



**PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR
ESCUELA HÁBITAT, INFRAESTRUCTURA Y CREATIVIDAD**

**TRABAJO DE INTEGRACIÓN CURRICULAR PREVIO A LA OBTENCIÓN
DEL TÍTULO DE INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN**

**SISTEMA INTELIGENTE PARA LA GESTIÓN Y SEGUIMIENTO DE LOS
RESULTADOS DE APRENDIZAJE EN LAS CARRERAS REPOTENCIADAS
DE LA PUCE IBARRA**

CAMPOS ZAMBRANO JEREMY PATRICIO

TUTOR:

SANTIAGO DAMIAN QUISHPE MORALES

IBARRA – ECUADOR

JULIO, 2026

Ibarra, 10 de julio de 2026

CERTIFICACIÓN TUTOR

En mi calidad de Tutor del Trabajo de **INTEGRACIÓN CURRICULAR** titulado:

SISTEMA INTELIGENTE PARA LA GESTIÓN Y SEGUIMIENTO DE LOS RESULTADOS DE APRENDIZAJE EN LAS CARRERAS REPOTENCIADAS DE LA PUCE IBARRA, presentado por el estudiante **Jeremy Patricio Campos Zambrano** con cédula de ciudadanía N° **1004461347**, para obtener el Título de **Ingeniero en Tecnologías de la Información**.

Certifico que el trabajo cumple con todos los parámetros establecidos, mediante el cual el estudiante demuestra el desarrollo de competencias en el campo de conocimiento de su profesión con un nivel de argumentación coherente, para ser sometido a la evaluación por parte de los lectores.

Adicionalmente, se adjunta el certificado de porcentaje de originalidad de TURNITIN.

20/7/26, 11:39 a.m. Turnitin - Originality Report - Trabajo de Titulación - Jeremy Campos.docx

Turnitin Originality Report	
Processed on: 20-Jul-2026 11:37 -05	
ID: 300800702	
Word Count: 17462	
Submitted: 1	
Trabajo de Titulación - Jeremy Campos.docx By Jeremy Campos	
Similarity Index	Similarity by Source
5%	Internet Sources: 4%
	Published: 0%
	Student Papers: 0%

< 1% match (Internet from 19-Oct-2022)	http://peace.uccs.edu/~colstream/11010/287/1/2-%20CTESIS%20PDF.pdf
< 1% match (Internet from 13-Feb-2022)	http://peace.uccs.edu/~colstream/11010/508/1/TFESIS%20PLAN%20ALBUJA.pdf
< 1% match (Internet from 04-Oct-2022)	http://peace.uccs.edu/~colstream/11010/482/1/72NAL%20TESIS%20CHICHAN%20DE%20OORA.pdf
< 1% match (Internet from 04-Oct-2022)	https://peace.uccs.edu/~colstream/11010/455/1/Proyecto%20de%20trabajo%203b3b.pdf
< 1% match (Internet from 19-Jun-2024)	https://edipal.edulearn.es/index.php/edulearn/catalog/view/30/30/30
< 1% match (Internet from 09-Jul-2024)	https://edipal.edulearn.es/index.php/edulearn/catalog/view/30/30/30
< 1% match (Internet from 11-Jun-2024)	https://edipal.uccs.edu/~colstream/handle/10515/155432/Documenta_completa.pdf?isAllowed=1&sequence=1
< 1% match (Student papers from 20-May-2026)	Submitted to Universidad Católica Boliviana "San Pablo" on 2024-05-20
< 1% match (Internet from 06-Apr-2018)	http://www.bu-ma.org/index.php/edipal/view/download/48/88
< 1% match (Internet from 11-Dec-2024)	https://www.copacabana.com.es/4646066/diagnosibilidad-de-datos-siempre-con-los-datos-de-P2-no-es-una-idea-de-combinar-sea/
< 1% match (Internet from 09-Jan-2023)	https://www.coursehero.com/file/30842750/Asorte-Trabajo-Colaborativo-Oscar-DuranBoc/
< 1% match ()	

Santiago
Quishpe
Morales

Firmado digitalmente
por Santiago Quishpe
Morales
Fecha: 2026.07.22
10:36:44 -05'00'

(f): _____

Mgs. Santiago Quishpe

TUTOR DE TRABAJO

C.C.: 1002697223

PÁGINA DE APROBACIÓN DEL TRIBUNAL

El tribunal examinador, aprueba el presente trabajo en nombre de la Pontificia Universidad Católica del Ecuador Ibarra:

Santiago
Quishpe
Morales

Firmado digitalmente
por Santiago Quishpe
Morales
Fecha: 2026.07.22
10:36:44 -05'00'

(f):

Mgs. Santiago Quishpe

C.C.: 1002697223

RUIZ QUIRANZA
RICARDO
PATRICIO

Firmado digitalmente
por RUIZ QUIRANZA
RICARDO PATRICIO
Fecha: 2026.07.22
09:22:45 -05'00'

(f):

Mgs. Patricio Ruiz

C.C.: 1002836524

Laura
Guerra
Torrealba

Firmado digitalmente
por Laura Guerra
Torrealba
Fecha: 2026.07.22
06:20:26 -05'00'

(f):

PhD. Laura Guerra

C.C.: 1757842784

ACTA DE CESIÓN DE DERECHOS

Yo, *Jeremy Patricio Campos Zambrano*, declaro conocer y aceptar la disposición del Art. 165 del Código Orgánico de Economía Social de los Conocimientos, Creatividad e Innovación, que manifiesta textualmente: “Se reconoce facultad de los autores y demás titulares de derechos de disponer de sus derechos o autorizar las utilidades de sus obras o prestaciones a título gratuito y oneroso, según las condiciones que determinen. Esta facultad podrá ejercerse mediante licencias libres, abiertas y otros modelos alternativos de licenciamiento o la renuncia”.

Ibarra, 10 de julio de 2026



Validar únicamente en FirmaEC.
Firmado electrónicamente por:
**JEREMY PATRICIO
CAMPOS ZAMBRANO**


(f): _____

Jeremy Patricio Campos Zambrano

C.C.:1004461347

AUTORÍA

Yo, *Jeremy Patricio Campos Zambrano*, portador de la cédula de ciudadanía N° 1004461347, declaro que el presente trabajo de investigación es de total responsabilidad del autor, y eximo expresamente a la Pontificia Universidad Católica del Ecuador Ibarra de posibles reclamos o acciones legales.



(f):.....

Jeremy Patricio Campos Zambrano

C.C.: 1004461347

DEDICATORIA

A mis padres, quienes con su amor incondicional y su esfuerzo incansable construyeron el camino que hoy me permite estar aquí. Desde pequeño me enseñaron que el trabajo honesto y la perseverancia son las únicas herramientas que nadie puede quitarte. Cada madrugada que se levantaron pensando en mi bienestar, cada sacrificio que hicieron en silencio para que yo pudiera estudiar y cada palabra de aliento en los momentos en que sentí que no podía más, quedaron grabados en mi corazón como la razón más poderosa para no rendirme. No existe logro en mi vida que no lleve su huella.

A mi familia, por ser el pilar que sostiene todo lo que soy. Por esa calidez única que solo se encuentra en casa, por las reuniones donde el cansancio desaparecía y por esa fe inquebrantable que siempre depositaron en mí, incluso cuando yo mismo no la tenía. En los momentos más difíciles de este proceso, bastaba con recordar que tenía a mi familia detrás para encontrar fuerzas y continuar. Gracias por celebrar cada avance como propio y por nunca dejar de creer que llegaría hasta aquí.

A mi novia, Arianna, quien ha sido mi compañera, mi cómplice y motivación. Gracias por ser mi calma cuando todo se sentía caótico, por escucharme hablar durante horas sobre el sistema, la tesis y los problemas que parecían no tener solución, y por responderme siempre con paciencia y con esa serenidad que tanto admiro en ti. Fuiste testigo de las noches largas, de las frustraciones y también de cada pequeña victoria que celebramos juntos. Tu presencia a lo largo de este proceso no fue un detalle, fue un sostén. Gracias por quedarte, por apoyarme y por ser exactamente lo que necesitaba en cada momento.

A todos ellos, con todo el amor y la gratitud que caben en estas páginas, dedico este trabajo que representa el cierre de una de las etapas más importantes de mi vida y el inicio de todo lo que está por venir.

AGRADECIMIENTOS

A Dios, por brindarme la fortaleza necesaria para culminar esta etapa de mi formación profesional.

A la Pontificia Universidad Católica del Ecuador Sede Ibarra, por ser el espacio donde adquirí los conocimientos y competencias que hicieron posible el desarrollo de este trabajo.

Al Ing. Santiago Quishpe, director de este trabajo de titulación, por su orientación técnica, su disposición permanente y por demostrar que un buen tutor no solo guía el conocimiento, sino también el carácter profesional de sus estudiantes.

A la Ing. Laura Guerra, por su acompañamiento constante durante el proceso de titulación y por su exigencia oportuna, que en más de una ocasión fue el impulso necesario para avanzar cuando el camino se tornaba difícil.

A mis compañeros y a todas las personas que de una u otra forma contribuyeron al desarrollo y culminación de este proyecto.

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN TUTOR	ii
PÁGINA DE APROBACIÓN DEL TRIBUNAL	iii
ACTA DE CESIÓN DE DERECHOS	iv
AUTORÍA.....	v
DEDICATORIA	vi
AGRADECIMIENTOS	vii
ÍNDICE DE CONTENIDOS.....	viii
ÍNDICE DE TABLAS	x
ÍNDICE DE FIGURAS.....	xi
RESUMEN	xii
ABSTRACT.....	xiii
INTRODUCCIÓN	1
OBJETIVO GENERAL	2
OBJETIVOS ESPECÍFICOS	2
CAPÍTULO I	4
ESTADO DEL ARTE	4
1.1. Antecedentes	4
1.2. Marco Teórico	7
1.2.1 Transformación digital en la educación superior	7
1.2.2 Analíticas de aprendizaje	7
1.2.3 Sistemas de información en la educación	8
1.2.4 Visualización de datos y tableros de control.....	9
1.2.5 Sistemas inteligentes, redes neuronales y toma de decisiones	10
1.2.6 Centralización e integración de datos	12
1.2.7 Bases de datos y gestión de la información.....	13
1.2.8 Arquitectura de software en aplicaciones web	13
1.2.9 Sistemas de alertas tempranas.....	14
1.2.10 Metodología en Cascada (Waterfall)	14
CAPÍTULO II	16
MATERIALES Y MÉTODOS.....	16
2.1 Aspectos generales de la investigación	16
2.1.1 Propósito.....	16
2.1.2 Alcance.....	16
2.1.3 Tipos de investigación	17
2.1.4 Enfoque de la investigación	17

2.1.5	Técnicas de recolección de la información	18
2.2	Metodología de desarrollo de software	18
2.2.1	FASE I: Análisis de requerimientos y planificación	19
2.2.2	FASE II: Diseño del sistema.....	28
2.2.3	FASE III: Implementación	37
2.2.4	FASE IV: Verificación	39
2.2.5	FASE V: Despliegue y mantenimiento	40
CAPÍTULO III.....		41
RESULTADOS Y DISCUSIÓN		41
3.1	Despliegue operativo por módulos del sistema.....	41
3.1.1	Módulo de autenticación y control de acceso	41
3.1.2	Módulo de administración de usuarios	42
3.1.3	Módulo de carga de Moodle	43
3.1.4	Módulo de resumen global	44
3.1.5	Módulo de predicción IA (alertas tempranas).....	46
3.1.6	Módulo de conciliación banner.....	48
3.1.7	Reportes Oficiales - Alertas tempranas IA.....	50
3.1.8	Reportes Oficiales – Actas de ruta.....	51
3.1.9	Reportes Oficiales – Conciliación	53
3.2	Pruebas de usabilidad y funcionamiento.....	55
3.2.1	Pruebas de caja negra	56
3.2.2	Pruebas de caja blanca	59
3.3	Discusión.....	63
3.3.1	Optimización del tiempo en la gestión de expedientes	64
3.3.2	Automatización en la detección preventiva de riesgo	64
3.3.3	Trazabilidad integral y auditoría cruzada.....	64
3.3.4	Seguridad y gobernanza de la información	65
3.3.5	Limitaciones del sistema.....	65
CONCLUSIONES		67
RECOMENDACIONES		69
REFERENCIAS BIBLIOGRÁFICAS		70
ANEXOS		72
Anexo1: Carta de aceptación de la propuesta tecnológica.....		72
Anexo2: Carta de recepción de la propuesta tecnológica por parte del cliente		73
Anexo3: Pares de entrenamiento del motor de clasificación		74

ÍNDICE DE TABLAS

Tabla 1 Comparación de arquitecturas de redes neuronales artificiales.....	11
Tabla 2 Características comunes de las arquitecturas de redes neuronales.....	12
Tabla 3 Historias de usuario funcionales y no funcionales	20
Tabla 4 Análisis de las historias de usuario y desglose de tareas.....	22
Tabla 5 Distribución de Sprints / Iteraciones de Desarrollo.....	24
Tabla 6 CU-01 Iniciar Sesión (JWT).....	30
Tabla 7 CU-02 Gestionar Usuarios (CRUD).....	31
Tabla 8 CU-03 Cargar Lotes Aula Virtual (Moodle)	32
Tabla 9 CU-05 Visualizar Dashboard de RDA	33
Tabla 10 CU-10 Notificar Alerta a Estudiante	34
Tabla 11 Matriz de Prueba: Autenticación de Usuario.....	56
Tabla 12 Matriz de Prueba: Carga de Archivos Moodle	57
Tabla 13 Matriz de Prueba: Edición en Línea y Auditoría.....	58
Tabla 14 Matriz de Prueba: Notificación por Correo Electrónico.....	59
Tabla 15 Matriz de Prueba: Estructuración y Normalización	60
Tabla 16 Matriz de Prueba: Ejecución del Motor Predictivo	61
Tabla 17 Matriz de Prueba: Seguridad de Endpoints (JWT).....	62
Tabla 18 Matriz de Prueba: Conciliación RDA por RDA.....	63
Tabla 19 Pares de entrenamiento.....	74

ÍNDICE DE FIGURAS

Figura 1 Metodología de cascada	18
Figura 2 Arquitectura del motor predictivo basado en red neuronal Feedforward	26
Figura 3 Diagrama de casos de uso del sistema de gestión RDA (PUCE-I)	29
Figura 4 Diagrama Relacional de la Base de Datos del Sistema	36
Figura 5 Diagrama de secuencia: cálculo de riesgo y semaforización	37
Figura 6 Módulo de Autenticación	42
Figura 7 Módulo de Administración de Usuarios	43
Figura 8 Módulo de Carga Moodle	44
Figura 9 Módulo de Resumen Global	45
Figura 10 Módulo de Predicción IA	47
Figura 11 Panel de Detalle y Notificación al Estudiante	48
Figura 12 Módulo de Conciliación Banner	49
Figura 13 Módulo de Reportes Oficiales: Alertas Tempranas IA	50
Figura 14 Reporte PDF: Alertas Tempranas IA	51
Figura 15 Módulo de Reportes Oficiales: Actas de Ruta	52
Figura 16 Reporte PDF: Actas de Ruta Académica	53
Figura 17 Módulo de Reportes Oficiales: Conciliación	54
Figura 18 Reporte PDF: Conciliación Banner	55

RESUMEN

El presente trabajo de titulación tuvo como propósito desarrollar un sistema web inteligente para la gestión y seguimiento de los Resultados de Aprendizaje en las carreras repotenciadas de la Pontificia Universidad Católica del Ecuador Sede Ibarra. La problemática identificada radicó en la gestión manual de los RDA mediante hojas de cálculo aisladas, lo que generaba una inversión de tiempo excesiva para los coordinadores, ausencia de trazabilidad en las modificaciones de calificaciones y muy poca capacidad de generar alertas tempranas sobre estudiantes en riesgo de reprobación.

Se aplicó la Metodología en Cascada y la arquitectura del sistema se diseñó bajo el patrón API RESTful, separando una capa de presentación desarrollada en Vue.js de la lógica de negocio implementada en NestJS, sobre una base de datos relacional MySQL con campos de auditoría en formato JSON. Como aporte diferenciador, se integró un motor predictivo basado en una Red Neuronal Artificial de arquitectura Feedforward, entrenada mediante retropropagación del error, capaz de calcular el riesgo académico de los estudiantes a partir de los Resultados de Aprendizaje disponibles en cualquier momento del periodo.

La validación del sistema se realizó mediante pruebas de caja negra y caja blanca. Los resultados demostraron que el motor predictivo clasificó al 83,8 % de la cohorte evaluada en niveles de riesgo Crítico o Alerta, que los mecanismos de seguridad basados en JSON Web Tokens bloquearon correctamente el acceso no autorizado a la API, y que el módulo de conciliación cruzó de manera individual cada Resultado de Aprendizaje entre los registros del Aula Virtual y el sistema institucional Banner.

Se concluyó que el sistema desarrollado constituyó una transición hacia un modelo de seguimiento académico proactivo y automatizado, dotando a la coordinación de la PUCE Ibarra de una herramienta capaz de centralizar la información, detectar oportunamente a los estudiantes en riesgo y notificarlos de manera automática vía correo electrónico.

