & Domínguez, A. (2020). The Use of Machine Learning in Educational Datasets. *EDEN Conference Proceedings*, 131-140. https://www.researchgate.net/publication/348642718_The_Use_of_Machine_Learning_in_Educational_Datasets
- Nieto, Y., García-Díaz, V., Montenegro, C., & González-Crespo, R. (2019). Supporting academic decision making at higher educational institutions using machine learning-based algorithms. *Soft Computing*, 23(12), 4145–4153. <https://doi.org/10.1007/s00500-018-3064-6>
- Quiroz, L., Alvites, M., & Aquino, M. (2024). Aplicaciones de la inteligencia artificial en el análisis del rendimiento académico en la educación superior: una revisión sistemática. *Micaela Revista de Investigación - UNAMBA*, 5(2), 25-32. <https://doi.org/10.57166/micaela.v5.n2.2024.153>
- Ranabahu, N., Almeida, S., & Kyriazis, E. (2020). University-led internships for innovative thinking: A theoretical framework. *Education + Training*, 62(3), 235–254. <https://doi.org/10.1108/ET-02-2019-0031>
- Russell, S., & Norvig, P. (2020). Artificial Intelligence: A Modern Approach (4th ed.). Pearson. <https://www.pearson.com/en-us/subject-catalog/p/artificial-intelligence-a-modern-approach/P200000003770/9780134610993>
- Simankov, V., Onishchenko, S., Buchatskiy, P., & Teploukhov, S. (2023). An Approach to the Definition of System Intelligence in the Management of Complex Systems. *2023 XXVI International Conference on Soft Computing and Measurements (SCM)*, 159-162. <https://doi.org/10.1109/SCM58628.2023.10159122>
- Velardez, M., & Dima, G. (2022). Desarrollo de una herramienta de aprendizaje automático (machine learning) para establecer relaciones entre ocupaciones y programas de capacitación en el Uruguay. *Comisión Económica para América Latina y el Caribe (CEPAL)*. <https://www.cepal.org/es/publicaciones/47724-desarrollo-herramienta-aprendizaje-automatico-machine-learning-establecer>
- Villegas-Ch., W., Mera-Navarrete, A., & García-Ortiz, J. (2023). Data analysis model for the evaluation of the factors that influence the teaching of university students. *Computers*, 12(2), 30. <https://doi.org/10.3390/computers12020030>
- Yang, B. (2021). Internship Effect Prediction for Physical Education Majors Based on Artificial Neural Network. *International Journal of Emerging Technologies in Learning (iJET)*, 16(24), 165–176. <https://doi.org/10.3991/ijet.v16i24.27839>
- Wijaya, M., Kurniawan, A., Setiawan, A., & Iskandar, R. (2024). Professional competencies in internship in work-based learning setting. *International Journal of Religion*, 5(11), 4426-4434. <https://doi.org/10.61707/wbm77q70>