

UNIVERSIDAD NACIONAL DEL SANTA
ESCUELA DE POSGRADO
Programa de Doctorado en Ingeniería de Sistemas e
Informática



UNS
ESCUELA DE
POSGRADO

**Modelo de implementación de inteligencia artificial
para la mejora de las finanzas personales
en estudiantes de institutos superiores**

**Tesis para optar el grado de Doctor en
Ingeniería de Sistemas e Informática**

Autor:

Mg. Galvez Layza, Gary Urigf
Código ORCID: 0009-0004-5460-8908

Asesor:

Dr. Mendoza Rivera, Ricardo Darío
DNI. N° 18070765
Código ORCID: 0000-0001-8744-4736

Línea de Investigación:

Ciencia de la Computación, Tecnologías de la Información

Nuevo Chimbote - PERÚ
2026



CERTIFICACIÓN DEL ASESOR

Yo, **Dr. Ricardo Darío Mendoza Rivera**, mediante la presente certifico mi asesoramiento de la tesis de Doctorado titulada: **“Modelo de Implementación de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores”**, elaborado por el **Mg. Gary Urigf Galvez Layza**, para obtener el Grado de **Doctor en Ingeniería de Sistemas e Informática**, en la Escuela de Posgrado de la Universidad Nacional del Santa.

Nuevo Chimbote, setiembre del 2026

Dra. Ricardo Darío Mendoza Rivera

Asesor

DNI N° 18070765

Código ORCID: 0000-0001-8744-4736



AVAL DE CONFORMIDAD DEL JURADO

Tesis de Doctorado titulada: **“Modelo de Implementación de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores”**, elaborado por el Mg. Gary Urig Galvez Layza.

Revisado y Aprobado por el Jurado Evaluador:

Dra. Lizbeth Dora Briones Pereyra
Presidenta

DNI N° 32960646

Código ORCID: 0000-0003-0626-7227

Dr. Yim Isaias Apestegui Florentino
Secretario

DNI N° 32541215

Código ORCID 0000-0003-2873-1748

Dr. Ricardo Darío Mendoza Rivera
Vocal/Asesor

DNI N° 18070765

Código ORCID: 0000-0001-8744-4736



ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE TESIS

A los ocho días del mes de setiembre del año 2026, siendo las 09:00 horas, en el aula P-02 de la Escuela de Posgrado de la Universidad Nacional del Santa, se reunieron los miembros del Jurado Evaluador, designados mediante Resolución Directoral N° 563-2026-EPG-UNS de fecha 02.07.2026, conformado por los docentes: Dra. Lizbeth Dora Briones Pereyra (Presidenta), Dr. Yim Isaias Apestegui Florentino (Secretario) y Dr. Ricardo Darío Mendoza Rivera (Vocal); con la finalidad de evaluar la tesis intitulada: **"Modelo de implementación de inteligencia artificial para la mejora de las finanzas personales en estudiantes de institutos superiores"**, cuyo autor es el Mg. Gary Urigf Galvez Layza, egresado del programa de Doctorado en Ingeniería de Sistemas e Informática.

Sustentación autorizada mediante Resolución Directoral N° 733-2026-EPG-UNS de fecha 07 de setiembre de 2026.

La presidente del jurado autorizó el inicio del acto académico; producido y concluido el acto de sustentación de tesis, los miembros del jurado procedieron a la evaluación respectiva, haciendo una serie de preguntas y recomendaciones al tesista, quien dio respuestas a las interrogantes y observaciones.

El jurado después de deliberar sobre aspectos relacionados con el trabajo, contenido y sustentación del mismo y con las sugerencias pertinentes, declara la sustentación como APROBADO, asignándole la calificación de DIECIOCHO.

Siendo las 10:00 horas del mismo día se da por finalizado el acto académico, firmando la presente acta en señal de conformidad.


Dra. Lizbeth Dora Briones Pereyra
Presidenta


Dr. Yim Isaias Apestegui Florentino
Secretario


Dr. Ricardo Darío Mendoza Rivera
Vocal/Asesor



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por **Turnitin**. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Gary Urigf GALVEZ LAYZA
Título del ejercicio: DOCTORADO 2026 - 2
Título de la entrega: Tesis Doctorado Gary Galvez
Nombre del archivo: Final_Informe_Galvez_24_06_2026.docx
Tamaño del archivo: 6.8M
Total páginas: 126
Total de palabras: 25,740
Total de caracteres: 151,414
Fecha de entrega: 24-jun-2026 03:21p. m. (UTC-0500)
Identificador de la entrega: 2989019421

UNIVERSIDAD NACIONAL DEL SANTA
ESCUELA DE POSGRADO
Programa de Doctorado en Ingeniería de Sistemas e
Informática

 **UNS**
ESCUELA DE
POSGRADO

Modelo de Implementación de Inteligencia Artificial para la
Mejora de las Finanzas Personales en Estudiantes de Institutos
Superiores

Tesis para optar el grado de Doctor en Ingeniería de
Sistemas e Informática

Autor:
Mg. Gary Urigf Galvez Layza Código
ORCID:

Asesor:
Dr. Ricardo Darío Mendoza Rivera
Código ORCID: 0000-0001-8744-4736
DNI N° 18070765

Nuevo Chimbote - PERÚ
2026

i

INFORME DE ORIGINALIDAD

5%

INDICE DE SIMILITUD

4%

FUENTES DE INTERNET

1%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1 repositorio.uns.edu.pe

Fuente de Internet

1%

2 www.coursehero.com

Fuente de Internet

<1%

3 www.dykinson.com

Fuente de Internet

<1%

4 César Aguado Cortés, Arturo Morales Castro. "Fintech e ingeniería financiera", Ecoe Ediciones S. A. S., 2025

Publicación

<1%

5 Submitted to CORPORACIÓN UNIVERSITARIA IBEROAMERICANA

Trabajo del estudiante

<1%

6 www.rilco.org

Fuente de Internet

<1%

7 Submitted to Universidad TecMilenio

Trabajo del estudiante

<1%

8 repositorio.unapiquitos.edu.pe

Fuente de Internet

<1%

9 Submitted to Universidad Nacional del Santa

Trabajo del estudiante

<1%

10 Submitted to Politecnico Jaime Isaza Cadavid

Trabajo del estudiante

<1%

11 www.iksadamerica.org

Fuente de Internet

<1%

12 Submitted to Universidad Anahuac México Sur

Trabajo del estudiante

<1%

13 www.criptonoticias.com

Fuente de Internet

<1%

14 dokumen.pub

Fuente de Internet

<1%

repositorio.unas.edu.pe

DEDICATORIA

A **Dios** por darme sabiduría y perseverancia para el desarrollo de mi trabajo de investigación

AGRADECIMIENTO

A mis padres, por su apoyo incondicional y su ejemplo de esfuerzo constante, que siempre me ha inspirado a perseguir mis metas con determinación. A mis hijos, por su amor, paciencia y comprensión durante este viaje académico. Y a una compañera especial que gracias a su presencia ha sido mi mayor motivación.

ÍNDICE

ACTA DE APROBACIÓN DE ORIGINALIDAD	iii
DECLARACIÓN JURADA DE AUTORÍA.....	iv
RECIBO TURNITIN.....	v
REPORTE PORCENTUAL DE TURNITIN.....	vi
DEDICATORIA.....	vii
AGRADECIMIENTO	viii
RESUMEN.....	14
ABSTRACT.....	15
I. INTRODUCCIÓN.....	16
1.1. DESCRIPCIÓN Y FORMULACIÓN DEL PROBLEMA	16
1.1.1. Realidad genérica del problema.....	16
1.1.2. Formulación del problema	18
1.2. OBJETIVOS	18
1.2.1 Objetivo General.....	18
1.2.2 Objetivos Específicos	18
1.3. FORMULACIÓN DE LA HIPÓTESIS	19
1.4. JUSTIFICACIÓN E IMPORTANCIA	19
1.4.1. Conveniencia	19
II. MARCO TEÓRICO.....	22
2.1. ANTECEDENTES.....	22
2.2. FUNDAMENTACIÓN TEÓRICA.....	29
2.2.1. Finanzas	29
2.2.2. Modelos de clasificación en finanzas personales	33
2.2.3. Técnicas de minería de datos	37
2.2.4. Innovaciones tecnológicas.....	38
2.2.6. Aplicaciones financieras en educación superior	40
2.3. MARCO CONCEPTUAL.....	43
III. METODOLOGÍA	47
3.1. Método de la investigación.....	47
3.2. Diseño de Investigación.....	49
3.3. Población y muestra	53
a. Población.....	53
b. Muestra.....	53
3.4. Operacionalización de las variables.....	55
3.5. Técnicas e instrumentos de recolección de datos.....	56

3.6.	Técnicas de análisis de resultados	57
3.7.	Procedimiento	61
IV.	RESULTADOS Y DISCUSIÓN	93
4.1.	Resultados	93
4.1.1.	Eficiencia computacional del modelo	94
4.1.2.	Mejora de la gestión financiera personal	114
4.1.3.	Contraste de la hipótesis de investigación	110
4.2.	Discusión.....	113
V.	CONCLUSIONES Y RECOMENDACIONES	115
5.1.	Conclusiones.....	115
5.2.	Recomendaciones.....	117
V.	REFERENCIAS BIBLIOGRÁFICAS	119
V.	ANEXOS	127

ÍNDICE DE TABLAS

TABLA 1. CORRESPONDENCIA ENTRE LAS CAPAS DEL MODELO PROPUESTO Y SU IMPLEMENTACIÓN EN EL SISTEMA FINANCIA	52
TABLA 2. CONFIABILIDAD DEL INSTRUMENTO POR SECCIÓN (ALFA DE CRONBACH, N = 154 OBSERVACIONES COMBINADAS).....	60
TABLA 3. MÓDULOS FUNCIONALES DEL SISTEMA FINANCIA Y SU APOORTE A LA INVESTIGACIÓN	63
TABLA 4. PLAN DE IMPLEMENTACIÓN DEL SISTEMA FINANCIA POR FASES Y OBJETIVOS TÉCNICOS	65
TABLA 5. COMPONENTES TECNOLÓGICOS DEL SISTEMA FINANCIA Y SUS FUNCIONES	67
TABLA 6. ESTRUCTURA PRINCIPAL DEL PROYECTO FINANCIA Y FUNCIÓN TÉCNICA DE SUS COMPONENTES	68
TABLA 7. COMANDOS DE INSTALACIÓN, VERIFICACIÓN Y EJECUCIÓN LOCAL DEL SISTEMA FINANCIA	70
TABLA 8. ENTIDADES PRINCIPALES DE LA BASE DE DATOS DEL SISTEMA FINANCIA Y SU PROPÓSITO	71
TABLA 9. ENDPOINTS PRINCIPALES DE LA API RESTFUL DEL SISTEMA FINANCIA.....	73
TABLA 10. VALIDACIONES APLICADAS EN EL MÓDULO DE USUARIOS DEL SISTEMA FINANCIA	74
TABLA 11. CAMPOS PRINCIPALES DEL MÓDULO FINANCIERO DEL SISTEMA FINANCIA	77
TABLA 12. DIMENSIONES DE LA ENCUESTA FINANCIERA DIGITAL Y SU RELACIÓN CON EL IMFP.....	79
TABLA 13. INDICADORES DEL MÓDULO DE RESUMEN FINANCIERO DEL SISTEMA FINANCIA	81
TABLA 14. GRÁFICAS DEL SISTEMA FINANCIA, DATOS UTILIZADOS Y FINALIDAD DE ANÁLISIS	83
TABLA 15. COMPONENTES DEL MÓDULO DE INTELIGENCIA ARTIFICIAL DEL SISTEMA FINANCIA Y SU APOORTE AL MODELO	85
TABLA 16. ESCENARIOS DE ACTIVACIÓN DEL FALLBACK LOCAL INTELIGENTE EN FINANCIA	88
TABLA 17. SECCIONES DEL REPORTE FINANCIERO PDF GENERADO POR FINANCIA Y SU UTILIDAD INVESTIGATIVA	90
TABLA 18. MATRIZ DE PRUEBAS FUNCIONALES DEL PROTOTIPO FINANCIA	91
TABLA 19. LATENCIA DE RESPUESTA DEL MÓDULO IA DE FINANCIA — DIFERENCIACIÓN POR TIPO DE RESPUESTA (N = 30 SOLICITUDES CONTROLADAS)	95
TABLA 20. DISPONIBILIDAD DEL SERVICIO DEL MÓDULO IA DE FINANCIA (N = 30 SOLICITUDES)	96
TABLA 21. CONSUMO DE MEMORIA RAM POR PROCESO DURANTE LA EJECUCIÓN DEL SISTEMA FINANCIA	98
TABLA 22. TASA DE ACTIVACIÓN DEL FALLBACK LOCAL EN LAS PRUEBAS DE EFICIENCIA DEL SISTEMA FINANCIA	100
TABLA 23. SÍNTESIS DE INDICADORES DE EFICIENCIA COMPUTACIONAL DEL MODELO PROPUESTO	101

TABLA 24. ESTADÍSTICA DESCRIPTIVA DE LA DIMENSIÓN DE CONOCIMIENTO FINANCIERO (K) — PRETEST Y POSTEST (N = 77)	102
TABLA 25. <i>ESTADÍSTICA DESCRIPTIVA DE LA DIMENSIÓN DE CONDUCTA FINANCIERA (C)</i> — <i>PRETEST Y POSTEST (N = 77)</i>	104
TABLA 26. ESTADÍSTICA DESCRIPTIVA DE LA DIMENSIÓN DE RESULTADO FINANCIERO (R) — PRETEST Y POSTEST (N = 77)	106
TABLA 27. <i>ESTADÍSTICA DESCRIPTIVA DEL IMFP GLOBAL — PRETEST Y POSTEST (N = 77)</i>	107
TABLA 28. RESULTADOS DEL CONTRASTE DE HIPÓTESIS SOBRE EL IMFP Y SUS DIMENSIONES — PRUEBA DE WILCOXON Y T DE STUDENT PAREADA (N = 77)	110