Palabras clave: Resultados de Aprendizaje, Red Neuronal Artificial, sistema web, alertas tempranas, conciliación académica.

ABSTRACT

This thesis project aimed to develop an intelligent web system for managing and monitoring Learning Outcomes (LOs) in the updated degree programs at the Pontifical Catholic University of Ecuador, Ibarra Campus. The identified problem lay in the manual management of LOs using isolated spreadsheets, which resulted in an excessive time investment for coordinators, a lack of traceability in grade modifications, and very little capacity to generate early warnings about students at risk of failing.

The Waterfall methodology was applied, and the system architecture was designed using the RESTful API pattern, separating a presentation layer developed in Vue.js from the business logic implemented in NestJS, on a MySQL relational database with audit fields in JSON format. As a differentiating contribution, a predictive engine based on a Feedforward Artificial Neural Network, trained using backpropagation, was integrated. This engine is capable of calculating students' academic risk based on the Learning Outcomes available at any point during the academic period.

System validation was performed using black-box and white-box testing. The results demonstrated that the predictive engine correctly classified 83.8% of the evaluated cohort into Critical or Alert risk levels, that the security mechanisms based on JSON Web Tokens effectively blocked unauthorized access to the API, and that the reconciliation module individually cross-referenced each Learning Outcome between the records in the Virtual Classroom and the institutional Banner system.

It was concluded that the developed system constituted a transition toward a proactive and automated academic monitoring model, providing the PUCE Ibarra coordination team with a tool capable of centralizing information, promptly identifying students at risk, and automatically notifying them via email

Keywords: Learning Outcomes, Artificial Neural Network, web system, early warnings, academic reconciliation.

INTRODUCCIÓN

En las últimas décadas, la educación superior ha experimentado una transformación profunda impulsada por la digitalización de los procesos académicos y la necesidad de garantizar la calidad educativa mediante modelos basados en competencias. En este contexto, han surgido tecnologías de vanguardia como las analíticas de aprendizaje (learning analytics) y los sistemas web inteligentes, que permiten la medición, recopilación y análisis de datos sobre los estudiantes para transformar información bruta en conocimiento estratégico para la toma de decisiones.

La Pontificia Universidad Católica del Ecuador Sede Ibarra (PUCE-I), como institución comprometida con la excelencia y la innovación, implementó carreras repotenciadas que demandan un control exacto y oportuno del progreso académico. Dentro de la sede, la gestión de la información se estableció como una prioridad para asegurar que los nuevos modelos pedagógicos se cumplan con transparencia y rigor, especialmente en el seguimiento de los Resultados de Aprendizaje (RDA). El sistema educativo definió rutas específicas para que los estudiantes logren la suficiencia académica, incluyendo procesos extrasemestrales de recuperación para aquellos que no alcanzaron los indicadores requeridos en el periodo ordinario.

No obstante, la Unidad Académica de la PUCE-I se enfrentó a desafíos significativos en la operatividad de este seguimiento. Aunque se cuenta con el sistema Banner como repositorio principal, la gestión específica de los RDA obtenidos en instancias extrasemestrales se realizaba de manera externa y manual mediante archivos de hojas de cálculo aislados. Esta dependencia de procesos artesanales ocasionaba una inversión de tiempo excesiva para los coordinadores, falta de trazabilidad en la modificación de calificaciones y una preocupante dispersión de la información que impedía generar alertas tempranas sobre estudiantes en riesgo de reprobar.

Este cambio de paradigma ha posicionado al seguimiento de los Resultados de Aprendizaje (RDA) como un eje fundamental para medir el éxito estudiantil y la eficacia de los rediseños curriculares. Sin embargo, como señalan Henríquez y Gallardo-Aguayo (2025), el procesamiento de grandes volúmenes de datos académicos en los escenarios emergentes exige infraestructuras tecnológicas que superen las limitaciones de los métodos tradicionales de gestión.

Por tal motivo, este trabajo de titulación tuvo como propósito desarrollar un sistema inteligente para la gestión y seguimiento de los Resultados de Aprendizaje, construido sobre arquitecturas modernas como Vue.js y NestJS. Esta iniciativa busca centralizar la información, automatizar el procesamiento de datos provenientes del Aula Virtual y garantizar la integridad de los expedientes académicos mediante módulos de trazabilidad e historial. El uso de esta plataforma no solo beneficia la labor administrativa de los coordinadores, sino que dota a la universidad de una herramienta analítica proactiva para mejorar el éxito académico de sus estudiantes.

A partir de este planteamiento, se establecieron los siguientes objetivos.

OBJETIVO GENERAL

Desarrollar un sistema web inteligente para el seguimiento y análisis predictivo de los Resultados de Aprendizaje extrasemestrales en las carreras repotenciadas de la PUCE Ibarra, integrando la información académica extraída del Aula Virtual para facilitar la toma de decisiones oportunas por parte de las coordinaciones académicas.

OBJETIVOS ESPECÍFICOS

- Analizar el proceso actual de gestión de Resultados de Aprendizaje (RDA) en las carreras repotenciadas de la PUCE Ibarra, identificando las principales limitaciones operativas, riesgos de integridad de datos y debilidades en la generación de reportes académicos.
- Diseñar la arquitectura funcional y técnica del sistema inteligente, definiendo los módulos para la carga de datos desde fuentes oficiales, el almacenamiento estructurado y la gestión de usuarios.
- Construir el sistema utilizando tecnologías modernas, para la centralización automatizada y la generación de indicadores de desempeño académico
- Validar el funcionamiento del sistema web desarrollado, mediante pruebas técnicas y funcionales que aseguren la confiabilidad de los datos, la usabilidad del sistema y su aporte a la mejora de los procesos de seguimiento académico.

El presente trabajo de titulación se encuentra estructurado en tres (3) capítulos que detallan el ciclo de vida del desarrollo tecnológico. El Capítulo I comprende el marco referencial y el estado del arte, donde se analiza la problemática de la gestión manual de los Resultados de Aprendizaje y se fundamenta científicamente el uso de analíticas educativas. El Capítulo II se enfoca en la metodología y el diseño, describiendo la arquitectura técnica basada en Vue.js, NestJS y MySQL, así como la construcción del sistema inteligente, documentando el desarrollo de los módulos de carga de datos, seguimiento de RDA e historial. Finalmente, en el Capítulo III se establecen los resultados del sistema.

CAPÍTULO I

ESTADO DEL ARTE

El presente capítulo constituye el fundamento teórico y referencial que sustenta el desarrollo del sistema inteligente para la gestión de los Resultados de Aprendizaje (RDA). A través de una revisión exhaustiva de la literatura y de sistemas tecnológicos implementados en el ámbito educativo, se examinan las tendencias actuales en analíticas de aprendizaje (*learning analytics*) y la implementación de tableros de control (*dashboards*) para el monitoreo académico en la educación superior. Asimismo, se analizan las arquitecturas de software y las metodologías de integración de datos que permiten la transición de un registro manual hacia un modelo de análisis automatizado. Esta base conceptual permitió identificar el vacío tecnológico en el seguimiento de los RDA dentro del contexto de las carreras repotenciadas, proporcionando el marco necesario para la ejecución de la solución técnica desarrollada.

1.1. Antecedentes

En los últimos años, las instituciones de educación superior han incorporado tecnologías digitales orientadas a la gestión académica y al análisis del rendimiento estudiantil. Estas soluciones han evolucionado desde plataformas de gestión del aprendizaje hasta sistemas más avanzados que integran analítica de datos, visualización de información y modelos predictivos para apoyar la toma de decisiones educativas.

En este contexto, plataformas de gestión del aprendizaje como Moodle, desarrollada por Moodle Pty Ltd, han sido ampliamente implementadas en instituciones de educación superior para la administración de cursos y el seguimiento académico de los estudiantes. Estas herramientas permiten gestionar contenidos, evaluaciones y registros de desempeño, constituyéndose como una base fundamental para la recopilación de datos educativos extraídos directamente desde el Aula Virtual (Moodle Pty Ltd, 2024). De manera similar, Canvas, desarrollada por Instructure Inc., ha incorporado funcionalidades de analítica de aprendizaje que permiten visualizar el progreso académico mediante tableros interactivos, facilitando el monitoreo del desempeño estudiantil (Instructure Inc., 2024).

Por otra parte, soluciones más especializadas como Blackboard Analytics, desarrollada por Anthology Inc., han sido implementadas para el análisis avanzado de

datos académicos, permitiendo a las instituciones generar reportes e indicadores clave para la toma de decisiones (Anthology Inc., 2024).

Ahora bien, en el ámbito de la investigación, estudios han analizado el impacto de estas tecnologías en la educación superior. En este sentido, Nguyen et al. (2020) examinaron el uso de analíticas de aprendizaje, evidenciando que estas herramientas permiten mejorar el seguimiento del rendimiento académico mediante el análisis de datos educativos. Este aporte es fundamental para la presente investigación, ya que justifica la necesidad institucional de transitar de un registro pasivo de calificaciones hacia un análisis dinámico de los resultados extrasemestrales.

Asimismo, Hellas et al. (2018) analizaron diferentes enfoques de analítica de aprendizaje en entornos educativos, destacando que estas tecnologías permiten identificar patrones de comportamiento estudiantil y mejorar los procesos de enseñanza-aprendizaje. La relevancia de este estudio radica en que respalda metodológicamente la necesidad de agrupar y analizar el historial del estudiante para inferir su desempeño futuro dentro de las carreras repotenciadas.

En relación con los sistemas de visualización de datos, Bodily y Verbert (2017) estudiaron el uso de tableros de control, evidenciando que estas herramientas facilitan la interpretación de información académica y mejoran la toma de decisiones educativas. Esto sustenta el diseño de la interfaz gráfica del sistema propuesto, cuyo objetivo principal es presentar información procesada de manera visualmente accesible para las coordinaciones académicas.

En el ámbito de la predicción del rendimiento académico, Folorunso et al. (2024) analizaron el uso de analíticas de aprendizaje para predecir el desempeño estudiantil, evidenciando que mediante el análisis de datos educativos es posible identificar patrones y anticipar resultados académicos. Este hallazgo contribuye directamente a la propuesta tecnológica, validando el uso de modelos algorítmicos para calcular métricas de alerta temprana frente a posibles escenarios de reprobación.

Para la transformación digital en la educación superior, Bond et al. (2021) destacan que la adopción de tecnologías digitales ha permitido automatizar procesos

académicos y mejorar la eficiencia en la gestión educativa. Esta perspectiva refuerza la iniciativa de automatizar la carga de datos masivos desde el Aula Virtual, eliminando la dependencia de hojas de cálculo aisladas.

En cuanto a la integración de soluciones avanzadas en el entorno local, Muñoz y Delgado (2024) implementaron un enfoque de inteligencia artificial aplicada a la gobernanza y gestión académica dentro de la educación superior. Este trabajo destaca cómo la aplicación estratégica de sistemas inteligentes permite identificar áreas críticas en la administración de datos, optimizando la toma de decisiones mediante el análisis automatizado de indicadores institucionales. Esta investigación aporta el marco de referencia directo para justificar cómo el sistema web desarrollado mejora la gobernanza sobre los RDA en la PUCE Ibarra, asegurando estándares de auditabilidad y superando las limitaciones operativas tradicionales.

Respecto a la evolución de los sistemas predictivos, la literatura reciente enfatiza la integración de Redes Neuronales Artificiales (RNA) como un avance fundamental frente a los métodos estadísticos convencionales. Estas arquitecturas computacionales permiten procesar múltiples variables de entrada simultáneas para identificar patrones ocultos en el historial académico. Su aplicación metodológica justifica el núcleo del presente proyecto, donde se emplea un motor predictivo para inferir el riesgo académico exacto de los estudiantes en periodos extrasemestrales.

Complementariamente, existe un desafío técnico en la interoperabilidad entre los Entornos Virtuales de Aprendizaje y los Sistemas de Gestión Estudiantil Oficiales. La transcripción manual de calificaciones genera altos riesgos de inconsistencias. Por consiguiente, resulta indispensable el desarrollo de mecanismos de conciliación automatizada que crucen datos masivos y detecten discrepancias para garantizar la integridad del expediente.

A pesar de la existencia de plataformas como Moodle, Canvas y Blackboard Analytics, así como de los avances en investigaciones relacionadas, aún existen limitaciones en la integración de datos, la interoperabilidad entre sistemas y la automatización de procesos académicos. Estas limitaciones evidencian la necesidad de

desarrollar la presente solución para permitir una gestión eficiente y centralizada de la información en la institución.

1.2.Marco Teórico

1.2.1 Transformación digital en la educación superior

La transformación digital en la educación superior implica la integración de tecnologías digitales en los procesos académicos y administrativos, con el propósito de mejorar la calidad educativa y optimizar la toma de decisiones. Según Selwyn et al. (2023), la digitalización en las instituciones educativas ha permitido la adopción de herramientas tecnológicas avanzadas que optimizan la gestión académica y facilitan el acceso a información en tiempo real.

En este contexto, la transición tecnológica contemporánea ya no se limita a la simple digitalización de actas o la migración de archivos físicos hacia bases de datos convencionales, sino que evoluciona hacia el análisis inteligente de la información. Las plataformas de gestión del aprendizaje (LMS), como las aulas virtuales, han dejado de operar como simples repositorios estáticos de documentos para convertirse en ecosistemas dinámicos que registran grandes volúmenes de datos estructurados sobre el rendimiento y la interacción estudiantil.

La explotación técnica de estos datos permite a las coordinaciones académicas superar el modelo de seguimiento reactivo tradicional. Al implementar arquitecturas de software modernas, las instituciones pueden monitorizar de forma centralizada el cumplimiento de los Resultados de Aprendizaje (RDA) y diseñar estrategias de intervención preventiva. Esto resulta fundamental en etapas decisivas del ciclo académico, tales como los periodos extrasemestrales, donde la agilidad algorítmica para identificar la vulnerabilidad estudiantil define la capacidad de la universidad para garantizar la retención y el éxito académico.

1.2.2 Analíticas de aprendizaje

Las analíticas de aprendizaje se definen como el uso de técnicas de análisis de datos para comprender y optimizar los procesos educativos. De acuerdo con Buckingham Shum et al. (2019), las learning analytics permiten analizar datos educativos a gran escala, proporcionando información clave para mejorar el rendimiento académico. Asimismo,

Tsai y Gasevic (2022) destacan que estas herramientas facilitan la toma de decisiones basada en evidencia en entornos educativos digitales.

La analítica de aprendizaje ha evolucionado significativamente desde los enfoques puramente descriptivos los cuales se limitaban a reportar calificaciones históricas al final de un periodo hacia modelos analíticos predictivos e intervencionistas. Esta evolución demanda la implementación de arquitecturas de software y algoritmos computacionales capaces de procesar, limpiar y normalizar grandes volúmenes de registros provenientes de los Entornos Virtuales de Aprendizaje.

La aplicación práctica de estas técnicas se materializa mediante la extracción de los datos en bruto y su posterior transformación a través de motores lógicos. Al estructurar esta información, es posible generar visualizaciones interactivas y tableros de control (dashboards) que traducen la complejidad algorítmica en métricas comprensibles, como los sistemas de semaforización de riesgo. De esta manera, las analíticas de aprendizaje se convierten en un instrumento técnico esencial para el seguimiento preciso de los Resultados de Aprendizaje, dotando a la coordinación académica de la capacidad operativa para anticipar la vulnerabilidad estudiantil y tomar decisiones oportunas.

1.2.3 Sistemas de información en la educación

Los sistemas de información en el ámbito educativo permiten gestionar datos académicos y administrativos mediante plataformas tecnológicas. Según Al-Fraihat et al. (2020), estos sistemas contribuyen significativamente a la mejora de la eficiencia institucional al integrar múltiples fuentes de información en un entorno digital. Un sistema de información robusto no solo almacena registros, sino que estructura los flujos de trabajo, define permisos de acceso según roles administrativos y asegura que la información correcta llegue al usuario adecuado en el momento oportuno.

En el marco de la educación superior contemporánea, el diseño de estas plataformas ha transitado desde aplicaciones monolíticas tradicionales hacia arquitecturas lógicas desacopladas. Esta separación estructural entre la interfaz del cliente y el servidor central permite una gestión altamente escalable de los expedientes estudiantiles. Al modelar las bases de datos de manera relacional, las instituciones logran automatizar la extracción e ingesta masiva de calificaciones provenientes de sus propios entornos

digitales como el Aula Virtual, eliminando la dependencia de la transcripción manual y garantizando la integridad absoluta de los registros académicos.

Adicionalmente, un sistema de información educativo de vanguardia incorpora mecanismos estrictos de auditoría de seguridad y módulos de procesamiento algorítmico para respaldar la gestión administrativa. En instancias evaluativas críticas, tales como el seguimiento de los Resultados de Aprendizaje (RDA) durante la fase extrasemestral, la plataforma trasciende la simple persistencia de notas. Al evaluar los datos en bruto a través de un motor lógico centralizado, el sistema proporciona a la coordinación académica métricas estructuradas en tiempo real, convirtiendo el almacenamiento de información en conocimiento proactivo para salvaguardar la trayectoria del estudiante.

1.2.4 Visualización de datos y tableros de control

La visualización de datos permite representar información mediante gráficos e indicadores visuales, facilitando su interpretación. Verbert et al. (2023) señalan que los dashboards educativos permiten analizar el desempeño académico en tiempo real, facilitando la identificación de patrones y tendencias relevantes.

La construcción de estas interfaces ha evolucionado notablemente gracias a la implementación de entornos web reactivos. Estas tecnologías permiten que la capa de presentación se actualice dinámicamente al consumir los datos estructurados provenientes de un servidor central, garantizando la fluidez de la navegación. Desde una perspectiva ergonómica y de usabilidad, un tablero de control eficaz debe mitigar la sobrecarga cognitiva del usuario administrativo, transformando matrices numéricas extensas y complejas como los historiales extraídos directamente del Aula Virtual en representaciones gráficas de rápida asimilación.

La utilidad operativa de estas visualizaciones se maximiza cuando se integran como el punto de salida de modelos algorítmicos predictivos. En la gestión y seguimiento de los Resultados de Aprendizaje (RDA), particularmente durante las críticas instancias extrasemestrales, la representación visual trasciende la simple exposición de promedios históricos. A través de técnicas de diseño como la semaforización, los tableros de control logran traducir el nivel de riesgo académico, calculado en fracciones de segundo por motores inteligentes, en un espectro de colores intuitivo. Esta categorización visual

inmediata empodera a la coordinación académica para focalizar sus esfuerzos de intervención de manera exacta, optimizando los tiempos de respuesta.

1.2.5 Sistemas inteligentes, redes neuronales y toma de decisiones

Los sistemas inteligentes utilizan técnicas de inteligencia artificial para analizar datos y generar respuestas automatizadas. Según Holmes et al. (2023), la inteligencia artificial en la educación permite desarrollar sistemas capaces de apoyar la toma de decisiones mediante modelos predictivos basados en datos. En este contexto, un sistema de software adquiere la categoría de "inteligente" cuando trasciende el simple almacenamiento y despliega capacidades de automatización analítica, cálculo continuo de indicadores y semaforización de datos.

En el campo de las Redes Neuronales Artificiales (RNA) existen distintas arquitecturas, cada una especializada según el tipo de problema y la naturaleza de los datos. La Tabla 1 presenta una comparación de las tres arquitecturas más utilizadas en aplicaciones de inteligencia artificial aplicada:

Tabla 1

Comparación de arquitecturas de redes neuronales artificiales

Característica	Feedforward	Convolutacional (CNN)	Recurrente (RNN)
Tipo de conexión	Completamente conectada (Dense)	Conexiones locales con filtros (kernels)	Conexiones hacia atrás (retroalimentación)
Flujo de información	Unidireccional (entrada → salida)	Unidireccional (entrada → salida)	Bidireccional (pasado → presente)
Parámetros	Muchos (pesos por cada neurona)	Pocos (pesos compartidos)	Moderados (pesos repetidos en el tiempo)
Memoria	No tiene (sin estado)	No tiene (sin estado)	Sí (puede recordar estados previos)
Especialización	Datos tabulares generales	Datos espaciales (imágenes)	Datos secuenciales (texto, temporal, voz)
Entrenamiento	Retropropagación estándar	Retropropagación estándar	BPTT (Backpropagation Through Time)
Entrada	Vectores o matrices aplanadas	Imágenes (2D) o volúmenes (3D)	Secuencias de longitud variable
Aplicaciones	Clasificación tabular, regresión, datos generales	Visión por computadora, detección de objetos	NLP, predicción de series, análisis de videos
Complejidad computacional	Alta (muchas multiplicaciones)	Moderada (operaciones locales)	Alta (iteraciones secuenciales)

Nota: Comparación de las principales arquitecturas de redes neuronales según su tipo de conexión, flujo de información y aplicaciones.

A pesar de sus diferencias arquitectónicas, las tres variantes comparten fundamentos comunes que las definen como redes neuronales artificiales, tal como se sintetiza en la Tabla 2:

Tabla 2

Características comunes de las arquitecturas de redes neuronales

Aspecto	Descripción
Todas son redes neuronales	Basadas en neuronas artificiales, pesos, sesgos y funciones de activación no lineales.
Aprendizaje supervisado	Se entrenan con datos etiquetados usando retropropagación para ajustar pesos.
Funciones de activación	Usan ReLU, Sigmoid, Tanh u otras funciones no lineales para aprender patrones complejos.
Optimización	Utilizan optimizadores como SGD, Adam o RMSprop para minimizar funciones de pérdida.

Nota: Fundamentos compartidos entre las principales arquitecturas de redes neuronales artificiales.

Esta inteligencia se materializa mediante la implementación de un motor predictivo basado en la arquitectura Feedforward, seleccionada por su idoneidad para problemas de regresión sobre datos tabulares con una variable de entrada continua, su interpretabilidad para entornos institucionales, y la compatibilidad de su algoritmo de entrenamiento con la escala de calificaciones definida por la PUCE Ibarra. La descripción técnica detallada de su configuración, parámetros y proceso de entrenamiento se presenta en el Capítulo II.

1.2.6 Centralización e integración de datos

La centralización de datos consiste en la consolidación de información proveniente de diversas fuentes en un único sistema, lo que permite mejorar la consistencia y accesibilidad de los datos. De acuerdo con Alamri et al. (2020), la integración de datos en entornos educativos facilita el análisis de información y mejora

la eficiencia en la gestión académica. En el contexto de las instituciones de educación superior, superar la fragmentación de la información es un paso operativo crítico. Cuando los registros académicos residen en repositorios aislados como aulas virtuales, sistemas oficiales y hojas de cálculo manejadas individualmente, se incrementa drásticamente el riesgo de redundancia, desactualización y error humano. La integración tecnológica resuelve esta problemática al establecer una única "fuente de verdad", lo cual constituye el requisito fundamental para habilitar procesos de conciliación automatizada y aplicar modelos predictivos que dependen estrictamente de datos unificados y fiables.

1.2.7 Bases de datos y gestión de la información

Las bases de datos son sistemas diseñados para almacenar información de manera estructurada, garantizando su integridad y disponibilidad. Según Viberg et al. (2018), el uso adecuado de bases de datos permite gestionar grandes volúmenes de información educativa, facilitando su análisis y contribuyendo a la toma de decisiones informadas. En la gestión de los Resultados de Aprendizaje, la estructuración relacional de la información trasciende el simple almacenamiento temporal; se convierte en el mecanismo principal para asegurar la trazabilidad y la seguridad institucional. Un gestor de base de datos robusto permite mantener un registro histórico e inmutable de las transacciones, documentando con exactitud cuándo y cómo se modificó una calificación. Esta capacidad de auditoría es indispensable para validar procesos académicos sensibles, como las recuperaciones extrasemestrales, asegurando que el expediente del estudiante se mantenga transparente y protegido contra alteraciones no autorizadas o pérdidas accidentales.

1.2.8 Arquitectura de software en aplicaciones web

La arquitectura de software define la estructura de los sistemas informáticos y la forma en que sus componentes interactúan entre sí. En aplicaciones web, se utiliza comúnmente una arquitectura basada en la separación entre frontend (capa de presentación visual) y backend (capa de procesamiento y lógica de servidor). Ifenthaler y Yau (2019) señalan que las arquitecturas modernas permiten desarrollar sistemas escalables y flexibles, capaces de adaptarse a las necesidades cambiantes de los entornos educativos. Este desacoplamiento funcional mediante interfaces de programación de aplicaciones (API RESTful) resulta esencial para el rendimiento operativo. Al separar estas responsabilidades, el servidor puede dedicar sus recursos exclusivamente al

procesamiento de tareas intensivas como la validación de reglas de negocio académicas y la ejecución de algoritmos predictivos, mientras que la interfaz del usuario opera de manera independiente y reactiva. Esto garantiza que los coordinadores académicos puedan interactuar con tableros de control complejos sin experimentar bloqueos o tiempos de carga prolongados en sus navegadores.

1.2.9 Sistemas de alertas tempranas

Los sistemas de alertas tempranas son herramientas proactivas que permiten identificar situaciones de vulnerabilidad mediante el análisis continuo de datos. En el ámbito educativo contemporáneo, su aplicación trasciende la mera detección del bajo rendimiento general, estructurándose en torno a criterios de evaluación específicos. En el contexto de este proyecto, el sistema se activa principalmente cuando se detecta un RDA no alcanzado durante las evaluaciones extrasemestrales. Para lograr una medición precisa, la plataforma calcula el porcentaje de suficiencia del estudiante, procesando sus calificaciones extraídas del Aula Virtual para establecer una métrica cuantitativa.

A partir de este cálculo algorítmico, el sistema clasifica el nivel de riesgo académico del alumno mediante indicadores visuales (como la semaforización en niveles crítico, de alerta o seguro). La finalidad de este modelo predictivo no es únicamente informativa; su objetivo principal es que la identificación temprana del riesgo detone acciones de seguimiento inmediatas, tales como la generación de reportes preventivos, la notificación automática a los estudiantes y la programación oportuna de tutorías de nivelación por parte de las coordinaciones académicas para evitar la reprobación definitiva.

1.2.10 Metodología en Cascada (Waterfall)

La metodología en cascada se define como un modelo de desarrollo de software secuencial, donde el avance fluye de manera descendente a través de fases estrictamente definidas (análisis de requisitos, diseño, implementación, pruebas y despliegue). Su aplicación en este proyecto se justificó por la necesidad fundamental de contar con una estructura rígida y predecible que permitiera documentar y validar cada etapa antes de proceder a la siguiente. Al tratarse de un sistema institucional que procesa datos académicos oficiales y sensibles como las calificaciones de los Resultados de Aprendizaje y su conciliación directa con los reportes de Banner, no existía margen para la

ambigüedad o los cambios constantes que caracterizan a los enfoques ágiles. De este modo, se garantizó un desarrollo seguro, la mitigación de errores críticos antes de la etapa de codificación y la generación de una documentación técnica exhaustiva, indispensable para la futura mantenibilidad del sistema por parte de la universidad.

CAPÍTULO II

MATERIALES Y MÉTODOS

El presente capítulo detalla el marco estratégico y los recursos tecnológicos aplicados para el desarrollo del sistema inteligente de seguimiento de los Resultados de Aprendizaje (RDA). A través de esta sección, se describen los procedimientos sistemáticos que permitieron transformar los requerimientos académicos de la PUCE-I en una solución funcional, garantizando la integridad de los datos y la eficiencia en la gestión interna de las carreras repotenciadas.

2.1 Aspectos generales de la investigación

2.1.1 Propósito

El propósito fundamental del sistema desarrollado fue proveer una herramienta inteligente para la toma de decisiones académicas oportunas. Mediante el procesamiento de los RDA, la solución buscó eliminar la fragmentación de la información y reducir el error humano en el seguimiento estudiantil. El sistema cumplió con el propósito de actuar como un monitor proactivo, notificando estados de riesgo académico y facilitando la visualización de resultados mediante interfaces reactivas, fortaleciendo así la gestión interna de la universidad.

2.1.2 Alcance

Como resultado del análisis inicial, se delimitó el alcance técnico y operativo del sistema para asegurar la viabilidad del proyecto. El software se centró específicamente en la centralización automatizada de los datos provenientes de las fuentes universitarias, descartando la modificación directa de registros en el sistema Banner para proteger la soberanía de la información institucional.

El alcance abarcó el procesamiento de indicadores académicos de instancias extrasemestrales, la generación de reportes automáticos y la implementación de un dashboard de alertas tempranas para los coordinadores. Esta delimitación permitió que la solución fuera una herramienta especializada en la toma de decisiones estratégicas, acotando su uso a la gestión administrativa interna de las carreras.

En cuanto al tratamiento de los datos académicos procesados, el sistema opera exclusivamente sobre información proporcionada por la coordinación académica de la PUCE Ibarra en el marco de sus funciones institucionales. El acceso a los datos está restringido mediante autenticación JWT por roles, y los registros son utilizados únicamente con fines de seguimiento académico interno, sin exposición a terceros ni transferencia fuera del entorno institucional

2.1.3 Tipos de investigación

Se aplicó una investigación de tipo aplicada y tecnológica. Fue aplicada porque se orientó a resolver una problemática práctica dentro de la gestión interna académica de la universidad. Fue tecnológica debido a que el resultado consistió en la creación de un artefacto de software diseñado para optimizar procesos mediante el uso de arquitecturas modernas

2.1.4 Enfoque de la investigación

El enfoque fue cualitativo y cuantitativo. El componente cualitativo se centró en la comprensión de las necesidades de los coordinadores académicos, obtenida mediante observación directa del flujo de trabajo manual y entrevistas semiestructuradas que permitieron identificar los cuellos de botella operativos en la gestión de los Resultados de Aprendizaje. El componente cuantitativo se enfocó en el procesamiento exacto de las calificaciones extraídas del Aula Virtual, el cálculo de porcentajes de suficiencia de los RDA y la validación del motor predictivo basado en Red Neuronal Artificial, verificando mediante pruebas técnicas que los valores de riesgo calculados por el algoritmo correspondieran con las categorías de semaforización esperadas según la escala institucional de calificaciones de la PUCE Ibarra.

Los umbrales de semaforización fueron definidos de manera conservadora: Crítico para puntajes iguales o superiores al 75% y Alerta para puntajes entre el 50% y el 74%. Esta decisión de diseño responde a la necesidad de focalizar la intervención del coordinador en los estudiantes con mayor vulnerabilidad, evitando saturar la interfaz con alertas en casos donde el puntaje de riesgo es moderado. Los estudiantes con puntaje inferior al 50% son clasificados como Seguros y no se despliegan en el listado principal, aunque su conteo total permanece visible en el panel de estadísticas.


2.1.5 Técnicas de recolección de la información

Para la obtención de requerimientos se utilizó la observación directa que permitió analizar el flujo de trabajo manual y los cuellos de botella en la tabulación de datos de Moodle. Además, se realizaron entrevistas semiestructuradas a los coordinadores para definir las funciones críticas del sistema y su impacto en la toma de decisiones.

2.2 Metodología de desarrollo de software

Para la ejecución del proyecto se seleccionó la Metodología en Cascada (Waterfall). Según Pressman (2010), este modelo "sugiere un enfoque sistemático y secuencial para el desarrollo del software, que comienza con la especificación de los requerimientos por parte del cliente y avanza a través de la planeación, el modelado, la construcción y el despliegue" (p. 39). Las fases secuenciales de este modelo se ilustran en la Figura 1.

Figura 1
Metodología de cascada



Nota: El diagrama muestra las etapas secuenciales del modelo de cascada: requisitos, diseño, implementación, pruebas, desarrollo y mantenimiento. Adaptado de Metodología Waterfall | Cómo aplicar la gestión de proyectos en cascada, por Coworkingfy, 2019.

Esta metodología se aplicó de manera estricta para garantizar que la lógica de los Resultados de Aprendizaje (RDA) se implementara bajo estándares de auditabilidad institucional, dividiéndose en las siguientes fases:

2.2.1 FASE I: Análisis de requerimientos y planificación

En esta fase se establecieron las Historias de Usuario (HU) como herramienta fundamental para definir las funcionalidades del sistema desde la perspectiva de los actores institucionales, tal como se detalla en las Tablas 3 y 4. Posteriormente, estas historias se desglosaron en tareas técnicas para estimar el esfuerzo de desarrollo, cuya distribución por sprints se presenta en la Tabla 5.

Tabla 3

Historias de usuario funcionales y no funcionales

IID	Nombre	Esfuerzo (horas)	Importancia	Descripción de historia de usuario	Criterios de aceptación	Dependencias
1	Gestión de Acceso y Roles	8	1000	Como Coordinador Académico, deseo ingresar al sistema mediante autenticación segura para acceder a la información de mi carrera.	- Validación de credenciales en base de datos. - Control de acceso estricto por roles (Administrador/Coordinador).	-
1	Carga y Conciliación de Datos	24	950	Como Administrador, deseo subir archivos de calificaciones extraídos del Aula Virtual (Moodle) y reportes de Banner para centralizar resultados.	- Soporte exclusivo para lectura de archivos .csv y .xlsx. - El sistema debe mapear automáticamente las columnas de Moodle y Banner.	1

3	Motor Predictivo (Red Neuronal)	20	900	Como Sistema, deseo procesar las calificaciones extrasemestrales mediante un modelo predictivo para calcular el riesgo académico.	- Ejecución de algoritmos de ponderación sobre notas. - Persistencia de resultados calculados en la base de datos relacional.	2
4	Dashboard de Monitoreo	24	850	Como Coordinador, deseo visualizar gráficos interactivos del rendimiento estudiantil para facilitar la toma de decisiones oportunas.	- Gráficos reactivos filtrados por periodo y nivel. -Almacenamiento temporal de datos (State Management) para carga rápida.	3
5	Alertas de Riesgo y Auditoría	16	950	Como Coordinador, deseo recibir alertas visuales (semáforo) de bajo rendimiento y detectar discrepancias entre Moodle y Banner.	- Clasificación visual automática (Rojo, Amarillo, Verde). - Registro inmutable de auditoría para trazabilidad de notas.	4
6	Seguridad y Rendimiento	12	800	Como Institución, deseo que el sistema cifre las comunicaciones y responda en tiempos óptimos para proteger la integridad de los datos.	- Implementación de tokens JWT para sesiones.	1

					- Tiempos de respuesta de la interfaz menores a 2 segundos.	
--	--	--	--	--	---	--

Tabla 4

Análisis de las historias de usuario y desglose de tareas

Prioridad	HU	ID Tarea	Descripción de Tareas Técnicas	Esfuerzo (horas)
Alta	1, 6	T1.1	Configuración de arquitectura NestJS y conexión local a MySQL (puerto 3307).	10
Alta	1, 6	T1.2	Implementación de seguridad JWT, encriptación de claves (bcrypt) y guardias de roles.	10
Alta	2	T2.1	Desarrollo del módulo de ingesta de archivos (Multer) y validación de extensiones.	12
Alta	2	T2.2	Implementación del motor de <i>parsing</i> para lectura de lotes de Excel/CSV (Moodle y Banner).	12
Alta	3	T3.1	Diseño algorítmico y programación del Motor Predictivo (Red Neuronal) para cálculo de riesgo.	10
Alta	3	T3.2	Desarrollo de servicios para persistencia y vinculación de resultados en MySQL.	10

Media	4	T4.1	Maquetación de interfaces reactivas en Vue 3 y gestión de estados globales con Pinia.	15
Media	4	T4.2	Integración de librerías gráficas y diseño de filtros dinámicos para los tableros de control.	15
Media	5	T5.1	Programación del sistema de semaforización cualitativa y alertas automáticas de vulnerabilidad.	10
Media	5	T5.2	Implementación del módulo de conciliación de notas y <i>logs</i> de auditoría institucional.	10
Media	6	T6.1	Desarrollo del módulo de generación de reportes técnicos exportables (PDF estructurado y CSV).	14
Baja	Todas	T7.1	Pruebas de integración, validación de rendimiento web y corrección de errores (<i>bugs</i>).	16
TOTAL			Esfuerzo Total Estimado	144 horas

Para la ejecución de la fase de implementación, se ha establecido una jornada de trabajo de 24 horas semanales, distribuidas en 4 horas diarias de lunes a sábado. Bajo este esquema, cada iteración (Sprint) tendrá una duración de una semana calendario, permitiendo completar el esfuerzo total estimado de 144 horas en un periodo de 6 semanas (un mes y medio).