ÍNDICE DE FIGURAS

FIGURA 1. PIRÁMIDE DE MASLOW	32
FIGURA 2. ARQUITECTURA COMPARATIVA: RNN CON CELDAS LSTM FRENTE A ARQUITECTURA TRANSFORMER.....	35
FIGURA 3. DIAGRAMA GENERAL DE LA METODOLOGÍA DE LA INVESTIGACIÓN	62
FIGURA 4. INTERFAZ PRINCIPAL Y PROPUESTA DE VALOR DE LA PLATAFORMA FINANCIA	64
FIGURA 5. FLUJO METODOLÓGICO DE IMPLEMENTACIÓN Y VALIDACIÓN.	66
FIGURA 6. ARQUITECTURA GENERAL DEL SISTEMA FINANCIERA.	68
FIGURA 7. ESTRUCTURA TÉCNICA DEL PROYECTO FINANCIERA.	69
FIGURA 8. EJECUCIÓN LOCAL DEL SERVIDOR FINANCIERA MEDIANTE NPM START.....	70
FIGURA 9. MODELO ENTIDAD-RELACIÓN DE LA BASE DE DATOS DEL SISTEMA FINANCIA.	72
FIGURA 10. VERIFICACIÓN DEL ENDPOINT DE SALUD DEL SISTEMA FINANCIERA.	74
FIGURA 11. REGISTRO DE USUARIO EN EL SISTEMA FINANCIERA.....	76
FIGURA 12. REGISTRO DE INGRESOS MENSUALES EN FINANCIERA.	78
FIGURA 13. REGISTRO DE GASTOS POR CATEGORÍA EN FINANCIERA.	78
FIGURA 14. ENCUESTA FINANCIERA DIGITAL APLICADA EN FINANCIERA.	80
FIGURA 15. MÓDULO DE RESUMEN FINANCIERO DEL SISTEMA FINANCIERA.....	82
FIGURA 16. VISUALIZACIÓN GRÁFICA DE INGRESOS Y GASTOS EN FINANCIERA.....	84
FIGURA 17. CONSULTA AL ASISTENTE FINANCIERO INTELIGENTE DE FINANCIERA.	87
FIGURA 18. RESPUESTA GENERADA MEDIANTE FALLBACK LOCAL INTELIGENTE.	89
FIGURA 19. REPORTE FINANCIERO EXPORTADO EN FORMATO PDF DESDE FINANCIERA.	90
FIGURA 20. VALIDACIÓN FUNCIONAL DEL ENDPOINT DE SALUD MEDIANTE POSTMAN	93
FIGURA 21. <i>DISTRIBUCIÓN DE LATENCIA DE RESPUESTA EN LAS 30 SOLICITUDES CONTROLADAS — DIFERENCIACIÓN ENTRE INFERENCIA REAL Y RESPUESTA CACHEADA</i>	96
FIGURA 22. CONSUMO DE MEMORIA RAM POR PROCESO — OLLAMA Y NODE.JS DURANTE LA EJECUCIÓN DE FINANCIERA.....	99
FIGURA 23. COMPARACIÓN DE LA DIMENSIÓN K (CONOCIMIENTO FINANCIERO) EN PRETEST Y POSTEST — DISTRIBUCIÓN DE PUNTAJES POR ESTUDIANTE	103
FIGURA 24. <i>DISTRIBUCIÓN DE PUNTAJES DE LA DIMENSIÓN C (CONDUCTA FINANCIERA) EN PRETEST Y POSTEST — COMPARACIÓN DE MEDIAS CON INTERVALO DE CONFIANZA AL 95 %</i>	105
FIGURA 25. PERFIL DE LA SITUACIÓN FINANCIERA INICIAL (PRETEST) DE LOS 77 ESTUDIANTES POR INDICADOR DE LA DIMENSIÓN R	107
FIGURA 26. COMPARACIÓN DE LA DISTRIBUCIÓN DEL IMFP GLOBAL EN PRETEST Y POSTEST — DIAGRAMAS DE CAJA (BOXPLOT).....	109
FIGURA 27. <i>EVOLUCIÓN INDIVIDUAL DEL IMFP DE LOS 77 ESTUDIANTES — PRETEST Y POSTEST CONECTADOS POR SEGMENTOS</i>	110
FIGURA 28. DIAGRAMA DE DISPERSIÓN IMFP PRETEST VS. POSTEST CON LÍNEA DE IDENTIDAD (45°) — LOS 77 ESTUDIANTES.....	112

RESUMEN

La presente investigación tuvo como objetivo desarrollar y validar un Modelo de Implementación de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores. El modelo se formalizó en cuatro capas funcionales —adquisición de datos financieros, procesamiento mediante un Modelo de Lenguaje de Gran Escala (LLM), generación de recomendaciones personalizadas y retroalimentación mediante el Índice de Mejora de Finanzas Personales (IMFP)— e implementó a través del sistema FinancIA, que incorpora el modelo llama3.2 ejecutado localmente mediante Ollama. El enfoque fue cuantitativo con diseño cuasi-experimental pretest-posttest de un solo grupo, aplicado a 77 estudiantes de un instituto de educación superior tecnológica de la región La Libertad, Perú. La validación técnica del modelo demostró su viabilidad operativa con indicadores de eficiencia compatibles con entornos educativos convencionales. La validación del impacto, medida mediante el instrumento CFPE-IMFP de 39 ítems, evidenció una mejora estadísticamente significativa y de efecto grande en la gestión financiera personal de los participantes (prueba de Wilcoxon, $p < 0,001$), con mejoras en las dimensiones de conocimiento, conducta y resultado financiero, y con el 98,7 % de los estudiantes transitando del nivel medio-bajo al nivel medio-alto del índice. Los resultados son consistentes con los hallazgos de investigaciones previas sobre sistemas de IA aplicados a la educación financiera y aportan evidencia empírica cuantitativa en un contexto latinoamericano no explorado previamente. Se concluye que el modelo propuesto constituye una herramienta técnicamente viable y educativamente efectiva para fortalecer la autonomía financiera de estudiantes de institutos superiores.

Palabras clave: Inteligencia artificial; finanzas personales; modelo de lenguaje de gran escala; educación financiera; institutos superiores.

ABSTRACT

This research aimed to develop and validate an Artificial Intelligence Implementation Model for the Improvement of Personal Finance in Technical Higher Education Students. The model was formalized into four functional layers — financial data acquisition, processing through a Large Language Model (LLM), generation of personalized recommendations, and feedback through the Personal Finance Improvement Index (IMFP) — and implemented via the FinancIA system, which incorporates the llama3.2 model running locally through Ollama. A quantitative approach with a quasi-experimental single-group pretest-posttest design was applied to 77 students at a technical higher education institute in the Lambayeque region, Peru. Technical validation demonstrated the model's operational feasibility with efficiency indicators compatible with conventional educational settings. Impact validation, measured through the 39-item CFPE-IMFP instrument, evidenced a statistically significant and large-effect improvement in participants' personal financial management (Wilcoxon test, $p < 0.001$), with improvements across the knowledge, conduct, and financial outcome dimensions, and 98.7% of students moving from the medium-low to the medium-high level of the index. Results are consistent with prior research on AI-based financial education systems and contribute quantitative empirical evidence in a previously unexplored Latin American context. It is concluded that the proposed model constitutes a technically viable and educationally effective tool for strengthening financial autonomy among technical higher education students.

Keywords: Artificial intelligence; personal finance; large language model; financial education; technical higher education.

I. INTRODUCCIÓN

1.1. DESCRIPCIÓN Y FORMULACIÓN DEL PROBLEMA

1.1.1. Realidad genérica del problema

La gestión de las finanzas personales constituye un aspecto fundamental para el bienestar económico y el desarrollo integral de los estudiantes de instituciones de educación superior. En este grupo poblacional, las dificultades relacionadas con la planificación financiera, el ahorro, la administración de deudas y el control de gastos son problemas recurrentes que impactan tanto en el rendimiento académico como en la calidad de vida (Batsurovska et al., 2024) (Marin & Notargiacomo, 2021) (Villarreal-Torres et al., 2023). Sin embargo, a pesar de la relevancia del tema, diversos estudios evidencian bajos niveles de alfabetización financiera en esta población, lo cual limita su capacidad para tomar decisiones económicas acertadas.

En el contexto peruano, esta problemática adquiere especial relevancia en los institutos de educación superior tecnológica, donde los estudiantes enfrentan restricciones económicas propias de su etapa formativa: ingresos irregulares, dependencia familiar, endeudamiento temprano y escasa cultura del ahorro. La ausencia de herramientas accesibles y personalizadas para la gestión financiera agrava estas condiciones y limita las posibilidades de tomar decisiones económicas responsables.

Ante este escenario, la Inteligencia Artificial (IA) emerge como una alternativa innovadora para fortalecer la educación financiera y mejorar la gestión de los recursos económicos individuales. En particular, los Modelos de Lenguaje de Gran Escala (LLM), sustentados en técnicas de aprendizaje automático (Machine Learning), aprendizaje profundo (Deep Learning), procesamiento del

lenguaje natural (NLP) y arquitecturas Transformer, permiten construir sistemas capaces de procesar información financiera compleja y generar recomendaciones personalizadas en tiempo real. Estos sistemas se adaptan a los hábitos, ingresos y gastos del usuario, generando estrategias ajustadas a sus necesidades específicas (Mehrfar et al., 2024) (Sofiia et al., 2025) (Ren et al., 2024). Asimismo, la IA puede integrarse a plataformas digitales existentes, lo que facilita su adopción y asegura una implementación escalable (Ramírez Téllez et al., 2024) (Huang, 2024).

Los métodos tradicionales de educación financiera presentan limitaciones conocidas: baja personalización, dependencia de instructores, ausencia de retroalimentación inmediata y dificultad para adaptarse al contexto individual de cada estudiante. En contraste, los sistemas basados en IA pueden superar estas restricciones al ofrecer orientación continua, análisis automatizado del comportamiento financiero y recomendaciones ajustadas al perfil de cada usuario (Olasiuk et al., 2023) (Hemachandran et al., 2022).

La presente investigación propone un Modelo de Implementación de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores, con el propósito de aportar una solución tecnológica que optimice la gestión económica individual y fomente la toma de decisiones responsables. El modelo incorpora componentes clave como la evaluación del nivel de alfabetización financiera, la identificación de problemas económicos recurrentes, la personalización de recomendaciones mediante algoritmos predictivos y el desarrollo de herramientas de planificación para el ahorro, el control de gastos y la reducción del endeudamiento. Asimismo, se integran principios de privacidad y seguridad de datos, garantizando la protección de la

información sensible de los participantes (Mehrfar et al., 2024) (Ramírez Téllez et al., 2024).

La validación del modelo se realizará a través de un programa piloto con métricas de rendimiento cuantitativas, lo que permitirá medir su impacto en la alfabetización financiera y el comportamiento económico de los estudiantes (Batsurovska et al., 2024) (Huang, 2024). De esta manera, la investigación busca demostrar tanto la viabilidad técnica de la propuesta como su aporte práctico al fortalecimiento de la educación financiera en el ámbito de la educación superior tecnológica.

1.1.2. Formulación del problema

¿En qué medida un modelo de implementación de Inteligencia Artificial mejora la gestión de las finanzas personales en estudiantes de institutos superiores?

1.2. OBJETIVOS

1.2.1 Objetivo General

Desarrollar un modelo de implementación de Inteligencia Artificial destinado a mejorar la gestión de las finanzas personales en estudiantes de institutos superiores.

1.2.2 Objetivos Específicos

- a) Analizar el estado actual de la gestión de finanzas personales en estudiantes de institutos superiores, como línea base para el diseño de la capa de adquisición de datos financieros (D) del modelo.
- b) Identificar las tecnologías de Inteligencia Artificial aplicables a la gestión financiera personal que sustenten el diseño de las capas de procesamiento mediante LLM (P) y de generación de recomendaciones (G) del modelo.

- c) Diseñar y construir la estructura funcional del modelo de Inteligencia Artificial —capas de adquisición de datos (D), procesamiento mediante LLM (P), generación de recomendaciones (G) y retroalimentación (F)— para la gestión de finanzas personales en estudiantes de institutos superiores.
- d) Validar la efectividad del modelo propuesto, mediante su implementación en el sistema FinancIA y la medición del cambio en la capa de retroalimentación (F), en la mejora de la gestión de finanzas personales en estudiantes de institutos superiores.

1.3. FORMULACIÓN DE LA HIPÓTESIS

La implementación de un modelo de Inteligencia Artificial mejora significativamente la gestión de las finanzas personales en estudiantes de institutos superiores.