La planificación de la construcción comienza desde las historias de usuario con mayor impacto en la seguridad y la arquitectura base, avanzando secuencialmente según la metodología en cascada definida.

Tabla 5

Distribución de Sprints / Iteraciones de Desarrollo

SPRINT	TAREA TÉCNICA PRINCIPAL
1	Configuración del entorno base (<i>Backend/Frontend</i>), estructuración de base de datos MySQL y sistema de seguridad JWT (T1.1, T1.2).
2	Desarrollo del módulo de carga, validación y motor de lectura de archivos masivos (Moodle/Banner) (T2.1, T2.2).
3	Implementación del Motor Predictivo (Red Neuronal) para el cálculo de RDA y persistencia de datos (T3.1, T3.2).
4	Desarrollo de la interfaz gráfica en Vue 3, integración de <i>stores</i> de Pinia y <i>dashboards</i> interactivos (T4.1, T4.2).
5	Programación de semaforización de riesgo, módulo de conciliación de auditoría y reportes formales (T5.1, T5.2, T6.1).
6	Pruebas finales de estrés, validación de requerimientos no funcionales (tiempos de carga) y despliegue local (T7.1).

Si bien la distribución del trabajo en iteraciones semanales (sprints) podría asociarse a metodologías ágiles, en el presente proyecto estas iteraciones funcionaron como subdivisiones de la fase de implementación dentro del modelo en cascada, sin alterar la secuencialidad característica del modelo: cada fase fue completada y validada antes de proceder a la siguiente, manteniendo la trazabilidad y documentación requeridas para un sistema institucional.

Integración del motor predictivo (red neuronal)

Si bien el planteamiento inicial del proyecto y sus objetivos específicos se orientaban a la centralización, análisis descriptivo y generación de alertas tempranas sobre el seguimiento de los Resultados de Aprendizaje, la etapa de requerimientos reveló la necesidad de dotar al sistema de una capacidad analítica superior. Se identificó que un simple cálculo aritmético de promedios resultaba insuficiente para anticipar de manera efectiva la deserción o el bajo rendimiento en periodos extrasemestrales.


Por consiguiente, como un aporte significativo y diferenciador del presente trabajo de titulación, se decidió integrar un Motor Predictivo basado en la lógica de Redes Neuronales Artificiales (RNA), apoyándose en la arquitectura de un modelo Feedforward (Red Neuronal Prealimentada).

La estructura de este modelo algorítmico se divide en tres capas secuenciales de procesamiento como se ilustra en la Figura 2:

- Capa de Entrada (Input Layer), ingiere los datos brutos extraídos del Aula Virtual, específicamente las calificaciones obtenidas en las asignaturas extrasemestrales y el porcentaje de suficiencia de los RDA.
- Capas Ocultas (Hidden Layers): El algoritmo agrupa los registros por estudiante, pondera el nivel de logro e identifica la calificación más crítica dentro del conjunto de asignaturas evaluadas, calculando un índice de riesgo máximo.
- Capa de Salida (Output Layer): Retorna un valor porcentual de vulnerabilidad académica, el cual es traducido automáticamente por la lógica de negocio en una semaforización visual (Crítico, Alerta, Seguro).

Figura 2

Arquitectura del motor predictivo basado en red neuronal Feedforward



Nota: El diagrama representa el flujo de datos unidireccional (Feedforward) desde la ingesta de notas del Aula Virtual hasta la clasificación del riesgo académico.

Para dotar al motor predictivo de la capacidad de inferir el riesgo académico, se diseñó un conjunto de entrenamiento supervisado compuesto por diez pares de ejemplos, cantidad suficiente dado que el problema no requiere descubrir patrones ocultos en datos ruidosos, sino aproximar una función matemática ya definida por la escala institucional de calificaciones. Los pares se distribuyeron estratégicamente cubriendo los extremos del rango (0 y 50 puntos) y los umbrales críticos entre cada equivalencia cualitativa (29-30, 39-40 y 44-45 puntos), garantizando que la red interpole correctamente cualquier nota intermedia. Cada par asocia una nota de entrada, normalizada al rango $[0, 1]$, con un valor de riesgo de salida esperado entre 0 (sin riesgo) y 1 (riesgo máximo), respetando los umbrales cualitativos establecidos por la PUCE Ibarra: notas inferiores a 30 puntos (equivalencia D) se asocian a niveles de riesgo superiores al 75%; notas entre 30 y 39 puntos (equivalencia C) a niveles entre el 30% y el 55%; notas entre 40 y 44 puntos (equivalencia B) a niveles entre el 10% y el 30%; y notas de 45 puntos o más (equivalencia A) a niveles inferiores al 10%.

El algoritmo de aprendizaje implementado fue la retropropagación del error (backpropagation), seleccionada por ser el algoritmo de optimización estándar para redes

Feedforward supervisadas, dado que permite ajustar los pesos de todas las capas de manera eficiente mediante el cálculo del gradiente del error respecto a cada parámetro, propagando la señal de corrección desde la capa de salida hacia la capa de entrada en cada iteración. El entrenamiento se ejecutó durante 3.000 iteraciones con una tasa de aprendizaje de 0,15, valor determinado mediante un proceso de ajuste empírico: tasas inferiores a 0,10 resultaron en una convergencia excesivamente lenta sin alcanzar un error mínimo aceptable en 3.000 iteraciones, mientras que tasas superiores a 0,30 produjeron oscilaciones en el error que impedían la estabilización del modelo. El valor de 0,15 demostró el equilibrio óptimo entre velocidad de convergencia y estabilidad del entrenamiento para el conjunto de datos utilizado.

La función de activación utilizada en todas las capas fue la función sigmoide, seleccionada por tres razones fundamentales: primero, su rango de salida acotado al intervalo (0, 1) es matemáticamente coherente con la interpretación del resultado como un puntaje de riesgo académico; segundo, su derivada continua y diferenciable en todos los puntos es un requisito indispensable para la aplicación del algoritmo de retropropagación; y tercero, su comportamiento no lineal permite a las neuronas de la capa oculta capturar la relación no proporcional entre la nota del estudiante y su nivel de vulnerabilidad académica, especialmente en los umbrales de cambio entre equivalencias. La arquitectura de la red fue definida como 1-4-1: una neurona de entrada que recibe la nota promedio normalizada, cuatro neuronas en la capa oculta encargadas de capturar la no linealidad de la relación entre calificación y riesgo, y una neurona de salida que retorna el porcentaje de vulnerabilidad académica.

En la fase de inferencia, el sistema agrupa los registros del lote seleccionado por estudiante y código NRC, calcula el promedio aritmético de los RDA disponibles independientemente de si se han cargado uno, dos o tres resultados, normaliza dicho promedio al rango [0, 1] y lo procesa a través de la red entrenada. El valor de salida es interpretado como puntaje de riesgo y traducido automáticamente en semaforización: un riesgo igual o superior al 75% corresponde al nivel Crítico (Rojo), entre el 50% y el 74% al nivel Alerta (Amarillo), e inferior al 50% al nivel Seguro (Verde). Cabe destacar que la red neuronal fue implementada desde cero en TypeScript, prescindiendo de librerías externas de aprendizaje automático, lo que garantizó la compatibilidad total con el

entorno de ejecución Node.js y eliminó dependencias de compilación nativa que resultaban incompatibles con el servidor de desarrollo institucional.

2.2.2 FASE II: Diseño del sistema

En esta fase se tradujeron los requerimientos institucionales y las historias de usuario en especificaciones técnicas formales. Se diseñó una arquitectura de software desacoplada utilizando el patrón API RESTful, estableciendo una clara separación entre la capa de presentación, desarrollada en Vue.js, y la lógica de negocio procesada mediante NestJS. Asimismo, se definió la estructura de persistencia de datos en el motor MySQL. Durante esta etapa se elaboraron los modelos funcionales (diagramas de Casos de Uso) y los modelos de datos (Entidad-Relación) para garantizar la integridad, trazabilidad y auditabilidad de la información académica correspondiente a las carreras repotenciadas de la PUCE Ibarra.

Arquitectura tecnológica del sistema

Para garantizar la escalabilidad y el rendimiento óptimo del sistema inteligente, el diseño arquitectónico se estructuró en tres capas principales:


- Capa de Presentación (Frontend): Diseñada como una Single Page Application (SPA) utilizando Vue.js (versión 3) y la API de Composición. Se implementó la librería Pinia para la gestión del estado global (State Management), lo que permite almacenar temporalmente en memoria los cálculos de riesgo de la red neuronal, evitando consultas redundantes al servidor y garantizando una navegación fluida en los tableros de control.
- Capa de Lógica de Negocio (Backend): Construida sobre el framework NestJS (Node.js). Esta capa actúa como el núcleo inteligente del sistema. Expone los endpoints seguros mediante autenticación JWT (JSON Web Tokens) y aloja el Motor Predictivo encargado de procesar las calificaciones extrasemestrales.
- Capa de Datos (Database): Se diseñó un modelo relacional utilizando MySQL. Esta base de datos almacena los expedientes unificados, los resultados de aprendizaje calculados y mantiene un registro estricto de auditoría para las conciliaciones académicas.

Modelado funcional: especificación de casos de uso

Para comprender la arquitectura lógica del Sistema Inteligente de Gestión de RDA, es necesario mapear las interacciones fundamentales entre los usuarios y los procesos automatizados. El modelado de casos de uso permite visualizar cómo la plataforma integra la gestión administrativa convencional con la ejecución del motor predictivo, asegurando que cada acción deje un rastro verificable en el sistema. A continuación, en la Figura 3, se presenta la representación gráfica general de estos flujos operativos.

Figura 3

Diagrama de casos de uso del sistema de gestión RDA (PUCE-I)



Nota. El diagrama representa las interacciones operativas y predictivas de los actores con la plataforma.

Como se evidencia en la Figura 3, el sistema delimita claramente los permisos según los roles establecidos. A partir de esta arquitectura visual, se definieron los Casos de Uso (CU) principales, los cuales detallan las precondiciones, el flujo transaccional y las respuestas del sistema. A continuación, en las Tablas 6, 7, 8, 9 y 10 se presenta la especificación técnica de cada proceso.

Tabla 6

CU-01 Iniciar Sesión (JWT)

Elemento	Descripción
Nombre del Caso de Uso	CU-01: Iniciar Sesión (JWT)
Actor Principal	Administrador de Sistema / Coordinador Académico
Descripción	Permite al usuario acceder de forma segura a la plataforma web validando sus credenciales de acceso para gestionar los expedientes.
Precondiciones	El usuario debe estar registrado en la base de datos MySQL. El servidor backend en NestJS y la base de datos deben estar en ejecución.
Flujo Principal	1. El actor ingresa a la URL de la plataforma desde su navegador. 2. El sistema presenta el formulario de inicio de sesión. 3. El actor ingresa su correo electrónico institucional y contraseña. 4. El frontend (Vue.js) envía la petición HTTP al servidor NestJS. 5. El servidor valida las credenciales y retorna un Token JWT. 6. El sistema redirige al actor al <i>Dashboard</i> principal correspondiente a su rol.
Flujos Alternativos	Paso 5a: Si las credenciales son incorrectas, el servidor retorna un código HTTP 401. El frontend muestra una alerta de "Credenciales inválidas" y vacía el campo de contraseña.
Postcondiciones	Se establece una sesión activa y segura, permitiendo la navegación en módulos internos.

Tabla 7

CU-02 Gestionar Usuarios (CRUD)

Elemento	Descripción
Nombre del Caso de Uso	CU-02: Gestionar Usuarios (CRUD)
Actor Principal	Administrador de Sistema
Descripción	Permite al administrador crear, leer, actualizar y desactivar las cuentas de los Coordinadores Académicos.
Precondiciones	El actor debe estar autenticado con el rol de "Administrador" (CU-01).
Flujo Principal	1. El actor ingresa al módulo de "Gestión de Usuarios". 2. El sistema despliega la lista actual de coordinadores registrados. 3. El actor selecciona "Nuevo Usuario". 4. El actor ingresa los datos y asigna el rol de "Coordinador". 5. El servidor encripta la contraseña y almacena el registro en la base de datos relacional. 6. El sistema confirma la creación y actualiza la lista en pantalla.
Flujos Alternativos	Paso 4a: Si el correo ingresado ya existe, el sistema bloquea la acción indicando duplicidad. Paso 2a: El actor selecciona un usuario existente y cambia su estado a "Inactivo" para revocar acceso.
Postcondiciones	La tabla de usuarios queda actualizada y los nuevos coordinadores pueden iniciar sesión.

Tabla 8

CU-03 Cargar Lotes Aula Virtual (Moodle)

Elemento	Descripción
Nombre del Caso de Uso	CU-03: Cargar Lotes del Aula Virtual (Moodle)
Actor Principal	Coordinador Académico
Descripción	Permite subir archivos CSV con calificaciones extrasemestrales en bruto para su posterior procesamiento.
Precondiciones	El actor debe haber iniciado sesión (CU-01). El archivo CSV debe mantener las cabeceras originales del Aula Virtual.
Flujo Principal	1. El actor navega al módulo de carga de datos. 2. El actor adjunta el archivo CSV de calificaciones extrasemestrales. 3. El servidor NestJS recibe el archivo y ejecuta el algoritmo de <i>parsing</i> 4. Se normalizan los campos y se persisten en la base de datos. 5. Se registra el evento en el log de auditoría (texto plano). 6. El sistema notifica la carga exitosa.
Flujos Alternativos	Paso 3a: Si el archivo tiene un formato inválido o carece de las columnas requeridas, el sistema cancela la ingesta y muestra un mensaje de error estructural.
Postcondiciones	Los expedientes quedan almacenados de forma estructurada, listos para la predicción.

Tabla 9

CU-05 Visualizar Dashboard de RDA

Elemento	Descripción
Nombre del Caso de Uso	CU-05: Visualizar Dashboard de RDA
Actor Principal	Coordinador Académico
Descripción	Presenta la información procesada a través de representaciones gráficas interactivas para el análisis institucional.
Precondiciones	El motor predictivo debe haber generado resultados (CU-04).
Flujo Principal	1. El actor ingresa a la sección "Dashboard" en la interfaz reactiva. 2. El frontend solicita las métricas consolidadas al servidor NestJS. 3. El sistema renderiza gráficos de barras y pastel resumiendo la suficiencia académica general de la cohorte extrasemestral. 4. El actor interactúa con las gráficas para filtrar datos por paralelo o asignatura.
Flujos Alternativos	Paso 2a: Si no hay datos procesados, el <i>dashboard</i> muestra un estado en blanco sugiriendo la carga de un lote del Aula Virtual.
Postcondiciones	El coordinador obtiene una vista panorámica del rendimiento académico.