1.4. JUSTIFICACIÓN E IMPORTANCIA

1.4.1. Conveniencia

La presente investigación constituye una iniciativa pertinente, dado que la implementación de modelos de Inteligencia Artificial (IA) en la gestión de las finanzas personales puede convertirse en una herramienta clave para la educación financiera de los estudiantes. El uso de arquitecturas avanzadas como Modelos de Lenguaje de Gran Escala (LLM), soportados por técnicas de aprendizaje automático (ML, procesamiento de lenguaje natural (NLP) y Transformers, permite procesar información financiera compleja y brindar recomendaciones personalizadas en tiempo real. En la actualidad, los métodos tradicionales de enseñanza financiera presentan limitaciones, tales como baja personalización, dependencia de instructores y ausencia de retroalimentación inmediata. Estos obstáculos impactan en la

capacidad de los jóvenes para desarrollar hábitos de ahorro, planificación presupuestaria y uso responsable del crédito. Por tanto, resulta conveniente evaluar cómo los LLM aplicados al ámbito educativo pueden mejorar la autonomía y la toma de decisiones financieras en los estudiantes.

1.4.2. Relevancia social

La gestión adecuada de las finanzas personales no solo tiene implicancias a nivel individual, sino también repercusiones directas en la sociedad. Una población con mejores hábitos de ahorro, planificación y control del endeudamiento contribuye a la estabilidad económica familiar y, por extensión, al bienestar comunitario. En el caso de los estudiantes de Institutos Superiores, la introducción de herramientas basadas en IA puede ayudarlos a enfrentar los desafíos económicos propios de esta etapa de vida, reduciendo la morosidad, fomentando la cultura del ahorro y promoviendo un uso responsable de los recursos. De este modo, la investigación aporta beneficios sociales al sentar bases para una generación más consciente de sus decisiones financieras, lo que repercute en la reducción de la pobreza, la mejora del capital humano y la sostenibilidad económica.

1.4.3. Valor teórico

El valor teórico de la investigación radica en la aplicación de los LLM como recurso emergente en la educación financiera, un campo en el que aún existe limitada evidencia empírica. A diferencia de los enfoques tradicionales de asesoría y enseñanza, los LLM poseen la capacidad de procesar grandes volúmenes de datos y adaptarse a los patrones de comportamiento de los estudiantes, generando funciones de recomendación personalizadas. Desde una perspectiva académica, este trabajo busca enriquecer el cuerpo de conocimientos sobre la integración de arquitecturas

de IA de última generación en la gestión de finanzas personales, aportando un marco conceptual y experimental que pueda ser replicado y ampliado en futuras investigaciones interdisciplinarias.

1.4.4. Implicancias prácticas

El desarrollo de un modelo basado en Inteligencia Artificial para la mejora de las finanzas personales tiene el potencial de transformar los procesos educativos y de asesoría financiera. Al ser capaz de generar recomendaciones precisas sobre ahorro, inversión y control presupuestal, el modelo puede mejorar significativamente la alfabetización financiera de los estudiantes. Además, su capacidad de personalización permite que cada usuario reciba retroalimentación ajustada a sus ingresos, gastos y hábitos de consumo, superando las limitaciones de los programas tradicionales. La aplicabilidad del modelo no se restringe al ámbito educativo, sino que puede extenderse a sectores como la banca digital, la asesoría financiera personalizada y las políticas públicas de inclusión financiera.

1.4.5. Utilidad metodológica

1.4.6. Delimitación y justificación de la población de estudio

La elección de estudiantes de institutos de educación superior tecnológica como población de estudio, y no de segmentos con mayor volumen de manejo de capital como empresarios o dueños de negocio, responde a un criterio de pertinencia y de brecha de investigación, y no únicamente de conveniencia operativa. La literatura revisada en el Capítulo II documenta que la etapa formativa superior es el periodo en que se consolidan los hábitos financieros que persisten en la vida adulta (Calisaya Quenta et al., 2023; Rubio Sáenz et al., 2023), mientras que los antecedentes sobre IA aplicada a finanzas personales se concentran mayoritariamente en usuarios con ingresos estables o en contextos

de inversión institucional (Ambuli et al., 2024; Zhu et al., 2024), dejando sin evidencia empírica suficiente a la población estudiantil, que enfrenta condiciones particulares (ingresos irregulares, dependencia familiar, endeudamiento temprano) no equiparables a las de un empresario. Intervenir sobre esta población resulta además operativamente viable para un diseño cuasi-experimental de alcance doctoral, al tratarse de un grupo accesible dentro de una institución educativa, condición que permite aplicar el esquema pretest-postest bajo condiciones controladas. La extensión del modelo propuesto a poblaciones con mayor volumen de manejo de capital, como emprendedores o pequeños empresarios, se reconoce como una línea de investigación futura (ver Capítulo V, sección 5.2).

Desde la perspectiva metodológica, la investigación aporta un enfoque experimental novedoso que combina la validación de un modelo emergente (LLM) con indicadores objetivos de desempeño (precisión, exactitud, recall, F1 Score) y métricas financieras (nivel de ahorro, reducción de deudas, cumplimiento presupuestal). Este esquema permite comparar el efecto de la intervención con respecto a métodos tradicionales de educación financiera, ofreciendo un marco replicable en distintos contextos educativos. Asimismo, al integrar metodologías de la computación y de las ciencias sociales, el estudio refuerza su carácter interdisciplinario, estableciendo un precedente para investigaciones futuras que busquen aplicar IA en la resolución de problemas económicos y educativos reales.

II. MARCO TEÓRICO

2.1. ANTECEDENTES

Los antecedentes presentados a continuación corresponden a investigaciones seleccionadas por su pertinencia directa con los ejes temáticos de la presente investigación:

aplicación de Inteligencia Artificial en la gestión de finanzas personales, sistemas de recomendación financiera para estudiantes y evaluación del impacto de herramientas digitales en la educación financiera. La revisión se organiza de manera que permita identificar convergencias, brechas y la posición de esta investigación dentro del estado del arte

Zhu et al. (2024), en su trabajo analizan el impacto de los asesores financieros personales impulsados por IA en la mejora del bienestar financiero individual. Se utilizó un enfoque basado en técnicas de análisis de datos y modelado predictivo, que permitió generar recomendaciones personalizadas en áreas como presupuestos, planificación de inversiones, gestión de deudas y preparación para la jubilación. Los resultados muestran que el uso de IA favorece la optimización de portafolios, la evaluación de riesgos y el monitoreo en tiempo real de los mercados, lo que se traduce en una mayor educación financiera, rentabilidad y bienestar general de los usuarios. Asimismo, el estudio subraya la importancia de abordar los aspectos éticos y de privacidad en la implementación de estas tecnologías, proponiendo un marco de despliegue transparente que promueva la confianza y la aceptación por parte de los usuarios. En conclusión, los asesores financieros basados en IA demuestran un potencial transformador en la gestión financiera personal, siempre que su aplicación se realice de manera responsable.

Su relevancia para la presente investigación radica en que establece la base conceptual de los asesores financieros automatizados y subraya la importancia del diseño centrado en la confianza del usuario, un principio que orienta el desarrollo del módulo de Inteligencia Artificial del presente trabajo.

Vaduka et al., (2024) analizan la integración de la Inteligencia Artificial en sistemas de apoyo a la toma de decisiones para la gestión financiera personal, ante la insuficiencia de los enfoques tradicionales frente a la creciente volatilidad de los mercados y la diversidad

de metas individuales. El método emplea algoritmos avanzados de IA para el análisis de datos y la predicción de tendencias, generando recomendaciones personalizadas en elaboración de presupuestos, estrategias de inversión, gestión de deudas y planificación para el retiro.

Los resultados evidencian que los sistemas impulsados por IA mejoran la calidad de las decisiones financieras personales, fortalecen la salud financiera general y proporcionan herramientas prácticas accesibles especialmente para usuarios sin formación financiera avanzada, como los estudiantes. Los autores identifican como desafíos centrales la privacidad de los datos y la transparencia algorítmica, señalando que su resolución es condición necesaria para un despliegue responsable.

Este antecedente resulta pertinente porque valida el enfoque de personalización basado en datos como estrategia eficaz para mejorar la toma de decisiones económicas, principio que subyace al diseño del modelo propuesto en la presente investigación.

En el trabajo de Amos Abidemi Ogunola y Adriana N Dugbartey (2024), se analiza el uso de herramientas financieras impulsadas por IA en la gestión de las finanzas personales de los estudiantes, con énfasis en el manejo de la deuda estudiantil. Se utilizó un método de análisis de aplicaciones financieras basadas en IA, incluyendo plataformas de presupuestación personalizada, servicios de refinanciación y sistemas de consolidación de deudas, evaluando su capacidad para optimizar decisiones financieras.

Los resultados evidencian que estas herramientas simplifican la toma de decisiones financieras complejas, promueven una mejor educación financiera y permiten a los prestatarios gestionar de forma más eficaz su deuda, fortaleciendo su estabilidad económica. Asimismo, el estudio resalta que la aplicación de la IA en finanzas personales debe considerar aspectos éticos y de privacidad de datos, así como el riesgo de sesgos algorítmicos, para garantizar un uso responsable y confiable.

Este trabajo aporta evidencia directa sobre la efectividad de sistemas de IA orientados al perfil de estudiantes de educación superior, que constituye exactamente la población objetivo de la presente investigación.

Gorai y Amarmaurya (2025), investigan el papel de la Inteligencia Artificial en la gestión financiera de estudiantes, centrando el análisis en las aplicaciones Mint y Betterment como casos de referencia. Mediante el análisis de sus funcionalidades, el estudio evalúa el seguimiento personalizado del gasto, la generación de consejos de inversión ajustados al perfil de riesgo y las estrategias de pago de deudas basadas en patrones de comportamiento financiero.

Los resultados muestran que la IA mejora significativamente la eficiencia y la personalización en la gestión financiera, fomentando la responsabilidad individual. Sin embargo, el trabajo identifica desafíos éticos persistentes relacionados con la privacidad de los datos y el sesgo algorítmico, cuya atención es indispensable para garantizar un uso equitativo y confiable de estas tecnologías.

La contribución de este antecedente a la presente investigación consiste en identificar criterios concretos de evaluación de herramientas de IA financiera, personalización, seguimiento en tiempo real, ajuste al perfil de riesgo, que informan el diseño del sistema implementado en el presente estudio y del IMFP.

En el trabajo de H Varghese et al. (2024), se examina el impacto de los robo-asesores impulsados por IA en la gestión financiera de los estudiantes. El sistema analizado emplea algoritmos sofisticados y técnicas de aprendizaje automático aplicadas al análisis de datos financieros e historial de preferencias individuales, ofreciendo herramientas de presupuestación personalizada, asesoría de inversión y estrategias automatizadas de gestión de la deuda.

Los resultados demuestran que los robo-asesores permiten una gestión automatizada de carteras con mínima intervención humana, mejorando la eficiencia en la toma de decisiones y democratizando el acceso al asesoramiento financiero de calidad. Este hallazgo es particularmente relevante para poblaciones estudiantiles con acceso limitado a asesores financieros profesionales.

La noción de democratización del asesoramiento financiero es un aporte teórico directo al fundamento social de la presente investigación, que busca poner al alcance de los estudiantes de institutos superiores una orientación financiera personalizada a través de tecnología de bajo costo.

Pawar et al. (2024), presenta ExpenseXpert, un sistema innovador diseñado para mejorar la gestión de las finanzas personales de los estudiantes mediante el uso de IA y ML. Se empleó un método tecnológico basado en algoritmos de IA/ML que permite el seguimiento automatizado de gastos, la elaboración de presupuestos personalizados a partir de patrones de consumo y la provisión de información financiera en tiempo real.

Los resultados muestran que ExpenseXpert optimiza la elaboración y el control de presupuestos, al ofrecer planes ajustados a las necesidades individuales, generar resúmenes descargables en PDF y Excel, y emitir notificaciones proactivas cuando los usuarios superan sus límites de gasto, lo que fomenta la disciplina financiera y la toma de decisiones más informadas en materia de inversión y gestión de deudas. La investigación demuestra la viabilidad técnica de un sistema de IA ligero y orientado a estudiantes, lo que refuerza la factibilidad tecnológica del sistema FinancIA propuesto en esta tesis.

En el trabajo de Balathas (2022), se propone MoneyEmpire, una aplicación móvil basada en Inteligencia Artificial para la automatización de la gestión financiera personal en contextos de economías en desarrollo, tomando como caso Sri Lanka. El método integra visión por computadora (Pytesseract y Microsoft Azure Cognitive Services) para la

extracción de texto desde imágenes, procesamiento de expresiones regulares y técnicas de lenguaje natural para identificar y clasificar transacciones desde SMS bancarios y comprobantes de gastos.

Los resultados muestran alta precisión en la clasificación automática de transacciones y un flujo de gestión financiera efectivamente automatizado, facilitando el seguimiento de gastos y la planificación presupuestaria en usuarios con escasos conocimientos financieros. El trabajo establece un precedente metodológico para el desarrollo de sistemas de IA financiera en contextos de recursos limitados, directamente equiparables a la realidad de los institutos superiores en regiones de Perú.

Lawrence Damilare Oyeniyi et al.(2024), realizan una revisión sistemática de literatura sobre el papel transformador de la Inteligencia Artificial en la planificación financiera, analizando su evolución histórica, aplicaciones vigentes y los desafíos que plantea su integración. La metodología se basa en el análisis cualitativo de literatura académica revisada por pares y estudios empíricos, con el fin de identificar beneficios, limitaciones y brechas de investigación.

Los resultados confirman que la IA actúa como catalizador de eficiencia operativa y mejora de la toma de decisiones estratégicas, con aplicaciones consolidadas en presupuestación, asesoría de inversiones y gestión de deudas. Los autores identifican desafíos éticos y regulatorios vinculados a la transparencia, el sesgo algorítmico y el cumplimiento normativo, proponiendo un enfoque que equilibre innovación con responsabilidad.