Tabla 10

CU-10 Notificar Alerta a Estudiante

Elemento	Descripción
Nombre del Caso de Uso	CU-10: Notificar Alerta a Estudiante
Actor Principal	Coordinador Académico
Descripción	Permite al coordinador accionar el envío automatizado de una notificación por correo electrónico al estudiante directamente desde el módulo de Predicción IA, tras calcularse un nivel de riesgo académico alto o moderado
Precondiciones	El actor debe encontrarse en la vista de resultados del Motor Predictivo (CU-04) con los datos del estudiante evaluados en tiempo real.
Flujo Principal	1. El actor revisa el resultado arrojado por la Red Neuronal para un estudiante específico. 2. El actor hace clic en el botón de notificación integrado en el panel de predicción. 3. El entorno reactivo (Vue.js) envía la solicitud de despacho al servidor 4. El backend (NestJS) ensambla la plantilla de correo predefinida con el texto de advertencia. 5. El servidor ejecuta el envío a través del protocolo SMTP. 6. El sistema registra la acción en el log de auditoría en texto plano. 7. La interfaz despliega un mensaje de confirmación de envío exitoso.
Flujos Alternativos	Paso 5a: Ante una interrupción del servicio SMTP, el servidor captura la excepción y el sistema notifica al actor la imposibilidad de enviar el correo en ese instante.
Postcondiciones	El sistema establece un registro de intervención preventiva oportuna para el estudiante analizado.

Modelado de datos


Para garantizar la integridad, consistencia y trazabilidad de la información académica, se diseñó un modelo de base de datos relacional estructurado para el motor MySQL. El esquema se normalizó para evitar la redundancia de datos y soportar eficientemente las consultas del motor predictivo y los procesos de conciliación.

El diseño físico de la base de datos contempla la gestión de accesos (usuarios y roles), el almacenamiento de las calificaciones en bruto extraídas del Aula Virtual (tablas de paso) y la persistencia temporal de los reportes oficiales de Banner. Asimismo, integra una entidad transaccional (*predicciones_ia*) diseñada específicamente para almacenar el historial de riesgo máximo calculado por la Red Neuronal y su respectiva semaforización cualitativa.

Cabe destacar que, como medida de aseguramiento de la información y optimización del rendimiento del motor de base de datos, el registro de auditoría (logs de trazabilidad) no se almacena de forma relacional. En su lugar, el sistema genera archivos de texto plano encriptados directamente en el servidor, garantizando que el historial de acciones sea inmutable frente a posibles inyecciones SQL. El modelo relacional resultante se ilustra en la Figura 4.

Figura 4

Diagrama Relacional de la Base de Datos del Sistema




Nota: El diagrama ilustra el modelo físico y la estructura relacional normalizada generada en el motor MySQL, destacando la interconexión entre los usuarios y los módulos de predicción.

Diseño dinámico: diagrama de secuencia del motor predictivo

Para ilustrar la interacción en tiempo real entre las distintas capas de la arquitectura del software, se modeló el flujo de información correspondiente a la ejecución del motor predictivo. Este diagrama evidencia la eficiencia del patrón API RESTful, donde la interfaz reactiva (Vue.js) se comunica de forma asíncrona con el servidor lógico (NestJS), el cual a su vez consulta la base de datos (MySQL) e invoca los algoritmos de la Red Neuronal para retornar una respuesta procesada, tal como se ilustra en la Figura 5.

Figura 5

Diagrama de secuencia: cálculo de riesgo y semaforización



Nota: El diagrama detalla la comunicación asíncrona entre el cliente, el servidor y el gestor de base de datos durante el procesamiento de los resultados extrasestrales mediante el motor predictivo.

2.2.3 FASE III: Implementación

Consistió en la escritura del código fuente. Se utilizó NestJS para el backend, implementando la lógica "inteligente" de cálculo de suficiencia y seguridad con JWT. En el frontend, se desarrolló la Single Page Application (SPA) con Vue.js, consumiendo los servicios del API para mostrar dashboards dinámicos.

Configuración del entorno de desarrollo

Para la construcción del sistema inteligente, se preparó un entorno de trabajo local que soportara las arquitecturas seleccionadas. El motor de base de datos MySQL se configuró y levantó localmente a través del puerto 3307, aislando el entorno de pruebas de otras instancias operativas. Para la gestión de dependencias y ejecución de los frameworks, se utilizó el entorno de ejecución Node.js, el cual permitió inicializar tanto el servidor backend mediante NestJS CLI, como el empaquetador del frontend para Vue.

Desarrollo del backend y lógica de negocio (NestJS)

El núcleo del sistema se desarrolló utilizando NestJS, aprovechando su estructura basada en decoradores y módulos para crear una API RESTful robusta. La implementación de esta capa se dividió en tres componentes críticos:

- **Módulo de Seguridad y Autenticación:** Se programaron guardias de rutas (Guards) y estrategias de validación utilizando JSON Web Tokens (JWT).
- **Motor de Ingesta y Auditoría:** Se implementaron servicios con la librería Multer para la recepción segura de archivos masivos. Además, se codificó el generador de logs en texto plano directamente en el servidor.
- **Implementación del Motor Predictivo:** Se materializó el diseño lógico de la Red Neuronal Artificial en algoritmos de procesamiento asíncrono implementados desde cero en TypeScript, sin dependencias de librerías externas de aprendizaje automático. La red fue configurada con los siguientes parámetros clave: arquitectura 1-4-1 (una neurona de entrada, cuatro neuronas en la capa oculta y una neurona de salida), función de activación sigmoide en todas las capas, tasa de aprendizaje de 0,15 y 3.000 iteraciones de entrenamiento mediante el algoritmo de retropropagación del error. Los pesos iniciales de la red se asignaron aleatoriamente y fueron ajustados durante el entrenamiento con diez pares de ejemplos supervisados basados en la escala institucional de calificaciones. En la fase de inferencia, el código ingiere el promedio de los RDA disponibles por estudiante y NRC, lo normaliza al rango [0,1] y lo procesa a través de la red entrenada, devolviendo una variable categórica de vulnerabilidad académica (Crítico, Alerta, Seguro).

Desarrollo del frontend e interfaces reactivas (Vue.js)

La interfaz de usuario se construyó utilizando Vue.js en su versión 3, empleando la API de Composición (Composition API) para garantizar un código limpio y modular. El desarrollo se centró en la usabilidad y el rendimiento para el Coordinador Académico:

- **Gestión de Estados Globales:** Para optimizar el rendimiento del sistema, se implementó la librería Pinia. Esto permitió almacenar en la memoria del navegador los resultados del cálculo predictivo (semaforización) y los datos del usuario. De esta forma, el dashboard interactivo puede cambiar de vistas y filtrar información en tiempo real sin necesidad de saturar al servidor con peticiones redundantes.

Tableros de Control: Se codificaron componentes visuales que consumen las respuestas de la API y las transforman en gráficos interactivos. Estos tableros traducen los datos técnicos del motor predictivo en alertas visuales claras, permitiendo a la coordinación académica identificar instantáneamente a los estudiantes que requieren intervención urgente.

2.2.4 FASE IV: Verificación

Cumpliendo con la secuencialidad de la Metodología en Cascada, una vez finalizada la codificación, se procedió a la fase de verificación y validación. El objetivo principal de esta etapa fue garantizar que el sistema cumpliera con los requerimientos funcionales e institucionales, asegurando la integridad de las calificaciones extraídas del Aula Virtual y el correcto despliegue de las alertas predictivas.

Para lograr una evaluación integral que asegurara la confiabilidad de los datos, la usabilidad del sistema y su aporte a la mejora de los procesos de seguimiento académico, se planificó la aplicación de dos enfoques complementarios de testing de software. El primero, las pruebas de caja blanca, orientadas a la validación de la estructura interna del código, la seguridad de los endpoints y la lógica algorítmica del motor predictivo en el servidor (backend en NestJS), mediante herramientas de testeo de APIs. El segundo, las pruebas de caja negra, enfocadas en la evaluación del sistema desde la perspectiva del usuario final (Coordinador Académico), verificando la funcionalidad de las interfaces construidas en Vue.js ante escenarios de error y éxito. Los resultados detallados de la ejecución de ambos protocolos de validación, incluyendo los casos de prueba ejecutados y sus resultados, se presentan en el Capítulo III.

Para la planificación de las pruebas se definieron ocho casos de prueba formales, distribuidos en ambos enfoques: cuatro casos de caja negra (CP-01 a CP-04) orientados a validar el control de acceso, la carga de archivos, la edición en línea de calificaciones y el envío de notificaciones por correo electrónico; y cuatro casos de caja blanca (CP-05 a CP-08) orientados a auditar la estructuración y normalización de datos en el backend, la ejecución y precisión del motor predictivo, la seguridad de los endpoints mediante JWT, y la lógica de conciliación RDA por RDA entre Moodle y Banner. Los resultados de cada caso de prueba se documentan en el Capítulo III mediante matrices de prueba estandarizadas

2.2.5 FASE V: Despliegue y mantenimiento

La última etapa de la metodología consistió en la preparación del sistema para su entrega formal. Durante la fase de despliegue, el software (tanto la SPA del frontend como la API del backend y el esquema de la base de datos MySQL) se empaquetó y documentó para asegurar su portabilidad hacia los entornos de producción o servidores locales de la PUCE Ibarra. Además, se definieron los lineamientos de mantenimiento, los cuales contemplan el respaldo físico de los archivos de texto plano que contienen los logs de auditoría y la actualización periódica de las librerías dependientes de Node.js para mitigar vulnerabilidades de seguridad a futuro.

CAPÍTULO III

RESULTADOS Y DISCUSIÓN

En el presente capítulo se exponen los resultados obtenidos tras la implementación operativa del Sistema Inteligente de Gestión de Resultados de Aprendizaje (RDA). Se detallan las evidencias del funcionamiento de la plataforma web, evaluando de forma específica el rendimiento del motor predictivo durante el procesamiento de las calificaciones correspondientes a un periodo académico real. A través de la presentación de estas métricas y pruebas de usabilidad, se valida el cumplimiento de los requerimientos institucionales y técnicos planteados inicialmente para las carreras repotenciadas.

Asimismo, se desarrolla una discusión analítica de los hallazgos, contrastando la eficacia de la nueva arquitectura tecnológica y el modelo algorítmico frente a los métodos de seguimiento tradicionales. Se demuestra cómo la centralización segura de la información y la generación automática de alertas semaforizadas impactan directamente en la capacidad de la coordinación académica para tomar decisiones preventivas ante el riesgo de bajo rendimiento estudiantil.

3.1 Despliegue operativo por módulos del sistema

Para validar el cumplimiento de los requerimientos técnicos y la correcta operatividad de la plataforma, se documenta el despliegue de las interfaces gráficas construidas en el entorno reactivo (Vue.js) y su interacción con los flujos de procesamiento en el servidor (NestJS). El diseño arquitectónico del sistema se estructuró en módulos especializados, garantizando la optimización del tiempo administrativo y la automatización del seguimiento de los Resultados de Aprendizaje (RDA).


3.1.1 Módulo de autenticación y control de acceso

El recorrido operativo del sistema inicia con el entorno de seguridad perimetral. Este módulo, desarrollado en el frontend con Vue.js, exige la validación estricta de credenciales institucionales antes de permitir la visualización de cualquier ruta interna. A nivel de servidor, NestJS procesa la petición contra la base de datos relacional mediante la librería bcrypt para la verificación de contraseñas, y en caso de éxito, emite un token criptográfico (JWT) con un tiempo de expiración de dos horas. Adicionalmente, todos los

endpoints de la API REST se encuentran protegidos mediante guardias de autenticación (Guards), los cuales verifican la validez del token en cada petición y rechazan con un código de estado 401 cualquier solicitud no autorizada. Esta arquitectura garantiza que únicamente el personal autorizado, ya sea con rol de Administrador o Coordinador Académico, pueda acceder a los recursos del sistema, salvaguardando la confidencialidad de la información académica. La interfaz de inicio de sesión se presenta en la Figura 6.

Figura 6

Módulo de Autenticación




Nota: Interfaz de autenticación segura para el control de acceso al sistema institucional.

3.1.2 Módulo de administración de usuarios

Inmediatamente después del control de acceso, se despliega el entorno de administración centralizada, habilitado exclusivamente para el rol de Administrador de Sistema. Este módulo permite la gestión completa (creación, lectura, actualización y desactivación) de las credenciales de los Coordinadores Académicos, almacenando las contraseñas mediante hash bcrypt de diez rondas. La automatización de este control de usuarios centraliza la asignación de permisos y evita la manipulación no autorizada de las vistas operativas y predictivas, como se observa en la Figura 7.

Figura 7

Módulo de Administración de Usuarios




Nota: Entorno administrativo para la gestión de roles y credenciales operativas.

3.1.3 Módulo de carga de Moodle

Este entorno representa el punto de entrada de la información del sistema. El Coordinador Académico accede a esta interfaz para realizar la ingesta de los archivos en bruto exportados directamente del Aula Virtual institucional, en formato CSV. El motor de procesamiento del backend filtra automáticamente las filas correspondientes a los ítems de evaluación denominados "RDA 1", "RDA 2" y "RDA 3" dentro del campo itemname del archivo, descartando el resto de columnas no relevantes para el seguimiento de Resultados de Aprendizaje. La implementación de este módulo elimina la dependencia de la transcripción manual, logrando una automatización en la estructuración y persistencia de las calificaciones dentro de la base de datos MySQL, preparando el terreno para el análisis posterior. El módulo de carga, junto con el historial de lotes procesados, se muestra en la Figura 8.

Figura 8

Módulo de Carga Moodle



Nota: Interfaz operativa utilizada por la coordinación académica para la carga masiva de registros del entorno virtual.

Como evidencia del funcionamiento de este módulo, se procesó un archivo correspondiente a un periodo académico, obteniendo un total de 26.057 registros de evaluación, distribuidos en 1.383 estudiantes únicos matriculados en distintas asignaturas y NRC de las carreras repotenciadas.

El lote de validación correspondió a un archivo exportado del Aula Virtual institucional que incluyó registros de múltiples carreras repotenciadas, NRC y paralelos activos del periodo evaluado. De los 26.057 registros totales, se filtraron únicamente las filas correspondientes a los ítems de evaluación denominados RDA 1, RDA 2 y RDA 3, descartando el resto de actividades evaluativas. Los 1.383 estudiantes únicos identificados presentaron entre uno y tres RDA cargados por asignatura, dependiendo del avance del periodo al momento de la exportación.


3.1.4 Módulo de resumen global

Diseñado como el tablero de control principal de analítica descriptiva, este entorno opera de manera independiente al motor de inteligencia artificial. Su actualización se ejecuta en tiempo real desde el momento exacto en que el coordinador finaliza la carga en el módulo anterior. Su función técnica es proporcionar una

visualización inmediata de los registros en bruto, calculando el promedio de los RDA disponibles por estudiante y exponiendo métricas generales mediante gráficos de pastel y de barras. Esta inmediatez visual garantiza la transparencia de los datos y dota a la coordinación de una herramienta ágil para la revisión preliminar de los expedientes, tal como se ilustra en la Figura 9.

Figura 9

Módulo de Resumen Global



Nota: Tablero descriptivo que consolida la distribución de estudiantes por calificación obtenida (equivalencias A, B, C y D), la proporción de aprobación general de la cohorte y la proporción de RDA aprobados por nivel.

El lote de prueba analizado correspondió a un archivo de calificaciones exportado del Aula Virtual institucional de las carreras repotenciadas de la PUCE Ibarra, proporcionado por la coordinación académica para efectos de validación del sistema. Los resultados revelan una distribución marcadamente concentrada en los niveles de riesgo y reprobación: apenas el 12,2 % de la cohorte (169 de 1.383 estudiantes) alcanzó niveles de aprobación con equivalencias A y B, mientras que el 57,8 % se ubicó en nivel de riesgo con equivalencia C y el 29,9 % en nivel de reprobación con equivalencia D. Esta distribución, que concentra al 87,7 % de la cohorte en niveles C o D, confirma la pertinencia institucional de un sistema de alertas tempranas que permita identificar y notificar a los estudiantes en situación de vulnerabilidad antes del cierre del periodo académico.

3.1.5 Módulo de predicción IA (alertas tempranas)

Constituye el núcleo analítico de la plataforma y el entorno donde opera la Red Neuronal Artificial descrita de manera teórica. A diferencia del módulo de Resumen Global, este componente fue diseñado para operar de manera incremental durante el periodo académico ordinario: el coordinador puede ejecutar el análisis preventivo en cualquier momento, ya sea con uno, dos o los tres RDA cargados, sin necesidad de esperar al cierre del periodo. El sistema agrupa los registros por estudiante y NRC, calcula el promedio de los RDA disponibles en ese instante y procesa dicho valor a través de la red neuronal entrenada para inferir un porcentaje de riesgo académico.

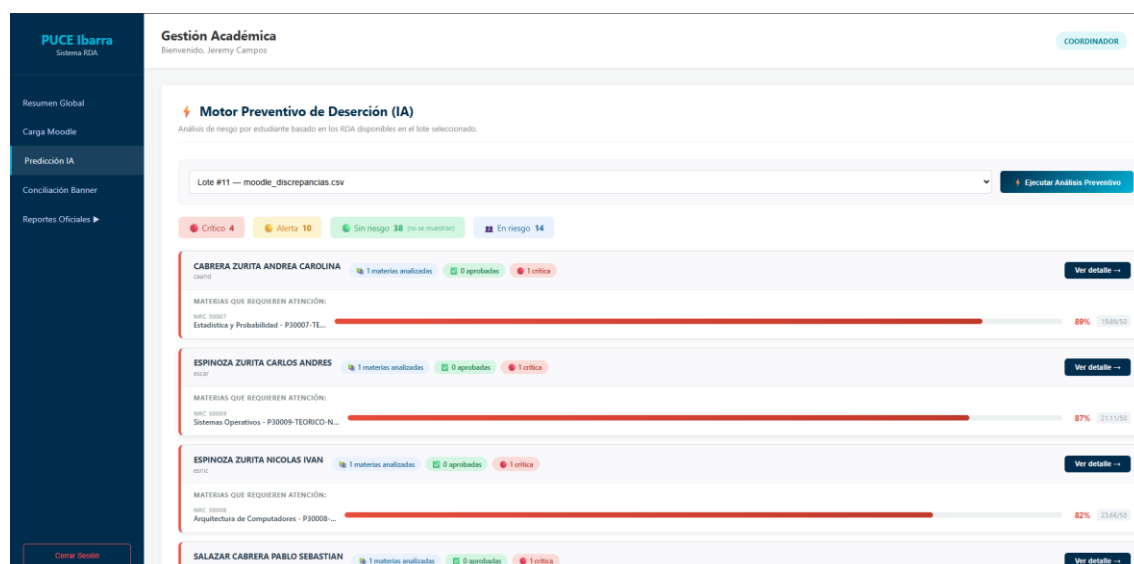
Con el objetivo de optimizar la experiencia del coordinador, la interfaz filtra automáticamente los resultados, presentando únicamente a los estudiantes cuyo nivel de riesgo corresponde a los semáforos Crítico (Rojo) o Alerta (Amarillo). Los estudiantes clasificados en el nivel Seguro (Verde) no se despliegan en el listado principal, dado que no requieren intervención inmediata por parte de la coordinación; no obstante, su número total se mantiene visible en el panel de estadísticas para conocimiento del coordinador.

La ejecución del motor predictivo sobre el lote de validación de 1.383 estudiantes permitió obtener los siguientes indicadores de funcionamiento: el modelo clasificó a 990 estudiantes (71,6 %) en nivel Crítico, correspondiente a un porcentaje de riesgo igual o superior al 75 %; a 169 estudiantes (12,2 %) en nivel Alerta, con riesgo entre el 50 % y el 74 %; y a 224 estudiantes (16,2 %) en nivel Seguro, con riesgo inferior al 50 %. En total, el sistema clasificó a 1.159 estudiantes (83,8 % de la cohorte) como candidatos a intervención preventiva por parte de la coordinación académica. Estos resultados evidencian la capacidad del motor de clasificación para procesar lotes de datos reales y generar distribuciones de riesgo coherentes con los umbrales institucionales de calificaciones, operando de manera eficiente sobre un volumen de 26.057 registros individuales de evaluación. Cabe precisar que este porcentaje representa la distribución de clasificación generada por el sistema según la escala institucional, y no constituye una métrica de precisión del modelo, dado que el motor no fue validado con etiquetas históricas de aprobación o reprobación real.

La Figura 10 presenta el tablero del motor predictivo.

Figura 10

Módulo de Predicción IA



Nota: Entorno de ejecución predictiva, mostrando únicamente a los estudiantes que requieren atención preventiva.

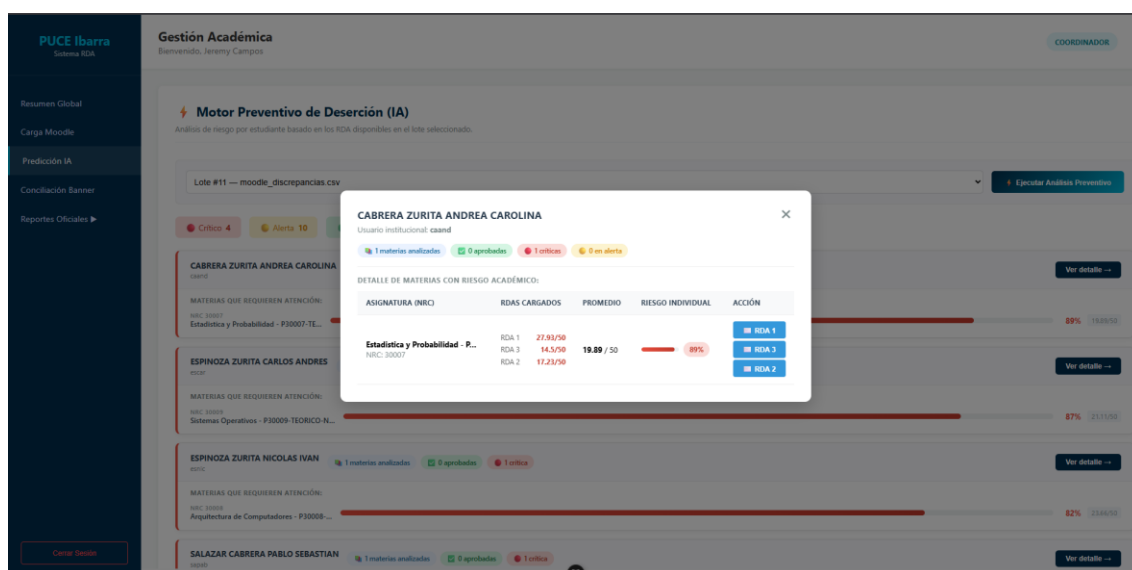
Sobre el mismo lote de 1.383 estudiantes, la ejecución del motor predictivo determinó que 990 estudiantes (71,6 %) presentaron al menos una asignatura clasificada en nivel Crítico, 169 estudiantes (12,2 %) presentaron asignaturas en nivel Alerta, sumando un total de 1.159 estudiantes (83,8 %) que requieren algún tipo de seguimiento preventivo. Los restantes 224 estudiantes (16,2 %) fueron clasificados en nivel Seguro y no se despliegan en la interfaz, al no representar riesgo de reprobación según el modelo predictivo.

Como indicadores de rendimiento del modelo Feedforward, se verificó la coherencia entre el valor de salida de la red y la clasificación esperada según la escala institucional: estudiantes con promedio inferior a 30 puntos (equivalencia D) obtuvieron valores de riesgo superiores a 0,75, siendo correctamente clasificados en nivel Crítico; estudiantes con promedio entre 30 y 39 puntos (equivalencia C) obtuvieron valores entre 0,30 y 0,55, clasificados en nivel Alerta o Crítico según el caso; y estudiantes con promedio de 40 puntos o más (equivalencias A y B) obtuvieron valores inferiores a 0,30, clasificados correctamente en nivel Seguro. Esta verificación cruzada entre la salida numérica del modelo y la semaforización visual confirmó que el motor predictivo opera de manera coherente con los umbrales institucionales definidos durante el entrenamiento.

Al hacer clic sobre cualquier estudiante del listado, el sistema despliega un panel de detalle que desagrega su situación por cada asignatura (NRC), mostrando las notas individuales de cada RDA cargado, el promedio calculado y el porcentaje de riesgo correspondiente. Desde este panel, el coordinador dispone de un botón de notificación que, al ser activado, ejecuta el envío automático de un correo electrónico de alerta temprana al estudiante, a través de un servicio de mensajería SMTP integrado en el backend. El sistema mantiene además un registro local de las notificaciones ya enviadas durante la sesión, evitando el envío duplicado de alertas. Este flujo se ilustra en la Figura 11.

Figura 11

Panel de Detalle y Notificación al Estudiante



Nota: Panel de desagregación por asignatura y herramienta de notificación automatizada vía correo electrónico.

3.1.6 Módulo de conciliación banner

Debido a la naturaleza del sistema institucional Banner, el cual exporta únicamente la calificación literal final por cada Resultado de Aprendizaje sin granularidad numérica, se desarrolló este módulo específico de validación. Su objetivo es cruzar la información detallada extraída de Moodle, procesada y convertida a su equivalencia cualitativa (A, B, C o D) mediante la escala institucional, con el resultado oficial registrado en Banner, comparando de manera individual cada Resultado de Aprendizaje: RDA 1 contra RDA 1, RDA 2 contra RDA 2 y RDA 3 contra RDA 3.

El cruce de los registros se realiza mediante la combinación del nombre de usuario institucional (extraído del correo electrónico del estudiante) y el código NRC de la asignatura. Para cada coincidencia encontrada, el sistema determina si las equivalencias cualitativas de Moodle y Banner son iguales para cada RDA; en caso de existir al menos una diferencia, el registro se marca con el estado "Discrepancia". Los registros para los cuales no existe una contraparte en el archivo de Banner se identifican bajo el estado "Sin Banner", permitiendo al coordinador distinguir entre errores de digitación, asignaturas pendientes de cierre en el sistema institucional y discrepancias reales en la calificación. Esta interfaz se presenta en la Figura 12.

Figura 12

Módulo de Conciliación Banner

Carga de Reporte Oficial (Banner)
 Importe el archivo CSV de calificaciones oficiales exportado desde Banner.

Haga clic para seleccionar archivo CSV de Banner

Historial de Lotes Banner 3 lotes
 Archivos del sistema institucional Banner procesados y disponibles para conciliación.

ID Lote	Archivo Banner	Registros	Fecha de Carga
#13	banner_discrepancias.csv	60	---
#12	banner_coincide.csv	60	---
#8	3. Reporte de calificaciones Carrera_Programa y asistencias por estudiante Antes de Paso Historia Académica - Escala R(Reportencias) - CSV_20260528_095442.csv	3,053	---

Auditoría y Conciliación de Notas — RDA por RDA
 Cruce automatizado entre Moodle y Banner comparando cada RDA individualmente.

1. Lote de Moodle: -- Seleccione un Lote --

2. Lote de Banner: -- Seleccione un Lote --

Ejecutar Conciliación

Nota: Interfaz de auditoría cruzada RDA por RDA entre el entorno virtual y el sistema de registro institucional.

Como prueba de funcionamiento del motor de cruce, se procesaron archivos de Moodle y de Banner correspondientes a periodos académicos distintos, lo cual permitió validar que el algoritmo de cruce basado en usuario institucional y NRC, opera correctamente: los registros para los cuales no existió coincidencia de periodo fueron correctamente identificados bajo el estado "Sin Banner" (S/D), mientras que el único registro coincidente en NRC entre ambos archivos fue clasificado correctamente bajo el estado "Coincide". Esta prueba confirmó la robustez del algoritmo de cruce ante escenarios de datos incompletos o de distinto origen temporal, validando su

comportamiento esperado para el escenario real de uso, en el cual ambos archivos corresponderán al mismo periodo académico.

3.1.7 Reportes Oficiales - Alertas tempranas IA

El sistema trasciende la visualización en pantalla mediante la generación automatizada de documentación formal exportable en formato PDF. Este submódulo compila y exporta el listado oficial de los estudiantes semaforizados con riesgo Crítico o Alerta por el motor predictivo, funcionando como el respaldo institucional de las alertas detectadas a tiempo por la coordinación académica, como se observa en la Figura 13.

Figura 13

Módulo de Reportes Oficiales: Alertas Tempranas IA

Usuario	Estudiante	Asignatura (NIC)	RDA 1	RDA 2	RDA 3	Promedio	Rango	Nivel
caand	CABRERA ZURITA ANDREA CAROLINA	Estadística y Probabilidad - P30007... NIC 30007	27.83	17.23	14.5	19.89/50	89%	Crítico
oscar	ESPINOZA ZURITA CARLOS ANDRES	Sistemas Operativos - P30009-TEORIC... NIC 30009	10.83	31.06	19.44	21.11/50	87%	Crítico
enric	ESPINOZA ZURITA NICOLAS IVAN	Arquitectura de Computadores - P300... NIC 30008	10.47	13.8	46.7	23.66/50	82%	Crítico
sapab	SALAZAR CABRERA PABLO SEBASTIAN	Gestión de Proyectos de TI - P30010... NIC 30010	15.87	17.4	45.31	25.93/50	76%	Crítico
gului	GUERRERO ESPINOZA LUIS MIGUEL	Arquitectura de Computadores - P300... NIC 30008	11.71	35.31	34.02	27.01/50	73%	Alerta
vapab	VELASCO MENDEZ PABLO SEBASTIAN	Álgebra Lineal - P30006-TEORICO-NÚM... NIC 30006	46.25	17.05	17.68	26.99/50	73%	Alerta
salui	SALAS NARANJO LUIS MIGUEL	Gestión de Proyectos de TI - P30010... NIC 30010	31.32	34.32	17.33	27.66/50	71%	Alerta
gunar	GUERRERO ZURITA MARIA JOSE	Álgebra Lineal - P30006-TEORICO-NÚM... NIC 30006	14.82	31.85	40.82	29.16/50	65%	Alerta
lirgab	BRITO GUERRERO GABRIELA ISABEL	Sistemas Operativos - P30009-TEORIC... NIC 30009	40.68	14.97	32.65	29.43/50	64%	Alerta
		Estadística y Probabilidad - P30007... NIC 30007	27.83	17.23	14.5	19.89/50	89%	Crítico

Nota: Generación automatizada del listado de vulnerabilidad estudiantil detectado por inteligencia artificial.

El reporte exportado en formato PDF incluye el logotipo institucional de la PUCE Ibarra, el título del documento, la fecha de generación y el listado completo de estudiantes clasificados en niveles Crítico y Alerta por el motor predictivo, como se ilustra en la Figura 14.

Figura 14

Reporte PDF: Alertas Tempranas IA

 PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR - SEDE IBARRA REPORTE DE ALERTAS TEMPRANAS — SISTEMA RDA Lote analizado: Lote #11 - moodle_discrepancias.csv Fecha de generación: 15/7/2026 4:44:01 p. m.										
N°	Usuario	Estudiante	Asignatura (NRC)	RDA 1	RDA 2	RDA 3	Promedio	Riesgo	Nivel	Acción
1	caand	CABRERA ZURITA ANDREA CAROLINA	Estadística y Probabilidad - P30007-TEOR... NRC: 30007	27.93	17.23	14.5	19.89/50	89%	CRÍTICO	Intervención urgente (tutoría)
2	escar	ESPINOZA ZURITA CARLOS ANDRES	Sistemas Operativos - P30009-TEORICO-N00... NRC: 30009	10.83	33.06	19.44	21.11/50	87%	CRÍTICO	Intervención urgente (tutoría)
3	esnic	ESPINOZA ZURITA NICOLAS IVAN	Arquitectura de Computadores - P30008-TE... NRC: 30008	10.47	13.8	46.7	23.66/50	82%	CRÍTICO	Intervención urgente (tutoría)
4	sapab	SALAZAR CABRERA PABLO SEBASTIAN	Gestión de Proyectos de TI - P30010-TEOR... NRC: 30010	15.07	17.4	45.31	25.93/50	76%	CRÍTICO	Intervención urgente (tutoría)
5	gului	GUERRERO ESPINOZA LUIS MIGUEL	Arquitectura de Computadores - P30008-TE... NRC: 30008	11.71	35.31	34.02	27.01/50	73%	ALERTA	Seguimiento académico
6	vepab	VELASCO MENDEZ PABLO SEBASTIAN	Álgebra Lineal - P30006-TEORICO-N0010-01... NRC: 30006	46.25	17.05	17.68	26.99/50	73%	ALERTA	Seguimiento académico
7	salui	SALAS NARANJO LUIS MIGUEL	Gestión de Proyectos de TI - P30010-TEOR... NRC: 30010	31.32	34.32	17.33	27.66/50	71%	ALERTA	Seguimiento académico
8	gumar	GUERRERO ZURITA MARIA JOSE	Álgebra Lineal - P30006-TEORICO-N0010-01... NRC: 30006	14.82	31.85	40.82	29.16/50	65%	ALERTA	Seguimiento académico
9	brgab	BRITO GUERRERO GABRIELA ISABEL	Sistemas Operativos - P30009-TEORICO-N00... NRC: 30009	40.68	14.97	32.65	29.43/50	64%	ALERTA	Seguimiento académico
10	pidav	PINTO GUERRERO DAVID ALEJANDRO	Estadística y Probabilidad - P30007-TEOR... NRC: 30007	44.49	27.92	10.63	30.04/50	62%	ALERTA	Seguimiento académico
11	camar	CARVAJAL VELASCO MARIA JOSE	Gestión de Proyectos de TI - P30010-TEOR... NRC: 30010	24.04	30.82	35.72	30.19/50	61%	ALERTA	Seguimiento académico

Sistema RDA — PUCE Ibarra | Página 1 de 2

Nota: Documento formal exportado por el sistema con el listado oficial de estudiantes en riesgo académico.

3.1.8 Reportes Oficiales – Actas de ruta

Como parte del seguimiento del proceso de recuperación, este submódulo permite la emisión de las actas de ruta académica. El sistema extrae los registros persistidos en la base relacional y permite al coordinador modificar la calificación de cada RDA mediante una edición en línea directamente sobre la tabla de resultados, sin recurrir a cuadros de diálogo emergentes. Cada modificación queda registrada en un historial de auditoría inmutable, almacenado como estructura JSON, el cual conserva la fecha, la nota anterior, la nota nueva y el identificador del coordinador responsable del cambio.

Una consideración fundamental de este submódulo es la aplicación de la regla institucional que delimita la calificación máxima alcanzable durante la instancia de recuperación extrasemestral: un estudiante que se somete a la ruta académica únicamente puede obtener, como máximo, la equivalencia C, independientemente del valor numérico ingresado. Por tal motivo, el sistema implementa dos funciones de conversión

diferenciadas: la primera, aplicada sobre la nota original (previa a la recuperación), utiliza la escala completa (A, B, C, D); la segunda, aplicada exclusivamente sobre la nota modificada en la ruta académica, restringe el resultado a las equivalencias C o D. La Figura 15 presenta la interfaz del submódulo, evidenciando que la columna "Nota tras Ruta Académica" no contempla las equivalencias A o B.