Esta revisión sistemática es el antecedente de mayor alcance teórico incluido en el estado del arte, y fundamenta la necesidad de investigaciones empíricas que validen el impacto de sistemas de IA en contextos educativos específicos, brecha que la presente investigación se propone cubrir.

En el trabajo de Wilhelmina Afua Addy et al. (2024), analiza la integración de la IA en la planificación financiera, destacando su papel transformador en la presupuestación, la asesoría de inversiones y la gestión de deudas, especialmente para estudiantes y usuarios que buscan optimizar sus decisiones financieras.

La metodología se basó en un análisis cualitativo, mediante la revisión rigurosa de literatura académica revisada por pares y estudios empíricos, con el propósito de identificar tanto los avances como los retos que supone la adopción de la IA en el ámbito financiero. Los resultados muestran que la IA funciona como un catalizador de eficiencia y precisión en la toma de decisiones financieras y en la gestión operativa, aportando un valor estratégico significativo. Al mismo tiempo, se reconocen nuevos desafíos, principalmente vinculados a las consideraciones éticas, el sesgo algorítmico y el cumplimiento regulatorio, lo que exige un enfoque responsable.

Ambuli et al. (2024), presentan un sistema de gestión financiera basado en IA para la optimización de carteras de inversión mediante técnicas avanzadas de aprendizaje automático. El método comprende la recolección y preprocesamiento de grandes volúmenes de datos financieros, el entrenamiento de modelos predictivos para detectar tendencias y oportunidades, y la implementación de un mecanismo de rebalanceo dinámico de portafolios en función de las condiciones de mercado.

En la evaluación de desempeño, el sistema alcanzó un retorno anual promedio (ROI) del 12,5%, un Sharpe Ratio de 1,2 y una pérdida máxima (drawdown) controlada de -5,2%, superando a los métodos tradicionales de gestión de inversiones en escenarios de mercado alcistas, bajistas y estancados. Aunque el enfoque de este trabajo difiere del de la presente investigación —centrado en inversión institucional más que en educación financiera estudiantil—, aporta evidencia cuantitativa sobre la superioridad de los modelos de IA

frente a los métodos convencionales, argumento que refuerza la justificación del modelo propuesto.

El análisis de los antecedentes permite identificar tres tendencias consolidadas en la literatura: (a) la efectividad de los sistemas de IA para mejorar la toma de decisiones financieras en usuarios no especializados, especialmente estudiantes; (b) la convergencia en torno a desafíos éticos comunes —privacidad, sesgo algorítmico y transparencia— que deben ser considerados en el diseño de cualquier sistema de este tipo; y (c) la escasez de investigaciones que validen empíricamente el impacto de modelos LLM en la educación financiera de estudiantes de institutos superiores en contextos latinoamericanos. Esta última brecha constituye la principal contribución que la presente investigación se ha propuesto realizar.

2.2. FUNDAMENTACIÓN TEÓRICA

2.2.1. Finanzas

Finanzas personales

Las finanzas personales constituyen el conjunto de prácticas, conocimientos y actitudes orientadas a la gestión eficiente de los recursos económicos individuales o familiares, abarcando el manejo del ingreso, el gasto, el ahorro, la inversión y el endeudamiento. Su objetivo central es alcanzar un equilibrio financiero que permita satisfacer necesidades básicas, afrontar contingencias y construir bienestar económico sostenible a lo largo del tiempo.

Estudios recientes en revistas indexadas destacan la estrecha relación entre la educación financiera y la correcta gestión de los recursos personales. Calisaya Quenta et al. (2023) evidencian que el nivel de educación financiera se correlaciona de manera positiva y significativa con una mejor administración presupuestaria en estudiantes jóvenes (coeficiente de correlación = 0,859; $p < 0,005$), lo que sugiere que la formación financiera

es un instrumento efectivo para mejorar la estabilidad económica personal. Estos hallazgos son consistentes con los reportados por Rubio Sáenz et al. (2023), quienes señalan que la educación financiera debe ir más allá del conocimiento declarativo y orientarse al desarrollo de actitudes y comportamientos que promuevan la autonomía económica y la reducción de vulnerabilidades ante crisis.

En términos prácticos, la gestión adecuada de las finanzas personales requiere: el establecimiento de metas financieras claras y alcanzables, el seguimiento riguroso del flujo de caja, la priorización del ahorro como práctica sistemática, y el incremento progresivo del patrimonio a través de inversiones diversificadas y ajustadas al perfil de riesgo del individuo. La aplicación sostenida de estos principios contribuye a mejorar la calidad de vida y el bienestar socioeconómico de la población (Calisaya Quenta et al., 2023).

En el contexto de los estudiantes de institutos superiores, la gestión de finanzas personales presenta características particulares: ingresos irregulares o dependientes de transferencias familiares, gastos asociados a la formación (transporte, materiales, alimentación fuera del hogar) y limitada experiencia en la administración de recursos propios. Estas condiciones hacen de este grupo una población especialmente vulnerable a desequilibrios financieros y, al mismo tiempo, particularmente receptiva a intervenciones educativas orientadas a mejorar sus competencias económicas.

La pirámide de Maslow aplicada a las finanzas personales

La jerarquía de necesidades propuesta por Maslow (1943) organiza las motivaciones humanas en cinco niveles progresivos: necesidades fisiológicas, de seguridad, sociales o de pertenencia, de estima y de autorrealización. Aunque concebida originalmente en el contexto de la psicología motivacional, su estructura ha sido ampliamente adoptada en el análisis financiero para priorizar la asignación de recursos económicos en función de la importancia relativa de las necesidades del individuo.

La aplicación financiera de la pirámide propone una correspondencia entre niveles de necesidad y objetivos económicos: las necesidades fisiológicas se asocian a la cobertura de gastos básicos (alimentación, vivienda, salud); la seguridad financiera implica la creación de fondos de emergencia, la contratación de seguros y la estabilidad laboral como mecanismos de protección ante contingencias (Korankye et al., 2024); las necesidades sociales y de estima se reflejan en gastos orientados a la educación, la participación cultural y la construcción de capital social; y la autorrealización financiera corresponde a metas de emprendimiento, inversión en proyectos personales y contribución a causas de interés (Brownell et al., 2025).

Esta jerarquía ofrece un marco práctico para que los individuos organicen su presupuesto de manera escalonada y coherente, evitando desequilibrios que comprometan la estabilidad económica básica mientras se persiguen metas de mayor orden, aunque estudios recientes matizan que el orden estricto de la jerarquía no siempre se sostiene empíricamente (Méndez & Rojas, 2024). Madero Gómez (2022) valida empíricamente esta correspondencia, mostrando que la insatisfacción en los niveles básicos de la jerarquía impacta negativamente en los niveles superiores, incluyendo la atracción y retención del talento humano en contextos laborales (Madero Gómez, 2022).

En la aplicación desarrollada en la presente tesis, donde se aplica un modelo basado en IA, el marco de Maslow se operacionaliza en el módulo de encuesta financiera y en la lógica de recomendación del asistente inteligente: las consultas y recomendaciones se priorizan en función del nivel de necesidad identificado en el perfil del usuario, asegurando que las orientaciones sean pertinentes y contextualmente adecuadas a la situación real de cada estudiante.




Figura 1. Pirámide de Maslow

Fuente: Adaptado de Maslow (1943) y Korankye et al. (2024).

Inteligencia Artificial aplicada a las finanzas personales

La IA comprende el conjunto de técnicas computacionales que permiten a los sistemas aprender de datos, identificar patrones complejos y generar respuestas o predicciones sin ser explícitamente programados para cada caso. En el ámbito de las finanzas personales, la IA ha transformado de manera fundamental los procesos de análisis, asesoría y toma de decisiones, al introducir capacidades de personalización y procesamiento a escala que los métodos tradicionales no pueden proporcionar (Mienye & Swart, 2024).

El proceso de toma de decisiones asistido por IA comprende etapas secuenciales: (1) recopilación y preprocesamiento de datos financieros individuales; (2) análisis mediante modelos predictivos o generativos; (3) evaluación de escenarios alternativos; y (4) generación y comunicación de recomendaciones personalizadas (Pak, 2026). La implementación de este ciclo en sistemas interactivos permite, además, la automatización de decisiones rutinarias, como la categorización de gastos o la emisión de alertas por

desviaciones presupuestarias, liberando la capacidad cognitiva del usuario para enfocarse en decisiones estratégicas de mayor impacto (Afrin et al., 2025).

Investigaciones recientes confirman que el uso de sistemas basados en IA incrementa significativamente la confianza de los usuarios en sus decisiones financieras, mejora indicadores cuantificables como la tasa de ahorro y la eficiencia en la asignación del presupuesto, y reduce la incidencia de errores cognitivos habituales en la gestión económica personal, como el sesgo de presente o la aversión a las pérdidas (Neyyila et al., 2025). En conjunto, la adopción de IA en este dominio representa un desplazamiento paradigmático desde enfoques basados en reglas fijas o en la intuición individual hacia sistemas adaptativos capaces de aprender del comportamiento del usuario.

2.2.2. Modelos de clasificación en finanzas personales

Los modelos de clasificación son una rama fundamental del aprendizaje automático que permite categorizar datos en grupos o clases predefinidas. En el ámbito de las finanzas personales, estos modelos se emplean para tomar decisiones binarias o multicategoría, tales como la aprobación de créditos, detección de fraudes, clasificación de riesgos financieros o categorización de gastos.

La literatura científica destaca que técnicas clásicas como la regresión logística, árboles de decisión, máquinas de vectores de soporte (SVM) y redes neuronales son comúnmente aplicadas para clasificación en finanzas debido a su capacidad para manejar datos heterogéneos y de alta dimensionalidad (Sahu et al., 2023). Estos modelos permiten transformar variables financieras cuantitativas y cualitativas en etiquetas que facilitan la toma de decisiones automatizadas.

En particular, estudios recientes han demostrado que la integración de modelos de clasificación con sistemas expertos mejora significativamente la precisión en la evaluación crediticia y en la gestión de riesgos financieros personales. Por ejemplo, un modelo híbrido

basado en árboles de decisión y SVM alcanzó una precisión del 92% en identificar perfiles de riesgo en préstamos personales (Chang et al., 2024).

Además, los modelos de clasificación pueden ser adaptativos, lo que implica que ajustan sus parámetros en función del feedback continuo, mejorando su desempeño en contextos dinámicos y cambiantes, como el mercado financiero personal. Esto incrementa la confiabilidad de las decisiones apoyadas en IA, haciéndolas más robustas frente a variaciones en el comportamiento del usuario o condiciones económicas (Yang, 2024).

Finalmente, la transparencia e interpretabilidad de estos modelos se han incrementado con nuevas técnicas explicativas, lo que es crucial para que los usuarios comprendan las decisiones automáticas y confíen en los sistemas financieros basados en IA (Rane, 2023).

Modelos de aprendizaje automático para series temporales financieras

ML son un conjunto avanzado de técnicas que permiten a los sistemas informáticos aprender directamente de los datos, detectar patrones ocultos y realizar predicciones sin ser explícitamente programados para cada tarea específica. En finanzas personales, estos modelos constituyen un componente esencial para la automatización y optimización de decisiones financieras personalizadas.

Investigaciones recientes indican que algoritmos como las redes neuronales artificiales (ANN), métodos ensemble (Random Forest, Gradient Boosting), SVM y largas memorias a corto plazo (LSTM) son ampliamente utilizados para tareas como la predicción de gastos, análisis de crédito, administración de portafolios y detección de fraudes (Pak, 2026).

Las ANN replican el funcionamiento del cerebro humano para procesar información compleja, resultando eficaces en el reconocimiento de patrones no lineales en el comportamiento financiero individual. Por su parte, las LSTM permiten modelar series temporales financieras, previendo fluctuaciones en ingresos y gastos futuros con un alto grado de precisión (Bayakhmetova et al., 2025).

Además, los modelos ML incorporan mecanismos de ajuste continuo basados en retroalimentación, lo que se traduce en sistemas de asesoría financiera inteligentes y adaptativos que mejoran la calidad y personalización de las recomendaciones, incrementando la satisfacción y confianza del usuario (Adadi & Berrada, 2018).

Los beneficios reportados incluyen una reducción significativa en errores humanos, mayor exactitud en la predicción de riesgos, optimización en la asignación de presupuestos y una mejor capacidad para anticipar cambios en la situación financiera personal. No obstante, expertos destacan la importancia de integrar la interpretabilidad de estos modelos para garantizar la transparencia y facilitar la confianza de los usuarios en las decisiones automatizadas (Mienye & Swart, 2024).




Figura 2. Arquitectura comparativa: RNN con celdas LSTM frente a arquitectura Transformer

Fuente: Vaswani et al. (2017)

Arquitecturas Transformer y Modelos de Lenguaje de Gran Escala (LLM)

La arquitectura Transformer, introducida por Vaswani et al. (2017), representó un punto de inflexión en el procesamiento del lenguaje natural (NLP) al sustituir la recurrencia secuencial de las RNN por un mecanismo de atención multi-cabeza (multi-head self-attention) que permite procesar todas las posiciones de una secuencia de manera paralela.

Esta capacidad de capturar dependencias de largo alcance de forma eficiente posibilitó el entrenamiento de modelos de lenguaje de escala sin precedentes.

Los Modelos de Lenguaje de Gran Escala (Large Language Models, LLM) son redes Transformer preentrenadas en corpus masivos de texto que adquieren la capacidad de generar, resumir, clasificar y razonar sobre texto en lenguaje natural. Modelos como GPT-4 (OpenAI), LLaMA-3 (Meta AI) y sus derivados han demostrado un rendimiento sobresaliente en tareas de comprensión, generación y diálogo contextualizado (Touvron et al., 2023). Su capacidad de seguir instrucciones (instruction following) mediante técnicas de ajuste fino supervisado (SFT) y aprendizaje por refuerzo con retroalimentación humana (RLHF) los hace especialmente adecuados para aplicaciones de asesoría personalizada.

En el contexto de las finanzas personales, los LLM ofrecen una ventaja sustancial frente a los modelos de ML tradicionales: la capacidad de interactuar con el usuario en lenguaje natural, interpretar consultas en contexto y generar recomendaciones explicadas en términos comprensibles para usuarios sin formación técnica. Esta propiedad tiene un impacto pedagógico directo en la educación financiera, ya que el proceso de consulta y respuesta puede convertirse en una instancia de aprendizaje activo para el estudiante.

Prompt engineering en sistemas de asesoría financiera

El prompt engineering es la disciplina que estudia el diseño, estructuración y optimización de las instrucciones (prompts) enviadas a un modelo de lenguaje para guiar la generación de respuestas hacia resultados deseados. En el contexto de los sistemas de asesoría financiera basados en LLM, el diseño del prompt es determinante para la calidad, coherencia y pertinencia de las recomendaciones generadas.

Un prompt financiero efectivo debe cumplir al menos tres condiciones: (a) proveer al modelo el contexto financiero real del usuario de manera estructurada y completa; (b) definir el rol del modelo de manera explícita (por ejemplo, 'actúa como un asesor

financiero educativo orientado a estudiantes'); y (c) establecer el formato y el nivel de detalle esperado en la respuesta, de modo que el output sea directamente utilizable por el usuario sin procesamiento adicional (White et al., 2023).

En el presente estudio, el prompt se construye dinámicamente en cada sesión incorporando los datos financieros actualizados del estudiante, totales de ingreso y gasto, saldo disponible, ratio gasto/ingreso, categorías principales de consumo y movimientos recientes. Esta arquitectura de prompt contextualizado garantiza que las recomendaciones generadas sean específicas a la situación económica del usuario y no respuestas genéricas que podrían obtenerse sin acceso a los datos reales.

2.2.3. Técnicas de minería de datos

La minería de datos (data mining) es una disciplina que utiliza técnicas estadísticas, algoritmos y aprendizaje automático para extraer conocimiento útil de grandes volúmenes de datos. En el ámbito de las finanzas personales, la minería de datos ha adquirido un rol clave para transformar datos crudos en información procesable, facilitando la toma de decisiones financieras más inteligentes y personalizadas.

Los avances recientes en aplicaciones fintech evidencian que las técnicas de minería de datos permiten un análisis profundo de los patrones de gasto, comportamientos de ahorro e inversión y detección de fraudes. Herramientas modernas emplean algoritmos de clustering para segmentar perfiles financieros y detectar anomalías inusuales que podrían indicar riesgos o fraudes (Gupta et al., 2026).

Además, técnicas predictivas derivadas de la minería de datos, como análisis de tendencias y modelos de regresión avanzada, mejoran la anticipación de gastos futuros y la planificación presupuestaria personalizada. Estas técnicas automatizan la categorización de transacciones con alta precisión, considerando contexto como ubicación, fecha y tipo de comercio, adaptándose al estilo de vida del usuario.

En 2025, la integración de minería de datos con inteligencia artificial ha potenciado la generación de alertas en tiempo real sobre desviaciones presupuestarias o movimientos sospechosos, fortaleciendo la seguridad y control financiero. Esta capacidad proactiva permite al usuario mantenerse informado y actuar con rapidez frente a posibles fraudes o excesos en gastos.

Asimismo, la minería de datos ayuda a personalizar recomendaciones financieras, ajustando estrategias de ahorro e inversión basadas en el análisis continuo de la información individual, favoreciendo una gestión financiera efectiva y adaptativa a las circunstancias cambiantes del mercado y la vida personal.

2.2.4. Innovaciones tecnológicas

La gestión financiera personal está experimentando una transformación profunda, impulsada por innovaciones tecnológicas que amplían el acceso, personalización y eficiencia de los servicios financieros. Para 2025, se destacan varias tecnologías que ya están revolucionando este ecosistema.

Aplicaciones de inversión automatizada (robo-advisors)

Plataformas que emplean algoritmos avanzados generan portafolios personalizados, accesibles para usuarios sin experiencia previa. Herramientas como Wealthfront o Betterment permiten automatizar la distribución y rebalanceo de inversiones, facilitando una gestión eficiente y diversificada.

Inteligencia Artificial predictiva

La IA ha avanzado para anticipar comportamientos del mercado y del consumidor con gran precisión, optimizando en tiempo real la toma de decisiones financieras. Empresas financieras líderes ya utilizan modelos predictivos que ayudan a identificar oportunidades y riesgos antes de que ocurran

Plataformas de educación financiera gamificadas

Estas herramientas convierten el aprendizaje económico en una experiencia interactiva y atractiva, aumentando la alfabetización financiera a través de recompensas y competencias, como lo muestran aplicaciones populares entre jóvenes y profesionales

Pagos digitales y finanzas descentralizadas (DeFi)

Las finanzas descentralizadas eliminan intermediarios y facilitan transacciones seguras, rápidas y de bajo costo. Plataformas como Uniswap impulsan esta tendencia, que para 2025 se proyecta con un crecimiento sostenido en inclusión financiera y eficiencia operativa.

Asistentes financieros por voz

El uso de asistentes como Alexa o Google Assistant en la gestión financiera personal se consolida, permitiendo operaciones bancarias y seguimiento de inversiones mediante comandos de voz, lo que mejora la accesibilidad y experiencia de usuario.

Realidad Aumentada y Realidad Virtual

Herramientas basadas en AR y VR facilitan la visualización inmersiva de escenarios financieros complejos, ayudando a usuarios a entender mejor sus finanzas y planificaciones a futuro.

La integración de estas innovaciones está redefiniendo el sector financiero, promoviendo un ecosistema más inteligente, accesible y personalizado que potencia la autonomía y bienestar económico de las personas.

2.2.5. Chatbots para asistencia financiera

Los chatbots basados en IA han emergido como herramientas esenciales para brindar asistencia financiera personalizada, accesible las 24 horas y en múltiples canales digitales. Estos asistentes virtuales automatizan la interacción con los usuarios para responder inquietudes sobre finanzas personales, seguimiento de gastos, inversiones y planificación financiera, transformando la experiencia tradicional de servicios financieros.

Una de las funciones más valoradas es el rastreo y categorización automática de gastos, lo que permite a los usuarios monitorear sus finanzas en tiempo real y recibir notificaciones sobre presupuestos excedidos o movimientos sospechosos. Los chatbots pueden también generar reportes financieros personalizados y ofrecer recomendaciones claras basadas en el análisis de los patrones de consumo y objetivos financieros.

Más allá de la asesoría básica, los chatbots avanzados proporcionan consejos financieros personalizados, sugiriendo ajustes en presupuestos, opciones de inversión y estrategias de ahorro adaptadas al perfil del usuario. Esta personalización se logra mediante el análisis de datos históricos, preferencias y hábitos, convirtiendo al chatbot en un asesor virtual proactivo (Nguyen & Le, 2025).

En términos operativos, brindan soporte para procesos complejos como la solicitud de créditos o gestión de facturas, agilizando trámites y facilitando la comunicación con entidades financieras. También contribuyen a la detección temprana de fraudes, alertando a los usuarios sobre actividades inusuales en sus cuentas (Yang et al., 2026).

Para 2025 se espera que los chatbots financieros continúen evolucionando incorporando capacidades predictivas y emocionalmente inteligentes, anticipando necesidades, ajustando el tono de comunicación y ofreciendo una experiencia cada vez más humana y empática, lo cual refuerza la confianza del usuario y mejora la inclusión financiera digital (Marak & Ayyagari, 2025).

2.2.6. Aplicaciones financieras en educación superior

La integración de tecnologías financieras innovadoras en instituciones de educación superior ha ganado relevancia creciente para optimizar la gestión económica de estudiantes y mejorar su experiencia académica. Las aplicaciones FinTech ofrecen soluciones eficientes para el manejo de presupuestos, administración de ayudas financieras, pagos y análisis de gastos en comunidades universitarias.

Estas herramientas permiten a las universidades implementar sistemas digitales que facilitan el acceso y control de recursos de becas, préstamos estudiantiles y subsidios gubernamentales, asegurando procesos más transparentes y ágiles. El uso de plataformas inteligentes mejora la capacidad de análisis para detectar patrones de uso y anticipar necesidades particulares que influyen en el rendimiento académico y la estabilidad financiera de los estudiantes.

Además, las soluciones FinTech integran funciones de análisis de gastos y presupuestos personales que apoyan a estudiantes para administrar de manera autónoma sus finanzas durante el ciclo académico. La gamificación y las recomendaciones personalizadas, basadas en el aprendizaje automático, promueven hábitos financieros saludables adaptados al entorno universitario.

Estas innovaciones no solo facilitan la gestión financiera, sino que también contribuyen a la inclusión financiera, permitiendo que estudiantes con menos recursos accedan a productos financieros digitales con condiciones favorables y plazos flexibles (Torkian et al., 2025). En definitiva, las aplicaciones FinTech en educación superior representan un avance sustancial que cohesiona la formación académica con la gestión responsable y eficiente de las finanzas personales de la comunidad estudiantil.

Análisis de gastos

El análisis de gastos (spending analysis) en instituciones de educación superior es una práctica clave para optimizar los recursos financieros y garantizar la sostenibilidad económica en un contexto de creciente presión presupuestaria y demandas académicas. Herramientas avanzadas de análisis financiero permiten desglosar y evaluar los gastos operacionales, inversiones en infraestructura, apoyo estudiantil y otros rubros cruciales para la administración universitaria (Ramírez Téllez et al., 2024).

Estas soluciones ofrecen visualizaciones interactivas que facilitan la identificación de las fuentes principales de gasto, comparaciones entre presupuestos previstos y gastos reales, y tendencias en categorías como mantenimiento, investigación, becas y licencias. Al proporcionar múltiples perspectivas, permiten a los directivos tomar decisiones estratégicas fundamentadas y ajustar planes financieros para mejorar la eficiencia.

Iniciativas recientes incorporan modelos predictivos que anticipan variaciones en las necesidades financieras de las instituciones educativas según inscripción estudiantil y cambios en políticas públicas, lo que habilita la planificación anticipada y la mitigación de riesgos económicos. Asimismo, el análisis continuo de gastos es vital para identificar áreas con posibles excesos o ineficiencias, optimizando el uso del presupuesto y asegurando el alineamiento con la misión institucional.

En el contexto de la educación superior, este enfoque analítico no solo mejora la gestión interna, sino que también permite transparentar el uso de los recursos ante estudiantes, familias y organismos reguladores, fortaleciendo la confianza y la rendición de cuentas.

Gestión de ayudas financieras

La gestión eficiente de ayudas financieras es un componente esencial en la administración universitaria, que impacta directamente en el acceso, retención y éxito académico de los estudiantes. La complejidad del proceso, que incluye la aplicación, verificación, asignación, desembolso y rendición de cuentas, demanda soluciones tecnológicas integrales para optimizar tiempos, reducir errores y cumplir con normativas.

Sistemas modernos de gestión de ayudas financieras aplican inteligencia artificial y análisis de datos para automatizar la evaluación de elegibilidad, priorización de solicitudes y distribución de recursos con alta precisión. Estas plataformas ofrecen interfaces amigables para estudiantes y personal administrativo, simplificando la presentación de documentos y seguimiento del estado de la ayuda.

Además, la personalización de la comunicación mediante chatbots y asistentes virtuales permite resolver dudas, enviar recordatorios de fechas límite y acompañar al estudiante durante todo el ciclo, fomentando mayor compromiso y reducción de abandono por razones financieras.

El análisis predictivo integrado en estos sistemas ayuda a las instituciones a identificar patrones y prever necesidades futuras, optimizando la asignación de fondos y mejorando la equidad en la distribución de becas y préstamos. La consolidación de datos provenientes de distintos sistemas (ERP, CRM, sistemas de información estudiantil) facilita una visión integral que soporta decisiones estratégicas de política financiera educativa.

2.3. MARCO CONCEPTUAL

Los siguientes términos y conceptos constituyen el glosario operativo de la investigación. Su definición precisa es necesaria para garantizar la consistencia entre el marco teórico, la operacionalización de variables y el análisis de resultados.

Análisis de Gastos

Técnica financiera que permite examinar y clasificar los desembolsos realizados en distintos periodos, con el fin de identificar patrones, tendencias, excesos e ineficiencias, contribuyendo a una gestión presupuestaria más efectiva.

Ahorro

Parte del ingreso que no se destina al consumo inmediato, sino que se reserva para cubrir necesidades futuras, imprevistos o alcanzar metas de mediano y largo plazo. Es un pilar fundamental de la estabilidad financiera.

Chatbots Financieros

Asistentes virtuales basados en IA que interactúan con los usuarios para ofrecer orientación en la gestión de gastos, ahorro, inversión y planificación financiera. Permiten

monitorear en tiempo real los movimientos económicos y brindar recomendaciones personalizadas.

Endeudamiento

Uso de recursos financieros obtenidos mediante préstamos o créditos, que implican la obligación de devolución con intereses. Un manejo responsable del endeudamiento permite aprovechar oportunidades de consumo o inversión sin comprometer la estabilidad financiera.