Figura 15

Módulo de Reportes Oficiales: Actas de Ruta

PUCE Ibarra
Sistema RDA

Gestión Académica
Bienvenido, Jeremy Campos

COORDINADOR

Actas de Ruta Académica
Genere, visualice y exporte el documento oficial de cierre de calificaciones de Moodle.

Generar Acta PDF

Lote #16 - Archivo de pruebas 2. Seleccione un NRC (Opcional)

Usuario / Estudiante	Nota Alcanzada		Nota tras Ruta Académica		Actividad
	Cuantitativa	Cualitativa	Cuantitativa	Cualitativa	
afaguirres AGUIRRE SUAREZ ANTHONY FERNANDO	7.50	D	50.00	C	RDA 1
djalmeida ALMEIDA MORENO DAVID JOSUE	26.82	D	45.00	C	RDA 3

Cerrar Sesión

Nota: Interfaz para la emisión del documento estandarizado de seguimiento académico, aplicando la restricción institucional de calificación máxima C en la instancia de recuperación.

El reporte exportado en formato PDF incluye el logotipo institucional de la PUCE Ibarra, el título del documento, la fecha de generación, los datos del estudiante, la nota original, la nota modificada tras la ruta académica y su equivalencia cualitativa restringida (C o D), como se ilustra en la Figura 16.

Figura 16

Reporte PDF: Actas de Ruta Académica

Acta_Ruta_Academica_NRC_1170.pdf

1 / 1 | 100% +

PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR IBARRA
RUTA ACADÉMICA
 2026-01

Nombre de la asignatura: **CONTABILIDAD BÁSICA**
 Paralelo / NRC: **1170**
 Nombre del docente: **MSC. NOMBRE DOCENTE**

Apellidos y Nombres	NOTA ALCANZADA		NOTA ALCANZADA LUEGO DE RUTA		Actividad (RDA)
	Cuantitativa	Cualitativa	Cuantitativa	Cualitativa	
AGUIRRE SUAREZ ANTHONY FERNANDO	7.50	D	50.00	C	RDA 1

MSC. NOMBRE DOCENTE
DOCENTE

Coordinador(a)

Director(a) Académico

***Nota:** Documento formal exportado con el acta estandarizada de seguimiento del proceso de recuperación académica.*

3.1.9 Reportes Oficiales – Conciliación

Finalmente, este submódulo consolida el cierre del proceso de seguimiento. Permite generar el acta formal de conciliación, unificando los resultados del análisis detallado RDA por RDA con las métricas finales registradas en Banner, y exportarla en formato PDF o Excel para su archivo institucional, como se muestra en la Figura 17.

Figura 17

Módulo de Reportes Oficiales: Conciliación

Reporte de Conciliación Banner

Exporte el documento formal de auditoría de calificaciones.

Exportar PDF Exportar CSV

Lote Aula Virtual (Moodle) Lote Oficial (Banner)

Lote #10 - moodle_coincide.csv Lote #12 - banner_coincide.csv

Cargar Vista Previa

Cédula	Estudiante	NRC	RDA 1 (Moodle / Banner)	RDA 2 (Moodle / Banner)	RDA 3 (Moodle / Banner)	Estado
brcar	BRITO MENDEZ CARLOS ANDRES	30005	A / A	A / A	C / C	COINCIDE
brdav	BRITO SALAZAR DAVID ALEJANDRO	30001	B / B	A / A	C / C	COINCIDE
brgab	BRITO ZURITA GABRIELA ISABEL	30005	B / B	B / B	B / B	COINCIDE
cadav	CABRERA NARANJO DAVID ALEJANDRO	30003	C / C	C / C	A / A	COINCIDE
cagab	CABRERA SALAS GABRIELA ISABEL	30001	C / C	A / A	C / C	COINCIDE
casnd	CARVAJAL ESPINOZA ANDREA CAROLINA	30004	A / A	B / B	A / A	COINCIDE
casof	CARVAJAL MENDEZ SOFIA VALENTINA	30001	C / C	C / C	B / B	COINCIDE
cadav	CARVAJAL SALAZAR DAVID ALEJANDRO	30001	C / C	A / A	C / C	COINCIDE

Nota: Generación del documento formal de cierre de notas y conciliación académica.

El reporte exportado en formato PDF o Excel incluye el logotipo institucional de la PUCE Ibarra, el título del documento, la fecha de generación y el detalle del cruce RDA por RDA entre los registros de Moodle y Banner, indicando para cada estudiante el estado de conciliación (Coincide, Discrepancia o Sin Banner), como se ilustra en la Figura 18.

Figura 18

Reporte PDF: Conciliación Banner

REPORTE OFICIAL DE CONCILIACIÓN DE NOTAS Comparativa: Aula Virtual (Moodle) vs Sistema Oficial (Banner) Fecha de emisión: 15/7/2026						
Cédula / Usuario	Estudiante	NRC	RDA1 (M/B)	RDA2 (M/B)	RDA3 (M/B)	Estado
brcar	BRITO MENDEZ CARLOS ANDRES	30005	A / A	A / A	C / C	COINCIDE
brdav	BRITO SALAZAR DAVID ALEJANDRO	30001	B / B	A / A	C / C	COINCIDE
brgab	BRITO ZURITA GABRIELA ISABEL	30005	B / B	B / B	B / B	COINCIDE
cadav	CABRERA NARANJO DAVID ALEJANDRO	30003	C / C	C / C	A / A	COINCIDE
cagab	CABRERA SALAS GABRIELA ISABEL	30001	C / C	A / A	C / C	COINCIDE
caand	CARVAJAL ESPINOZA ANDREA CAROLINA	30004	A / A	B / B	A / A	COINCIDE
casof	CARVAJAL MENDEZ SOFIA VALENTINA	30001	C / C	C / C	B / B	COINCIDE
cadav	CARVAJAL SALAZAR DAVID ALEJANDRO	30001	C / C	A / A	C / C	COINCIDE
celui	CEVALLOS LOAIZA LUIS MIGUEL	30004	B / B	A / A	C / C	COINCIDE
cedav	CEVALLOS MENDEZ DAVID ALEJANDRO	30002	C / C	A / A	B / B	COINCIDE
cecar	CEVALLOS TORRES CARLOS ANDRES	30001	B / B	B / B	A / A	COINCIDE
eslui	ESPINOZA HERRERA LUIS MIGUEL	30003	A / A	A / A	C / C	COINCIDE
esjua	ESPINOZA PINTO JUAN JOSE	30005	A / A	B / B	A / A	COINCIDE
espab	ESPINOZA RIOS PABLO SEBASTIAN	30004	A / A	B / B	C / C	COINCIDE
esdia	ESPINOZA TORRES DIANA MELISSA	30004	B / B	A / A	B / B	COINCIDE
guand	GUERRERO MENDEZ ANDREA CAROLINA	30004	B / B	C / C	A / A	COINCIDE
hepab	HERRERA BRITO PABLO SEBASTIAN	30004	A / A	A / A	C / C	COINCIDE
heval	HERRERA MORA VALERIA NATALIA	30002	C / C	C / C	A / A	COINCIDE
helui	HERRERA NARANJO LUIS MIGUEL	30001	A / A	B / B	C / C	COINCIDE
loval	LOAIZA CABRERA VALERIA NATALIA	30005	C / C	B / B	B / B	COINCIDE
logab	LOAIZA MENDEZ GABRIELA ISABEL	30002	C / C	C / C	B / B	COINCIDE
lodia	LOAIZA MORA DIANA MELISSA	30004	A / A	C / C	B / B	COINCIDE
lodia	LOAIZA MORA DIANA MELISSA	30001	B / B	A / A	A / A	COINCIDE
lolui	LOAIZA NARANJO LUIS MIGUEL	30004	A / A	B / B	C / C	COINCIDE
losof	LOAIZA RIOS SOFIA VALENTINA	30001	B / B	C / C	C / C	COINCIDE
loval	LOAIZA SALAZAR VALERIA NATALIA	30004	A / A	B / B	B / B	COINCIDE

Nota: Documento formal exportado con el acta de auditoría cruzada entre el Aula Virtual y el sistema institucional Banner.

3.2 Pruebas de usabilidad y funcionamiento

Para garantizar la estabilidad del Sistema Inteligente de Gestión RDA, se ejecutaron protocolos de validación técnica. Estas pruebas certifican que los módulos desarrollados cumplen con los criterios de optimización y automatización requeridos para el manejo de la información académica. La evaluación se dividió en pruebas de caja negra, orientadas a la experiencia del usuario en las interfaces, y pruebas de caja blanca, enfocadas en la integridad de la lógica del servidor, la seguridad y el motor predictivo.

3.2.1 Pruebas de caja negra

Estas pruebas evaluaron la respuesta del entorno reactivo ante las interacciones del Coordinador Académico, validando que el sistema controle adecuadamente las entradas incorrectas y ejecute los flujos esperados sin interrupciones.

Es importante señalar que las matrices de prueba presentadas a continuación en las tablas 11, 12, 13 y 14 corresponden a pruebas de funcionamiento técnico y verificación funcional del sistema, orientadas a validar el comportamiento de las interfaces y la lógica del servidor ante escenarios de error y éxito. Estas pruebas no constituyen una evaluación formal de usabilidad bajo estándares como SUS (System Usability Scale) o ISO/IEC 25010, cuya aplicación se plantea como trabajo futuro una vez que el sistema opere en un entorno de producción real con usuarios institucionales.

Tabla 11

Matriz de Prueba: Autenticación de Usuario

Elemento	Descripción
ID Prueba	CP-01 — Módulo Control de Acceso (Login)
Descripción	Validar la restricción de acceso ante credenciales incorrectas.
Precondición	El servidor backend y la base de datos se encuentran activos.
Datos de Entrada	Correo institucional válido y contraseña incorrecta.
Resultado Esperado	El sistema debe denegar el acceso, no generar el Token JWT y mostrar una alerta visual de "Credenciales inválidas".
Resultado Obtenido	El frontend captura el código HTTP 401 del servidor y despliega la alerta correctamente. El formulario se limpia automáticamente.
Estado	Aprobado

Tabla 12

Matriz de Prueba: Carga de Archivos Moodle

Elemento	Descripción
ID Prueba	CP-02 — Módulo Carga Moodle (Ingesta)
Descripción	Verificar el comportamiento del sistema al intentar subir un formato de archivo no admitido.
Precondición	El usuario ha iniciado sesión con rol de Coordinador Académico.
Datos de Entrada	Un archivo en formato .pdf en lugar del formato estructurado esperado.
Resultado Esperado	El sistema debe bloquear la carga antes de enviar la petición al servidor, mostrando un mensaje de error indicando formato no soportado.
Resultado Obtenido	La interfaz valida la extensión del archivo, cancela el evento de subida y despliega una notificación de error estructural al usuario.
Estado	Aprobado

Tabla 13

Matriz de Prueba: Edición en Línea y Auditoría

Elemento	Descripción
ID Prueba	CP-03 — Módulo Área de Trabajo
Descripción	Verificar que la edición en línea de una calificación registre correctamente el cambio en el historial de auditoría.
Precondición	Existe un lote cargado con al menos un estudiante.
Datos de Entrada	Modificación de la nota de un RDA de 28,00 a 32,00.
Resultado Esperado	El sistema debe actualizar la nota, recalcular la equivalencia cualitativa según la escala de ruta académica (máximo C) y registrar el cambio en el historial con fecha, valores anterior y nuevo, y el usuario responsable.
Resultado Obtenido	La nota se actualizó a 32,00, la equivalencia cambió de D a C, y el historial de auditoría registró correctamente la transacción con el coordinador autenticado.
Estado	Aprobado

Tabla 14

Matriz de Prueba: Notificación por Correo Electrónico

Elemento	Descripción
ID Prueba	CP-04 — Módulo Predicción IA (Notificación)
Descripción	Validar el envío automatizado de la alerta temprana al correo institucional del estudiante.
Precondición	El motor predictivo clasificó a un estudiante en nivel Crítico o Alerta.
Datos de Entrada	Solicitud de notificación desde el panel de detalle del estudiante.
Resultado Esperado	El backend debe ensamblar y enviar un correo electrónico HTML al estudiante, registrando la acción para evitar notificaciones duplicadas.
Resultado Obtenido	El correo fue recibido correctamente por la cuenta de prueba, conteniendo el detalle de los RDA, el promedio y el porcentaje de riesgo. El botón de notificación cambió su estado a "Notificado".
Estado	Aprobado

3.2.2 Pruebas de caja blanca

Estas pruebas se enfocaron en auditar el comportamiento interno del código en NestJS, la seguridad de los endpoints y la correcta interacción con la base de datos MySQL, asegurando que la automatización de los procesos no corrompa la información.

A continuación, se presentan en las tablas 15, 16, 17 y 18.

Tabla 15

Matriz de Prueba: Estructuración y Normalización

Elemento	Descripción
ID Prueba	CP-05 — Módulo Procesamiento Backend (NestJS)
Descripción	Validar la correcta extracción y normalización de un lote de calificaciones.
Precondición	Envío exitoso de un archivo válido desde el frontend.
Flujo Interno	El controlador recibe el archivo, el servicio ejecuta el parsing, filtra las filas correspondientes a RDA 1, RDA 2 y RDA 3, y descarta el resto de filas e información no relevante.
Resultado Esperado	Los registros deben persistirse en las tablas relacionales con los tipos de datos correctos, sin duplicidad, generando un total coherente con el número de filas filtradas del archivo origen.
Resultado Obtenido	La consulta a la base de datos confirmó la persistencia de 26.057 registros correspondientes a 1.383 estudiantes, con la integridad relacional esperada.
Estado	Aprobado

Tabla 16

Matriz de Prueba: Ejecución del Motor Predictivo

Elemento	Descripción
ID Prueba	CP-06 — Módulo Predicción IA
Descripción	Auditar el cálculo matemático de vulnerabilidad académica realizado por la Red Neuronal.
Precondición	Existencia de registros normalizados en la base de datos.
Flujo Interno	El algoritmo agrupa los registros por estudiante y NRC, calcula el promedio de los RDA disponibles, normaliza el valor al rango [0,1] y lo procesa a través de la red entrenada para obtener una puntaje de riesgo.
Resultado Esperado	El sistema debe asignar correctamente la categorización de riesgo (Rojo ≥ 75 %, Amarillo entre 50 % y 74 %, Verde < 50 %) según el umbral correspondiente al promedio calculado.
Resultado Obtenido	De los 1.383 estudiantes evaluados, el sistema clasificó a 990 en nivel Crítico, 169 en nivel Alerta y 224 en nivel Seguro, correspondiendo dichas clasificaciones con los promedios calculados para cada caso.
Estado	Aprobado

Tabla 17

Matriz de Prueba: Seguridad de Endpoints (JWT)

Elemento	Descripción
ID Prueba	CP-07 — Seguridad de la API
Descripción	Verificar que los Guards de NestJS bloqueen el acceso no autorizado a los endpoints sensibles.
Precondición	El servidor backend se encuentra en ejecución.
Flujo Interno	Se envían peticiones HTTP hacia los endpoints del módulo RDA: primero sin token, luego con token válido, y finalmente con un token expirado y con un token alterado manualmente en su firma, verificando el comportamiento del Guard en cada escenario
Resultado Esperado	Las peticiones sin token deben recibir un código de respuesta 401 (Unauthorized); las peticiones con token válido deben recibir un código 200 (OK) junto con los datos solicitados.
Resultado Obtenido	Las peticiones sin token fueron rechazadas con código 401. Las peticiones con token válido retornaron código 200. Las peticiones con token expirado y token alterado fueron igualmente rechazadas con código 401, confirmando que el Guard valida tanto la estructura como la vigencia del token.
Estado	Aprobado

Tabla 18

Matriz de Prueba: Conciliación RDA por RDA

Elemento	Descripción
ID Prueba	CP-08 — Módulo de Conciliación
Descripción	Validar el cruce individual de cada Resultado de Aprendizaje entre los registros de Moodle y Banner.
Precondición	Existen lotes procesados de Moodle y de Banner.
Flujo Interno	El algoritmo indexa los registros de Banner por usuario institucional y NRC, agrupa los registros de Moodle por el mismo criterio, y compara individualmente las equivalencias de RDA 1, RDA 2 y RDA 3 entre ambas fuentes.
Resultado Esperado	El sistema debe clasificar cada registro como "Coincide", "Discrepancia" o "Sin Banner", según corresponda al resultado del cruce de cada RDA.
Resultado Obtenido	El algoritmo identificó correctamente los registros sin contraparte en Banner bajo el estado "Sin Banner" y clasificó correctamente el único registro coincidente bajo el estado "Coincide", validando la lógica de cruce.
Estado	Aprobado

3.3 Discusión

La implementación del Sistema Inteligente de Gestión RDA permitió contrastar la operatividad de los flujos tecnológicos automatizados frente a los métodos de seguimiento manuales empleados tradicionalmente. Del análisis del funcionamiento en el entorno de despliegue, se extraen los siguientes hallazgos fundamentales.