Educación Financiera

Proceso mediante el cual los individuos adquieren conocimientos, habilidades y actitudes necesarias para tomar decisiones económicas informadas, responsables y orientadas al logro de metas financieras personales y familiares.

Finanzas

Disciplina que estudia la gestión del dinero, los activos y las inversiones, tanto en el ámbito personal, empresarial como institucional, con el fin de maximizar los recursos disponibles y minimizar los riesgos financieros.

Finanzas Personales

Conjunto de prácticas, estrategias y conocimientos aplicados para administrar de manera eficiente los ingresos, gastos, ahorros, inversiones y deudas de una persona o familia, con el objetivo de alcanzar estabilidad económica, bienestar y sostenibilidad financiera en el tiempo.

Inteligencia Artificial (IA)

Campo de la informática que desarrolla sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, el razonamiento y la toma de decisiones.

IA en Finanzas Personales

Conjunto de técnicas computacionales, como algoritmos de aprendizaje automático y minería de datos, aplicadas a la gestión financiera individual. Su objetivo es analizar grandes volúmenes de información, identificar patrones y generar recomendaciones automatizadas para optimizar la toma de decisiones financieras.

Gestión de Ayudas Financieras

Conjunto de procesos administrativos y tecnológicos orientados a la asignación, control y evaluación de becas, préstamos y subsidios en instituciones educativas, con el fin de facilitar la inclusión y la sostenibilidad económica de los estudiantes.

Índice de Mejora de Finanzas Personales (IMFP)

Indicador compuesto calculado como $IMFP = 0,30 \cdot K + 0,40 \cdot C + 0,30 \cdot R$, donde K es el puntaje de conocimiento financiero, C el de conducta financiera y R el de resultado financiero, todos en escala 0–100.

Inversión

Asignación de recursos económicos en instrumentos, negocios o proyectos con el fin de generar rendimientos o ganancias futuras, asumiendo distintos niveles de riesgo y horizonte temporal.

Innovaciones Financieras Tecnológicas (FinTech)

Conjunto de herramientas digitales y plataformas que integran tecnología con servicios financieros para mejorar la accesibilidad, eficiencia, personalización y transparencia en la gestión de recursos personales y educativos.

Minería de Datos (Data Mining)

Proceso de exploración y análisis de grandes volúmenes de datos para identificar patrones y relaciones útiles. En finanzas personales, se aplica en la segmentación de perfiles financieros, análisis de gastos, predicción de necesidades futuras y prevención de fraudes.

Modelos de Aprendizaje Automático (Machine Learning Models)

Técnicas avanzadas que permiten a los sistemas aprender de los datos y generar predicciones. En finanzas personales, se aplican para estimar gastos futuros, evaluar créditos, detectar fraudes y diseñar estrategias de inversión personalizadas.

Modelos de Clasificación (Machine Learning)

Métodos de aprendizaje automático que permiten categorizar información en clases predefinidas, aplicados en finanzas para la aprobación de créditos, detección de fraudes, clasificación de riesgos o segmentación de gastos.

Modelo de Lenguaje de Gran Escala (LLM)

Red neuronal de arquitectura Transformer preentrenada en grandes corpus de texto, capaz de generar, resumir, clasificar y dialogar en lenguaje natural con alta coherencia contextual.

Pirámide de Maslow

Modelo psicológico que organiza las necesidades humanas en cinco niveles jerárquicos: fisiológicas, seguridad, sociales, estima y autorrealización. Su aplicación en las finanzas personales permite priorizar la gestión de recursos económicos en función de la satisfacción progresiva de estas necesidades.

Procesos de Toma de Decisiones Financieras

Conjunto de etapas que incluyen la recopilación de información, análisis de alternativas, evaluación de riesgos y selección de la mejor opción para administrar recursos financieros personales, considerando metas a corto, mediano y largo plazo.

Prompt engineering

Disciplina que estudia el diseño y optimización de instrucciones enviadas a un LLM para guiar la generación de respuestas precisas, pertinentes y en el formato deseado.

III. METODOLOGÍA

3.1. Método de la investigación

Desde la perspectiva de la investigación científica clásica, la presente investigación es de enfoque cuantitativo, ya que se sustenta en la recolección y el análisis de datos numéricos para medir el efecto del modelo de implementación de Inteligencia Artificial sobre la

gestión de las finanzas personales de los estudiantes, mediante un IMFP y un conjunto de indicadores objetivos de desempeño computacional del sistema FinancIA (latencia de respuesta, disponibilidad del servicio y consumo de recursos).

Por su finalidad, la investigación es de tipo aplicada, pues no se limita a la generación de conocimiento teórico, sino que desarrolla y valida un artefacto tecnológico funcional, el sistema FinancIA, orientado a resolver un problema concreto de la gestión financiera estudiantil. Por su alcance temporal, es de corte longitudinal de tendencia simple, dado que la variable dependiente se mide en dos momentos diferenciados (pretest y posttest) sobre los mismos sujetos.

Adicionalmente, y dado que el componente experimental de la investigación corresponde al desarrollo de un sistema de software, se complementa el método cuantitativo con el método clásico de investigación en ingeniería de sistemas e informática, que comprende las siguientes etapas:

- Modelado: diseño conceptual de la arquitectura del sistema, que integra técnicas de aprendizaje automático y procesamiento del lenguaje natural a través de un Modelo de Lenguaje de Gran Escala (LLM), aplicadas a la gestión de finanzas personales.
- Análisis teórico: revisión de los fundamentos computacionales, estadísticos y financieros que sustentan el uso de modelos LLM en la generación de recomendaciones financieras personalizadas (Adadi & Berrada, 2018).
- Experimentación: diseño y ejecución de pruebas controladas sobre el módulo de inteligencia artificial del sistema FinancIA, evaluando indicadores de eficiencia computacional (latencia, disponibilidad, consumo de memoria) bajo condiciones reales de operación precisión (Bayakhmetova et al., 2025).

- Desarrollo del prototipo: implementación de un sistema funcional basado en LLM que procesa información financiera real de los estudiantes y emite recomendaciones personalizadas de gestión económica (Pak, 2026).

3.2. Diseño de Investigación

El diseño de investigación es cuasi-experimental, de tipo pretest-posttest con un solo grupo, sin grupo de control. Se aplica el instrumento de medición (Cuestionario IMFP, Anexo 2) a la muestra de estudiantes antes de la implementación del sistema FinancIA y, posteriormente, tras un periodo de uso del sistema, se aplica nuevamente el mismo instrumento para determinar el efecto atribuible a la intervención tecnológica.

El esquema del diseño se representa de la siguiente manera:

G: $O_1 - X - O_2$

Donde G representa al grupo único de estudiantes participantes; O_1 es la observación pretest mediante el Cuestionario IMFP; X es la intervención experimental, correspondiente al uso del sistema FinancIA con su módulo de inteligencia artificial; y O_2 es la observación posttest mediante el mismo instrumento.

Este diseño permite evaluar el cambio en la variable dependiente (mejora de las finanzas personales) en condiciones de uso que reflejan el contexto real de los estudiantes de institutos superiores, sin requerir un control experimental estricto de todas las variables intervinientes, lo cual es consistente con la naturaleza exploratoria del estudio (Etikan et al., 2016). La ausencia de grupo de control constituye una limitación metodológica reconocida explícitamente en el apartado de limitaciones del Capítulo IV, ya que no permite descartar por completo la influencia de factores externos a la intervención (maduración, aprendizaje del instrumento, eventos contextuales).

- Variables de investigación

Variable independiente: Modelo de implementación de Inteligencia Artificial para la mejora de las finanzas personales, operacionalizado a través del sistema FinancIA, cuyo componente central es un Modelo de Lenguaje de Gran Escala (LLM, llama3.2) ejecutado localmente mediante Ollama, integrado a un módulo de procesamiento financiero y un mecanismo de prompt contextualizado.

Variable dependiente: Mejora de las finanzas personales en estudiantes de institutos superiores, operacionalizada mediante el IMFP, que integra las dimensiones de conocimiento financiero, conducta financiera y resultado financiero.

3.2.1. Definición formal del Modelo de Implementación de Inteligencia Artificial


El aporte central de la presente investigación doctoral es el Modelo de Implementación de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores. Este modelo constituye un constructo teórico-metodológico general, independiente de cualquier tecnología específica, que especifica cómo deben organizarse y relacionarse los componentes de un sistema de IA para producir mejoras medibles en la gestión financiera personal de un estudiante. El sistema FinancIA, descrito en esta investigación, es la implementación concreta empleada para validar empíricamente este modelo; el modelo, en cambio, es replicable con otras arquitecturas de lenguaje, otros motores de inferencia o distintos entornos de despliegue, siempre que se respete su estructura funcional.

El modelo se compone formalmente de cuatro capas funcionales articuladas en un ciclo continuo de adquisición, procesamiento, recomendación y retroalimentación:

- Capa de adquisición de datos financieros (D): recolecta el perfil financiero del estudiante, compuesto por ingresos, gastos categorizados, saldo, nivel de

endeudamiento y respuestas declaradas en el instrumento de diagnóstico (conocimiento, conducta y resultado financiero).

- Capa de procesamiento mediante Modelo de Lenguaje de Gran Escala (P): transforma los datos financieros estructurados en un contexto interpretable por un LLM, mediante una función de construcción de prompt que integra los indicadores financieros reales del usuario con instrucciones de rol y formato.
- Capa de generación de recomendaciones (G): a partir del contexto construido, el LLM genera una salida estructurada que incluye diagnóstico financiero, identificación de riesgos, oportunidades de mejora y un plan de acción personalizado.
- Capa de retroalimentación y medición del cambio (F): cuantifica el efecto de las recomendaciones recibidas sobre la conducta financiera del estudiante a lo largo del tiempo, mediante la reaplicación del instrumento de diagnóstico y el cálculo del IMFP.



Esquema 1. Estructura funcional del modelo de implementación de Inteligencia Artificial propuesto (capas D–P–G–F)

Estas cuatro capas pueden expresarse mediante la siguiente notación funcional, que sintetiza el comportamiento del modelo:

$$\mathbf{R} = \mathbf{G}(\mathbf{P}(\mathbf{D}(\mathbf{u}))) \quad (1)$$

Donde $\mathbf{u}$ representa a un estudiante participante, $\mathbf{D}(\mathbf{u})$ es su perfil financiero estructurado, $\mathbf{P}(\cdot)$ es la función de contextualización mediante prompt engineering, $\mathbf{G}(\cdot)$ es la función de generación de recomendaciones del LLM, y $\mathbf{R}$ es la recomendación personalizada resultante. El efecto del modelo sobre el estudiante se mide mediante la función de cambio:

$$\Delta \text{IMFP}(\mathbf{u}) = \text{IMFP}(\mathbf{u}, t_1) - \text{IMFP}(\mathbf{u}, t_0) \quad (2)$$

Donde t_0 y t_1 representan los momentos de medición pretest y posttest, respectivamente. Esta función de cambio es la que articula el modelo con el diseño cuasi-experimental y con el procedimiento de validación detallado en el apartado de técnicas de análisis de resultados.

La Tabla 1 sintetiza la correspondencia entre cada capa funcional del modelo, su fundamento teórico y el componente técnico mediante el cual fue implementada en el sistema FinancIA, dejando explícita la distinción entre el modelo, como aporte doctoral generalizable y FinancIA como instancia particular de validación.

Tabla 1. Correspondencia entre las capas del modelo propuesto y su implementación en el sistema FinancIA

Capa del modelo	Fundamento teórico	Implementación en FinancIA
D — Adquisición de datos financieros	Finanzas personales; minería de datos	Módulos de ingresos, gastos y encuesta financiera
P — Procesamiento mediante LLM	Arquitecturas Transformer y LLM; prompt engineering	Servicio ollamaService.js; construcción de prompt financiero contextualizado
G — Generación de recomendaciones	Chatbots y asistentes conversacionales	Endpoint /api/ia/chat; modelo llama3.2 ejecutado vía Ollama

F — Retroalimentación y medición del cambio	Pirámide de Maslow aplicada a finanzas; toma de decisiones financieras	Cuestionario IMFP (Anexo 2); cálculo de Δ IMFP en pretest y posttest
---	--	---

3.3. Población y muestra

a. Población

La población objetivo está constituida por 770 estudiantes matriculados en un Instituto de Educación Superior Tecnológico, durante el periodo académico 2025-II. Estos estudiantes son usuarios potenciales del sistema FinancIA, desarrollado como componente experimental de la presente investigación.

Criterios de inclusión: estudiantes (a) matriculados en el periodo de estudio; (b) con acceso a un smartphone o computadora y conexión a internet; (c) que otorguen consentimiento informado para participar en el estudio.

Criterios de exclusión: estudiantes que no completen las mediciones pretest o posttest, o que registren un uso del sistema inferior al periodo mínimo de intervención establecido.

b. Muestra

Se empleó un muestreo no probabilístico por conveniencia (Etikan et al., 2016), determinado por restricciones operativas de disponibilidad, acceso y tiempos de intervención propios de un estudio doctoral con recursos limitados. La muestra estuvo conformada por el 10% de la población, es decir, $n = 77$ estudiantes.

Para la estimación de proporciones en el escenario más conservador ($p = 0,5$), con corrección por población finita ($N = 770$) y $n = 77$, el margen de error aproximado al 95% de confianza es de $\pm 10,6$ puntos porcentuales. Este nivel de precisión es adecuado para un estudio cuasi-experimental de carácter exploratorio, orientado a evidenciar efectos prácticos de la intervención sobre la gestión financiera personal, sin pretender una generalización estadística estricta a la población total de institutos superiores del país.