3.3.1 Optimización del tiempo en la gestión de expedientes

El primer hallazgo significativo radica en la optimización de los tiempos administrativos. Previo a la implementación tecnológica, la consolidación de calificaciones requería la descarga, depuración y transcripción manual de los datos hacia hojas de cálculo. Con la automatización del módulo de Carga Moodle, la extracción e ingesta masiva de registros se ejecuta de forma directa hacia la base de datos relacional: en la prueba realizada, un único archivo de 26.057 registros fue procesado, filtrado y persistido en la base de datos en 46 segundos, equivalente a una tasa de procesamiento de 566 registros por segundo, frente a las aproximadamente 434 horas que requeriría su tabulación manual a razón de un registro por minuto, lo que representa una reducción del 99,9 % en el tiempo de procesamiento.

3.3.2 Automatización en la detección preventiva de riesgo

A nivel analítico, se evidenció un cambio de paradigma estructural al transitar de un modelo reactivo a uno predictivo y continuo. Tradicionalmente, la coordinación académica identificaba el bajo rendimiento estudiantil únicamente al finalizar el periodo, guiándose por el reporte estático de Banner. El hallazgo principal del sistema propuesto es la capacidad del motor de Inteligencia Artificial para evaluar los registros del Aula Virtual en cualquier momento del periodo académico, incluso con información parcial (uno o dos RDA cargados). En la prueba realizada, el sistema clasificó al 83,8 % de la cohorte evaluada (1.159 de 1.383 estudiantes) con al menos una asignatura en nivel Crítico o Alerta según los umbrales institucionales definidos. Esta proporción ilustra la magnitud del seguimiento requerido y evidencia que, bajo el modelo tradicional, esta información solo habría sido visible al cierre del periodo, cuando las posibilidades de intervención son limitadas. El sistema dota al coordinador de una herramienta de clasificación automatizada y un mecanismo de notificación por correo electrónico para ejecutar planes de seguimiento de manera oportuna, con la consideración de que la efectividad real del modelo deberá evaluarse en iteraciones futuras con datos históricos de cohortes anteriores.

3.3.3 Trazabilidad integral y auditoría cruzada

El despliegue del módulo de Conciliación demostró la importancia de mantener la integridad de los datos en arquitecturas desacopladas. Se identificó que, aunque el

entorno virtual (Moodle) provee la granularidad numérica necesaria para el cálculo predictivo, el sistema institucional (Banner) sigue siendo el repositorio de cierre oficial, expresado únicamente en equivalencias cualitativas por cada Resultado de Aprendizaje. El hallazgo técnico destaca que la plataforma web actúa como un puente de auditoría efectivo, permitiendo contrastar, RDA por RDA, la equivalencia calculada a partir de la nota numérica de Moodle con la equivalencia oficial registrada en Banner, asegurando que cualquier discrepancia entre ambas fuentes sea detectada y documentada antes del cierre definitivo del expediente del estudiante.

3.3.4 Seguridad y gobernanza de la información

Finalmente, la incorporación de guardias de autenticación JWT en la totalidad de los endpoints de la API, junto con el almacenamiento de credenciales sensibles (claves de seguridad, credenciales de base de datos y del servicio de correo electrónico) en variables de entorno externas al código fuente, fortaleció la gobernanza del sistema frente a accesos no autorizados. Esta arquitectura de seguridad, validada mediante las pruebas CP-07, garantiza que la información académica de los estudiantes, incluyendo calificaciones, historiales de modificación y datos de contacto permanezca protegida ante el acceso de terceros no autenticados, cumpliendo con los estándares de confidencialidad esperados para un sistema de gestión académica institucional.

3.3.5 Limitaciones del sistema

A pesar de los resultados favorables obtenidos, el desarrollo del presente trabajo evidenció ciertas limitaciones que deben ser considerada para la interpretación de los hallazgos y para futuras mejoras del sistema; el envío de notificaciones por correo electrónico. Esto se implementó utilizando una cuenta de correo externa configurada mediante el protocolo SMTP, debido a que no se dispuso de credenciales de una cuenta de correo institucional de la PUCE Ibarra al momento del desarrollo. Aunque la funcionalidad fue validada exitosamente y el sistema está preparado para operar con cualquier proveedor SMTP compatible, se recomienda que, en una fase de implementación productiva, la institución asigne una cuenta de correo institucional dedicada al sistema, de manera que las notificaciones se perciban con mayor formalidad por parte de los estudiantes.

Asimismo, el motor de clasificación fue entrenado con un único conjunto de diez pares de ejemplos definidos manualmente a partir de la escala institucional, sin contar con etiquetas históricas reales de aprobación o reprobación. Al disponer de una sola variable predictora que es el promedio de los RDA disponibles, el modelo no captura factores adicionales que pueden influir en el rendimiento académico, como la asistencia, el historial previo o el tipo de asignatura. En consecuencia, el sistema podría generar falsos positivos (estudiantes clasificados en riesgo que efectivamente aprueban) o falsos negativos (estudiantes no detectados que reprueban), situación que solo podrá evaluarse con precisión una vez que el sistema opere con datos históricos reales de cohortes anteriores.

CONCLUSIONES

El levantamiento de requerimientos con los coordinadores académicos de las carreras repotenciadas de la PUCE Ibarra permitió identificar que la gestión manual de los Resultados de Aprendizaje mediante hojas de cálculo aisladas generaba una inversión de tiempo de aproximadamente 434 horas para procesar un volumen equivalente al lote de prueba utilizado, evidenciando la necesidad de automatización que el sistema desarrollado logró satisfacer al reducir ese tiempo a 46 segundos, una disminución del 99,9 % en el tiempo de procesamiento.

La arquitectura desacoplada implementada bajo el patrón API RESTful, con Vue.js en el frontend y NestJS en el backend, demostró ser funcional y estable durante las pruebas de validación, permitiendo que los coordinadores académicos accedieran a la información procesada de manera fluida desde cualquier navegador, sin tiempos de carga prolongados, y con control de acceso garantizado mediante guardias de autenticación JWT que rechazaron correctamente todas las peticiones no autorizadas durante las pruebas de seguridad.

La integración del motor predictivo basado en una Red Neuronal Artificial de arquitectura 1-4-1 demostró su capacidad para clasificar el riesgo académico de forma incremental, operando correctamente sobre lotes con uno, dos o tres RDA disponibles. Aplicado sobre un lote real de 1.383 estudiantes, el motor identificó que el 83,8 % de la cohorte presentaba al menos una asignatura en nivel de riesgo Crítico o Alerta, generando automáticamente el listado de estudiantes que requieren intervención preventiva por parte de la coordinación.

Las pruebas de caja negra y caja blanca ejecutadas sobre un lote real de 26.057 registros validaron el correcto funcionamiento de los ocho casos de prueba definidos, confirmando la confiabilidad de los datos procesados, la usabilidad de las interfaces y el aporte del sistema a la mejora de los procesos de seguimiento académico. No obstante, se identificaron dos limitaciones operativas: el envío de notificaciones se validó sobre una cuenta de correo externa al dominio institucional, y los resultados del motor predictivo no se persisten de manera permanente en la base de datos.

En términos generales, el Sistema Inteligente para la Gestión y Seguimiento de los Resultados de Aprendizaje constituyó una transición efectiva desde un modelo de seguimiento reactivo y manual hacia un modelo proactivo y automatizado, dotando a la coordinación académica de la PUCE Ibarra de una herramienta capaz de centralizar la información, clasificar a los estudiantes según umbrales de riesgo institucionales y notificarlos de manera automática, fortaleciendo la gestión del proceso de seguimiento académico de las carreras repotenciadas.

RECOMENDACIONES

Se recomienda gestionar ante las autoridades de la PUCE Ibarra la asignación de una cuenta de correo electrónico institucional dedicada al sistema, con el objetivo de que las notificaciones automáticas de alerta temprana sean enviadas desde un dominio oficial, fortaleciendo la percepción de formalidad y confiabilidad de las comunicaciones recibidas por los estudiantes.

Se sugiere implementar la persistencia de los resultados generados por el motor predictivo en una entidad dedicada de la base de datos relacional. Si bien el sistema actual incorpora un mecanismo de auditoría inmutable para el registro de modificaciones manuales de calificaciones, almacenando en formato JSON la fecha, la nota anterior, la nota nueva y el identificador del coordinador responsable, los resultados calculados por la Red Neuronal no se persisten entre sesiones, dado que el análisis predictivo se ejecuta dinámicamente cada vez que el coordinador lo solicita. Implementar dicha persistencia permitiría a la coordinación académica realizar comparaciones longitudinales del nivel de riesgo de un mismo estudiante a lo largo del periodo, complementando así el historial de auditoría ya existente con un registro histórico de las predicciones generadas.

Resultaría conveniente entrenar el motor predictivo con conjuntos de datos históricos reales de cohortes anteriores de la PUCE Ibarra, en lugar de los umbrales definidos manualmente a partir de la escala institucional, lo que permitiría que la Red Neuronal ajuste sus pesos a partir de patrones de comportamiento observados en la población estudiantil real.

Como línea de trabajo futuro, se plantea la incorporación de un asistente conversacional basado en modelos de lenguaje (LLM) que permita a los coordinadores realizar consultas en lenguaje natural sobre los datos procesados por el sistema, tales como identificar estudiantes en riesgo o solicitar un resumen del desempeño de un estudiante específico, complementando la interfaz visual del motor predictivo con una capa de interacción conversacional

REFERENCIAS BIBLIOGRÁFICAS

Alamri, H. A., Watson, S., & Watson, W. R. (2020). Learning technology models that support personalized learning in higher education. *TechTrends*.

Al-Fraihat, D., Joy, M., & Sinclair, J. (2020). Evaluating E-learning systems success: An empirical study. <https://doi.org/10.1016/j.chb.2019.08.004>

Anthology Inc. (2024). *Blackboard analytics*. <https://www.anthology.com>

Bodily, R., & Verbert, K. (2017). Review of research on student-facing learning analytics dashboards. *IEEE Transactions on Learning Technologies*.

Bond, M., Bedenlier, S., Marín, V. I., & Händel, M. (2021). Emergency remote teaching in higher education. *International Journal of Educational Technology in Higher Education*.

Buckingham Shum, S., Ferguson, R., & Martinez-Maldonado, R. (2019). Human-Centred Learning Analytics. *Journal of Learning Analytics*, 6(2), 1–9. <https://doi.org/10.18608/jla.2019.62.1>

Coworkingfy. (19 de marzo de 2019). Metodología Waterfall | Cómo aplicar la gestión de proyectos en cascada. <https://coworkingfy.com/metodologia-waterfall/>

Folorunso, S. O., Farhaoui, Y., Adigun, I. P., & Imoize, A. L. (2024). *Prediction of student's academic performance using learning analytics*. En **Artificial intelligence, data science and applications** (pp. 314–325). Springer. https://doi.org/10.1007/978-3-031-48465-0_41

Ghader Azad, H. (2025). Enhancing student engagement through learning analytics dashboards. https://publications.polymtl.ca/65829/1/2025_HastiGhaderAzad.pdf

Hellas, A., Ihantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., ... Liao, S. N. (2018). Predicting academic performance: A systematic literature review. *Proceedings of the ACM Conference on Innovation and Technology in Computer Science Education*.

Holmes, W., Bialik, M., & Fadel, C. (2023). Artificial intelligence in education. Educational Technology Research and Development.

Ifenthaler, D., & Yau, J. Y. K. (2019). Utilising learning analytics for study success: Reflections on current empirical findings. *British Journal of Educational Technology*.

Instructure Inc. (2024). *Canvas learning management system*. <https://www.instructure.com/canvas>

- Moodle Pty Ltd. (2024). *Moodle learning management system*. <https://moodle.org>
- Nguyen, A., Gardner, L., & Sheridan, D. (2021). Data analytics in higher education: An integrated view. *Journal of Information Systems Education*.
- Pressman, R. S. (2010). *Ingeniería del Software: Un enfoque práctico* (7ma ed.). McGraw-Hill Education.
- Ruiz Muñoz, G. F. ., Vasco Delgado, J. C. ., & Alvear Dávalos, J. M. (2024). Inteligencia artificial y gobernanza en la gestión académica y administrativa de la educación superior. *Revista Social Fronteriza*, 4(6), e46508. [https://doi.org/10.59814/resofro.2024.4\(6\)508](https://doi.org/10.59814/resofro.2024.4(6)508)
- Selwyn, N., Hillman, T., Bergviken Rensfeldt, A., & Perrotta, C. (2021). Digital transformation in higher education. *Learning, Media and Technology*.
- Tsai, Y. S., & Gašević, D. (2022). Learning analytics in higher education – Stakeholders, strategy and scale. <https://doi.org/10.1016/j.iheduc.2021.100833>
- Verbert, K., Ochoa, X., De Croon, R., Dourado, R., & De Laet, T. (2020). Learning analytics dashboards. *IEEE Transactions on Learning Technologies*.
- Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior Reports*, 8, 100230.

ANEXOS

Anexo1: Carta de aceptación de la propuesta tecnológica



Escuela de Hábitat, Infraestructura y Creatividad

CERTIFICA:

Que el estudiante JEREMY PATRICIO CAMPOS ZAMBRANO, estudiante de la carrera de Ingeniería en Tecnologías de la Información de la Pontificia Universidad Católica del Ecuador Ibarra, va a desarrollar el proyecto de titulación titulado:

“SISTEMA INTELIGENTE PARA LA GESTIÓN Y SEGUIMIENTO DE LOS RESULTADOS DE APRENDIZAJE EN LAS CARRERAS REPOTENCIADAS DE LA PUCE IBARRA”.

El presente proyecto tiene como finalidad diseñar un sistema web orientado al seguimiento y análisis descriptivo de los Resultados de Aprendizaje mediante la centralización de la información académica proveniente del sistema Banner, el procesamiento automático de datos académicos a través de indicadores y reportes, y la incorporación de mecanismos de trazabilidad e integridad de la información, con el fin de apoyar la toma de decisiones académicas oportunas por parte de las coordinaciones académicas.

Para la ejecución del proyecto, el estudiante podrá realizar actividades de levantamiento y análisis de información, revisión de procesos académicos, diseño de la arquitectura del sistema, desarrollo del sistema web, pruebas funcionales y validación de resultados, de conformidad con los lineamientos académicos y metodológicos establecidos por la institución.

Se deja constancia de que el desarrollo del proyecto tiene fines estrictamente académicos, en cumplimiento de los requisitos establecidos para la obtención del título profesional correspondiente.

Para los fines pertinentes, se extiende la presente certificación.

Ibarra, febrero de 2026

Atentamente,

Santiago
Damián
Quishpe
Morales

Firmado digitalmente
por Santiago Damián
Quishpe Morales
Fecha: 2026.02.06
11:14:23 -0500

Santiago Quishpe

Coordinador Académico Carrera de Software

Escuela de Hábitat, Infraestructura y Creatividad

Pontificia Universidad Católica del Ecuador – Sede Ibarra

Anexo2: Carta de recepción de la propuesta tecnológica por parte del cliente



Escuela de Hábitat, Infraestructura y Creatividad

CERTIFICA:

Que la Coordinación Académica de la Carrera de Software, con el Mgs. Santiago Quishpe como responsable, ha recibido a conformidad el proyecto de titulación titulado **"SISTEMA INTELIGENTE PARA LA GESTIÓN Y SEGUIMIENTO DE LOS RESULTADOS DE APRENDIZAJE EN LAS CARRERAS REPOTENCIADAS DE LA PUCE IBARRA"**, desarrollado por el estudiante JEREMY PATRICIO CAMPOS ZAMBRANO de la carrera de Ingeniería en Tecnologías de la Información.

El sistema entregado automatiza el procesamiento de calificaciones provenientes del Aula Virtual y Banner, incorpora un motor predictivo basado en Red Neuronal Artificial para la detección temprana de estudiantes en riesgo académico, y genera reportes oficiales con mecanismos de auditoría y conciliación entre Moodle y el sistema institucional Banner, cumpliendo con los requerimientos funcionales establecidos al inicio del proyecto.

Se deja constancia de que el desarrollo tuvo fines estrictamente académicos, en cumplimiento de los requisitos para la obtención del título de **Ingeniero en Tecnologías de la Información**.

Para los fines pertinentes, se extiende la presente certificación.

Ibarra, julio de 2026

Firmado digitalmente por
Santiago Quishpe
Fecha: 2026.07.17
12:57:42 -05'00'

Mgs. Santiago Quishpe

Coordinador Académico Carrera de Software
Escuela de Hábitat, Infraestructura y Creatividad
Pontificia Universidad Católica del Ecuador – Sede Ibarra

Anexo3: Pares de entrenamiento del motor de clasificación

Se detallan los diez pares de entrada-salida utilizados para el entrenamiento de la Red Neuronal Artificial, junto con los umbrales institucionales que los fundamentan:

Tabla 19

Pares de entrenamiento

Nota (sobre 50)	Valor normalizado	Puntaje de riesgo esperado	Equivalencia
0	0,00	1,00	D extremo
10	0,20	0,95	D
20	0,40	0,85	D
29	0,58	0,75	Límite D/C
30	0,60	0,55	C bajo
35	0,70	0,40	C medio
39	0,78	0,30	Límite C/B
40	0,80	0,20	B
45	0,90	0,08	A bajo
50	1,00	0,02	A máximo