Se reconoce como limitación que el muestreo por conveniencia no garantiza representatividad probabilística de la población.

3.4. Operacionalización de las variables

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES	ÍTEMS	INSTRUMENTO
Variable independiente: Modelo de implementación de IA (sistema FinancIA)	Conjunto jerárquico de técnicas de Inteligencia Artificial que abarca desde algoritmos de aprendizaje automático (ML) hasta modelos de lenguaje de gran escala (LLM), aplicados a la optimización de la gestión financiera individual.	Implementación de un módulo LLM (llama3.2 vía Ollama) que procesa el contexto financiero real del estudiante y genera recomendaciones personalizadas	Eficiencia computacional	Latencia de respuesta (ms)	Tiempo de procesamiento=Tiempo final – Tiempo inicial	Script de medición automatizada
				Disponibilidad del servicio (%)	Disponibilidad = (solicitudes exitosas / solicitudes totales) × 100	
				Consumo de memoria RAM (MB)	CM = CMD – CMI Consumo de memoria= Consumo de memoria utilizada – consumo de memoria inicial	
				Tasa de activación del fallback local (%)	Tasa de fallback = (respuestas generadas por fallback / solicitudes totales) × 100	
Variable dependiente: Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores.	Proceso de fortalecimiento de la capacidad de administrar ingresos, gastos, ahorro e inversión a través de la aplicación de modelos de Inteligencia Artificial.	Cambio en la capacidad de los estudiantes para gestionar ingresos, gastos, ahorro y deuda, medido antes y después del uso del sistema FinancIA	Mejora de gestión	Conocimiento financiero (K)	Puntaje en test objetivo de conocimientos financieros (escala 0–100)	Cuestionario IMFP (CFPE-IMFP) — Anexo 2
				Conducta financiera (C)	Puntaje en escala Likert de hábitos financieros (escala 0–100)	
				Resultado financiero (R)	Puntaje en indicadores de situación financiera: ahorro, balance, deuda, fondo de emergencia (escala 0–100)	
				Índice global	IMFP = 0,30·K + 0,40·C + 0,30·R, aplicado en pretest y posttest; Δ IMFP = IMFP_post – IMFP_pre	

3.5. Técnicas e instrumentos de recolección de datos

Para la variable independiente (eficiencia del sistema FinancIA) se empleó la técnica de observación estructurada mediante pruebas automatizadas, que permite registrar de manera sistemática el comportamiento del módulo de inteligencia artificial durante la ejecución de solicitudes controladas, recogiendo información cuantitativa sobre latencia, disponibilidad y consumo de recursos computacionales.

Para la variable dependiente (mejora de las finanzas personales) se empleó la técnica de la encuesta, aplicada mediante un cuestionario estructurado en dos momentos (pretest y posttest), lo que permite cuantificar el cambio en el conocimiento, la conducta y el resultado financiero de los estudiantes participantes.

Los instrumentos empleados fueron los siguientes:

- Ficha de observación de eficiencia (Anexo 1): instrumento diseñado para registrar los valores de latencia de respuesta, consumo de memoria RAM, disponibilidad del servicio y activación del mecanismo de fallback, obtenidos mediante el script automatizado `medir_eficiencia.js` y el monitoreo de procesos del sistema operativo.
- Cuestionario IMFP — Finanzas Personales en Estudiantes (CFPE-IMFP) (Anexo 2): instrumento de 39 ítems estructurado en tres secciones (15 ítems de conocimiento financiero de opción múltiple, 16 ítems de conducta financiera en escala de frecuencia y 8 ítems de resultado financiero), aplicado de forma anónima en pretest y posttest a la muestra de 77 estudiantes.
- Herramientas de monitoreo y scripts de registro automático: empleadas para obtener de manera objetiva los datos de uso de recursos del sistema y garantizar la trazabilidad de las mediciones de eficiencia computacional.

3.6. Técnicas de análisis de resultados

a. Análisis de la eficiencia computacional del sistema FinancIA

Para evaluar la eficiencia del módulo de inteligencia artificial, se emplearon los siguientes indicadores, registrados en la ficha de observación del Anexo 1:

Latencia de respuesta. Se calculó como la diferencia entre el tiempo de finalización y el tiempo de inicio de cada solicitud al endpoint /api/ia/chat:

$$\text{TDP} = \text{TF} - \text{TI} \quad (3)$$

Donde TDP es el tiempo de procesamiento, TF es el tiempo final y TI es el tiempo inicial de la solicitud.

Consumo de memoria. Se calculó como la diferencia entre la memoria utilizada después y antes de la ejecución de una tarea, registrada de forma diferenciada por proceso (Ollama y Node.js):

$$\text{CM} = \text{CMD} - \text{CMI} \quad (4)$$

Donde CM es el consumo de memoria, CMD es la memoria utilizada después de la ejecución y CMI es la memoria utilizada inicialmente.

Disponibilidad del servicio. Se calculó como el porcentaje de solicitudes exitosas sobre el total de solicitudes enviadas durante la prueba experimental de 30 ejecuciones controladas.

$$\text{Disponibilidad} = (\text{solicitudes exitosas} / \text{solicitudes totales}) \times 100 \quad (5)$$

Tasa de activación del fallback. Se calculó como el porcentaje de respuestas generadas por el mecanismo de respaldo local (reglas financieras predefinidas) sobre el total de solicitudes, en los escenarios donde el motor Ollama no se encontraba disponible.

$$\text{Tasa de fallback} = (\text{solicitudes respondidas por fallback} / \text{solicitudes totales}) \times 100 \quad (6)$$

b. Análisis de la mejora de las finanzas personales

La variable dependiente se operacionalizó mediante el IMFP, calculado en una escala de 0 a 100 puntos, integrando tres dimensiones cuantificables: conocimiento financiero (K), conducta financiera (C) y resultado financiero (R).

Cada dimensión se transforma a un puntaje estandarizado de 0 a 100: K corresponde al puntaje obtenido en el test objetivo de conocimientos financieros (sección K del Anexo 2); C corresponde al puntaje promedio de los ítems tipo Likert sobre hábitos y prácticas financieras (sección C); y R corresponde al puntaje derivado de los indicadores de situación financiera, ahorro, balance, fondo de emergencia, deuda y atrasos (sección R).

De manera explícita, la fórmula de estandarización aplicada en cada sección del instrumento es la siguiente: $K_{\text{estandarizado}} = (\text{puntaje bruto obtenido en los 15 ítems de opción múltiple} / 15) \times 100$; $C_{\text{estandarizado}} = (\text{suma de los ítems C1 a C16} / 48) \times 100$, donde 48 es la suma de los puntajes máximos de los 16 ítems evaluados en la escala de frecuencia de 0 (Nunca) a 3 (Siempre); y $R_{\text{estandarizado}} = (\text{suma de los ítems R1 a R8} / 20) \times 100$, donde 20 es la suma de los puntajes máximos de los 8 ítems de la sección (3+2+3+2+3+2+3+2, según el detalle del Anexo 2). Esta explicitación evita ambigüedades de cálculo derivadas de los distintos puntajes máximos por ítem que componen cada sección, y es consistente con los valores reportados en las Tablas 24, 25 y 26.

El IMFP se calcula como una combinación ponderada de las tres dimensiones:

$$\text{IMFP} = 0,30 \cdot K + 0,40 \cdot C + 0,30 \cdot R \quad (7)$$

Las ponderaciones priorizan la conducta financiera (40%), por representar la aplicación práctica y sostenida del manejo financiero personal, mientras que el conocimiento y el resultado financiero se ponderan en partes iguales (30% cada uno), al constituir respectivamente la base cognitiva y la consecuencia observable de dicha conducta.

Para estimar la mejora atribuible a la intervención, el instrumento se aplicó en dos momentos, pretest, antes de la implementación del sistema; y posttest, después de un periodo de uso, calculándose el cambio como:

$$\Delta\text{IMFP} = \text{IMFP}_{\text{post}} - \text{IMFP}_{\text{pre}} \quad (8)$$

La interpretación del ΔIMFP se estableció de la siguiente manera: $\Delta\text{IMFP} > 0$ indica mejora en la gestión de finanzas personales; $\Delta\text{IMFP} = 0$ indica ausencia de cambio; y $\Delta\text{IMFP} < 0$ indica retroceso. Adicionalmente, el puntaje final del IMFP se categoriza en cuatro niveles: 0–24 (bajo), 25–49 (medio-bajo), 50–74 (medio-alto) y 75–100 (alto).

c. Contraste de hipótesis

Dado que el diseño corresponde a un esquema pretest-posttest de un solo grupo con mediciones repetidas sobre los mismos sujetos, el contraste de la hipótesis de investigación se realizó mediante la prueba de rangos con signo de Wilcoxon, aplicada sobre las diferencias individuales del IMFP (ΔIMFP) de los 77 estudiantes, con un nivel de significancia $\alpha = 0,05$. Como prueba complementaria, dado que la distribución de las diferencias del IMFP global no se aparta significativamente de la normalidad (prueba de Shapiro-Wilk, $p = 0,387$), se reportó también la prueba t de Student para muestras relacionadas en esa variable.

d. Confiabilidad del instrumento (Alfa de Cronbach)

Dado que el Cuestionario IMFP (CFPE-IMFP) es un instrumento de elaboración propia, su confiabilidad se evaluó mediante el coeficiente Alfa de Cronbach, calculado sobre las respuestas reales de los 77 estudiantes en cada sección del instrumento. El coeficiente se calcula mediante la siguiente fórmula:

$$\alpha = (k / (k - 1)) \cdot (1 - \Sigma \sigma_i^2 / \sigma_r^2) \quad (9)$$

Donde k es el número de ítems de la sección, σ_i^2 es la varianza de cada ítem y σ_t^2 es la varianza de la puntuación total de la sección. Un valor de $\alpha \geq 0,70$ se considera aceptable para instrumentos de investigación en ciencias sociales (George & Mallery, 2003).

La Tabla 2 presenta los coeficientes obtenidos para cada sección del instrumento, calculados sobre las respuestas combinadas de pretest y posttest ($n = 154$ observaciones) para maximizar la estabilidad de la estimación.

Tabla 2. Confiabilidad del instrumento por sección (Alfa de Cronbach, $n = 154$ observaciones combinadas)

Sección	N° de ítems	Naturaleza de los ítems	Alfa de Cronbach	Interpretación
K — Conocimiento financiero	15	Dicotómicos (correcto/incorrecto), dominios heterogéneos	0,27	No aplicable bajo el supuesto de unidimensionalidad
C — Conducta financiera	16	Politómicos (escala 0-3), constructo homogéneo	0,71	Aceptable
R — Resultado financiero	8	Politómicos heterogéneos, indicadores de distinta naturaleza	0,13	No aplicable bajo el supuesto de unidimensionalidad

El coeficiente Alfa de Cronbach de la sección C (conducta financiera) fue de 0,71, valor que se considera aceptable según los criterios convencionales y respalda la consistencia interna de esta sección como medida de un constructo razonablemente homogéneo: la frecuencia con la que el estudiante aplica prácticas financieras saludables.

Los coeficientes obtenidos para las secciones K ($\alpha = 0,27$) y R ($\alpha = 0,13$) no deben interpretarse como evidencia de un instrumento defectuoso, sino como resultado de aplicar un coeficiente que no corresponde a la naturaleza de sus ítems. La sección K está compuesta por ítems dicotómicos (correcto/incorrecto) que evalúan dominios de conocimiento heterogéneos (presupuesto, deuda, ahorro, metas financieras); para este tipo de ítems, el coeficiente psicométricamente apropiado es el Kuder-Richardson 20 (KR-20), y no el Alfa de Cronbach, dado que este último tiende a subestimar la fiabilidad cuando los ítems dicotómicos evalúan

dominios no unidimensionales (Streiner, 2003). Por su parte, la sección R se define conceptualmente como un constructo formativo: sus ocho indicadores (nivel de ahorro, balance, fondo de emergencia, atrasos, endeudamiento, uso de crédito, estrés financiero percibido y capacidad de respuesta ante imprevistos) son causas independientes de la situación financiera del estudiante, y no reflejos intercambiables de un mismo rasgo latente; no existe, por tanto, una razón teórica para esperar que correlacionen entre sí. Los índices de consistencia interna basados en la correlación inter-ítem, como el Alfa de Cronbach, no son aplicables a un constructo de naturaleza formativa, por lo que su valor bajo no compromete la validez de la sección R.

3.7. Procedimiento

En este apartado se describe el procedimiento seguido para implementar y validar empíricamente el modelo de Inteligencia Artificial, mediante el sistema FinancIA, que constituye el componente experimental de la investigación. La explicación se organiza desde el diagnóstico inicial del proyecto hasta la validación funcional del prototipo, articulando cada módulo del sistema con la capa del modelo que materializa (Tabla 1), de modo que el desarrollo técnico se mantenga subordinado, en todo momento, a su función como instancia de validación del modelo doctoral propuesto.

La Figura 3 sintetiza el flujo metodológico completo de la investigación, desde la definición formal del modelo de Inteligencia Artificial hasta el análisis estadístico de los resultados, pasando por su validación empírica mediante el sistema FinancIA, el diseño cuasi-experimental pretest-posttest y los instrumentos de medición aplicados.




Figura 3. Diagrama general de la metodología de la investigación

3.7.1. FinancIA como instrumento de validación del modelo

FinancIA es el sistema web desarrollado para validar empíricamente el modelo de implementación de Inteligencia Artificial propuesto en esta investigación. A través de sus módulos, el sistema operacionaliza las cuatro capas funcionales del modelo (adquisición de datos, procesamiento mediante LLM, generación de recomendaciones

y retroalimentación), permitiendo a los estudiantes de institutos superiores registrar ingresos, registrar gastos, responder una encuesta financiera, visualizar resúmenes económicos, consultar un asistente inteligente y exportar reportes financieros. Su finalidad no es constituir un producto comercial, sino proporcionar la evidencia empírica necesaria para evaluar si el modelo propuesto, al ser implementado, contribuye efectivamente a mejorar la administración de las finanzas personales.

Desde el punto de vista funcional, el sistema integra módulos de usuarios, finanzas, encuestas, resumen, gráficas, inteligencia artificial, historial conversacional y exportación de resultados. Estos módulos permiten recolectar datos financieros, transformarlos en indicadores, generar retroalimentación personalizada y conservar evidencias para el análisis metodológico.

La Tabla 3 resume la contribución de cada módulo del sistema FinancIA dentro del proceso de investigación doctoral, identificando además la capa del modelo (D, P, G o F, según la notación del apartado 3.2.1) que cada módulo materializa.

Tabla 3. Módulos funcionales del sistema FinancIA y su aporte a la investigación

Módulo del sistema	Función técnica	Aporte a la investigación
Usuarios	Registra e identifica a cada estudiante	Permite asociar datos financieros a cada participante
Ingresos	Registra entradas económicas mensuales	Mide la capacidad económica del estudiante
Gastos	Registra egresos por categoría	Permite analizar hábitos de consumo
Encuesta	Recoge información financiera declarada	Sirve como instrumento de pretest y postest

Resumen	Calcula ingresos, gastos, saldo y ratio	Genera indicadores financieros
Gráficas	Visualiza datos financieros	Facilita la interpretación de patrones
IA Chat	Genera recomendaciones personalizadas	Representa la intervención inteligente
Historial IA	Guarda consultas y respuestas	Permite trazabilidad de la intervención
Exportación PDF	Genera reporte financiero	Proporciona evidencia documental

Como se observa en la Fig. 1, FinancIA no solo cumple una función tecnológica, sino también metodológica, ya que permite recolectar, procesar, analizar y evidenciar información financiera de los estudiantes participantes.



Figura 4. Interfaz principal y propuesta de valor de la plataforma FinancIA

3.7.2. Fases metodológicas de implementación del sistema

La implementación de FinancIA se organizó por fases, con el propósito de mantener una trazabilidad entre el desarrollo técnico del sistema y los objetivos metodológicos

de la investigación. Esta organización permitió diagnosticar el proyecto, ordenar la estructura, configurar el entorno, diseñar la base de datos, desarrollar los módulos funcionales, integrar inteligencia artificial, validar el prototipo y generar evidencias para el informe doctoral.

La Tabla 4 presenta las fases de implementación del sistema FinancIA, indicando el objetivo técnico asociado a cada etapa del proceso.

Tabla 4. Plan de implementación del sistema FinancIA por fases y objetivos técnicos

Fase	Nombre de la fase	Objetivo técnico
0	Diagnóstico inicial	Identificar estado del sistema, módulos y riesgos
1	Estructura del proyecto	Ordenar carpetas y archivos
2	Configuración del entorno	Instalar dependencias y ejecutar servidor
3	Base de datos	Definir tablas y relaciones
4	Backend y API REST	Implementar rutas y controladores
5	Usuarios	Registrar e iniciar sesión
6	Ingresos y gastos	Registrar movimientos financieros
7	Encuestas	Recolectar datos financieros
8	Resumen financiero	Calcular indicadores financieros
9	Gráficas	Visualizar datos
10	IA con Ollama	Generar recomendaciones personalizadas
11	Fallback local	Responder sin Ollama
12	Frontend completo	Integrar pantallas
13	Exportación PDF	Generar reporte
14	Pruebas funcionales	Validar módulos
15	Métricas doctorales	Medir eficiencia y mejora
16	Resultados y discusión	Comparar pretest y posttest
17	Documentación técnica	Elaborar manual técnico
18	Manual de usuario	Guiar uso del sistema
19	Evidencias	Organizar capturas
20	Validación final	Verificar coherencia del proyecto

La figura 5 muestra el flujo metodológico de implementación y validación del sistema FinancIA, organizado en ocho fases secuenciales que orientan el desarrollo técnico del proyecto. Este flujo inicia con el diagnóstico del sistema, continúa con la configuración

del entorno, el diseño de la base de datos, la implementación del backend/API y el desarrollo del frontend, para luego integrar el módulo de inteligencia artificial con su mecanismo de fallback. Finalmente, se consideran las fases de pruebas y resultados, las cuales permiten validar el funcionamiento del sistema y evidenciar el cumplimiento de los objetivos planteados en la investigación.




Figura 5. Flujo metodológico de implementación y validación.

3.7.3. Diagnóstico inicial del proyecto

El diagnóstico inicial permitió identificar que el sistema FinancIA ya contaba con una base funcional implementada, incluyendo backend, frontend, base de datos local, API REST, gestión de usuarios, registro financiero, encuesta, gráficos, chat IA, fallback local y exportación PDF. Sin embargo, también se identificó la necesidad de fortalecer la documentación técnica, las métricas doctorales, la matriz de pruebas, la evidencia visual y la relación formal entre el sistema y la hipótesis de investigación.

3.7.4. Arquitectura general del sistema

La arquitectura de FinancIA responde a un modelo cliente-servidor. El frontend permite la interacción del usuario mediante formularios, navegación, gráficos y chat; el backend expone servicios mediante una API REST; la base de datos local almacena usuarios, movimientos financieros, encuestas e historial; y el módulo de inteligencia artificial procesa consultas financieras mediante Ollama o mediante una respuesta local

alternativa. Esta arquitectura permite integrar los datos financieros del estudiante con un sistema de recomendación personalizada.

La siguiente Tabla 5 describe los componentes principales de la arquitectura del sistema y su función dentro del prototipo experimental.

Tabla 5. Componentes tecnológicos del sistema FinancIA y sus funciones

Componente	Tecnología	Función
Cliente	HTML, CSS, JavaScript	Interfaz de usuario y formularios
Servidor	Node.js + Express	Procesamiento de solicitudes y servicios
API REST	Express Router	Comunicación entre frontend y backend
Base de datos	SQLite mediante sql.js	Persistencia local de datos
IA local	Ollama	Generación de recomendaciones
Fallback	Reglas financieras locales	Respuesta alternativa sin Ollama
Reportes	jsPDF + html2canvas	Exportación de resultados

La figura 6 muestra la arquitectura general del sistema FinancIA, representando la interacción entre el usuario estudiante, el frontend, el backend API REST, la base de datos, el módulo de inteligencia artificial local y el mecanismo de fallback. En esta arquitectura, el usuario accede al sistema mediante una interfaz desarrollada con HTML, CSS y JavaScript, la cual se comunica con el backend implementado en Node.js y Express. A su vez, el backend gestiona las solicitudes del sistema, consulta la base de datos SQLite mediante sql.js y se conecta con el motor de IA local Ollama para generar recomendaciones financieras personalizadas. Asimismo, se incorpora un fallback local basado en reglas financieras, el cual permite mantener la respuesta del sistema en caso de que el servicio de IA no se encuentre disponible.




Figura 6. Arquitectura general del sistema FinancIA.

3.7.5. Estructura técnica del proyecto

El proyecto se organizó en una estructura modular que separa la lógica del backend, la interfaz frontend, la configuración, la base de datos, los controladores, las rutas, los servicios y los middlewares. Esta organización facilita el mantenimiento del sistema, la validación por módulos y la documentación técnica del prototipo.

La Tabla 6 describe la estructura técnica principal del proyecto FinancIA, detallando las carpetas y archivos más relevantes que conforman el sistema. En ella se especifica la función técnica de cada componente, desde la configuración del entorno, la administración de la base de datos y la definición de rutas REST, hasta la integración del frontend, el módulo de inteligencia artificial local y la documentación del proyecto.

Tabla 6. Estructura principal del proyecto FinancIA y función técnica de sus componentes

Carpeta o archivo	Función técnica
backend/config/env.js	Configura puerto, modelo IA, URL de Ollama y ruta frontend
backend/controllers	Atiende solicitudes de usuarios, finanzas, encuestas e IA
backend/database/database.js	Inicializa y administra la base de datos
backend/database/app.db	Archivo de persistencia local
backend/middlewares/errorHandler.js	Maneja errores y rutas inexistentes
backend/routes/index.js	Define endpoints REST
backend/services/financeService.js	Calcula resumen y estadísticas

backend/services/ollamaService.js	Construye prompt y consulta IA
backend/server.js	Inicia servidor y sirve frontend
frontend/index.html	Estructura visual del sistema
frontend/css/styles.css	Estilos y diseño responsive
frontend/js/app.js	Lógica de navegación, API, chat y PDF
package.json	Dependencias y comandos
README.md	Documentación del proyecto

La figura 7 muestra la estructura técnica del proyecto FinancIA, organizada en backend, frontend, base de datos, rutas, controladores y servicios. Esta distribución evidencia una arquitectura modular que facilita el mantenimiento, la comprensión del sistema y la validación técnica del prototipo desarrollado.




Figura 7. Estructura técnica del proyecto FinancIA.

3.7.6. Configuración del entorno de desarrollo

La configuración del entorno permitió ejecutar el sistema de manera local para realizar pruebas controladas. El sistema requiere Node.js, npm, un navegador moderno y, opcionalmente, Ollama para ejecutar modelos de lenguaje de forma local. Una vez instaladas las dependencias, el servidor se ejecuta mediante `npm start` y queda disponible en `http://localhost:3000`.

La Tabla 7 presenta los principales comandos utilizados durante la instalación, verificación y ejecución local del sistema FinancIA. Estos comandos permiten comprobar las versiones de Node.js y npm, instalar las dependencias necesarias del

proyecto, validar la sintaxis del backend, iniciar el servidor y verificar el correcto funcionamiento de la aplicación web y de la API REST.

Tabla 7. Comandos de instalación, verificación y ejecución local del sistema FinancIA

Comando	Función
node -v	Verifica versión de Node.js
npm -v	Verifica versión de npm
npm install	Instala dependencias
npm run check	Verifica sintaxis del backend
npm start	Inicia el servidor
http://localhost:3000	Abre la aplicación
http://localhost:3000/api/health	Verifica API

La figura 8 muestra la ejecución local del servidor FinancIA mediante el comando npm start desde la terminal de Visual Studio Code. En la imagen se evidencia que el backend se inicia correctamente, la base de datos local app.db queda disponible y la aplicación web queda activa en <http://localhost:3000>, además de indicar la conexión opcional con Ollama para el módulo de inteligencia artificial local.




Figura 8. Ejecución local del servidor FinancIA mediante npm start.

3.7.7. Diseño de la base de datos

La base de datos del sistema FinancIA se implementó mediante SQLite local usando la librería sql.js, permitiendo almacenar información de usuarios, movimientos

financieros, encuestas, respuestas del asistente IA e historial conversacional. Esta decisión resulta adecuada para un prototipo académico, debido a que permite mantener una persistencia local simple, portable y suficiente para pruebas experimentales controladas.

La Tabla 8 describe las entidades principales que conforman la base de datos del sistema FinancIA, indicando el propósito de cada una dentro del funcionamiento técnico y del proceso investigativo. En ella se identifican tablas orientadas al registro de usuarios, movimientos financieros, encuestas, historial de conversación e interacción con inteligencia artificial. Asimismo, se incluyen entidades destinadas al almacenamiento de métricas del modelo y resultados de comparación pretest y posttest, las cuales permiten respaldar el análisis de eficiencia, trazabilidad y mejora obtenida durante la validación del sistema.

Tabla 8. Entidades principales de la base de datos del sistema FinancIA y su propósito

Tabla	Propósito
usuarios	Almacena datos básicos del estudiante
finanzas	Almacena ingresos y gastos
encuestas	Almacena respuestas del cuestionario
respuestas_ia	Guarda consultas y respuestas IA
chat_history	Registra conversación por usuario
metricas_modelo	Registra latencia y uso del sistema
resultados_pretest_postest	Registra comparación antes/después

La figura 9 presenta el modelo entidad-relación de la base de datos del sistema FinancIA, donde la entidad usuarios actúa como tabla principal y se relaciona con las tablas finanzas, encuestas, respuestas_ia y chat_history mediante relaciones de uno a muchos. Este diseño permite asociar cada registro financiero, respuesta de encuesta, consulta a la inteligencia artificial y conversación histórica con un estudiante

específico, garantizando la organización, trazabilidad e integridad de la información utilizada por el sistema durante la intervención financiera.




Figura 9. Modelo entidad-relación de la base de datos del sistema FinancIA.

3.7.8. Arquitectura backend y API REST

El backend del sistema se implementó con Node.js y Express bajo una arquitectura modular basada en rutas, controladores, servicios, base de datos y middleware de errores. La API REST permite que el frontend consuma los servicios de usuarios, finanzas, encuestas, estadísticas, inteligencia artificial e historial de chat.

La Tabla 9 presenta los principales endpoints de la API RESTful del sistema FinancIA, organizados según el método HTTP, la ruta de acceso, el módulo al que pertenecen y la función que cumplen dentro del prototipo. Esta tabla permite evidenciar la estructura de comunicación entre el frontend y el backend, mostrando que el sistema cuenta con servicios para verificar el estado del servidor, gestionar usuarios, registrar ingresos y gastos, consultar resúmenes financieros, obtener estadísticas, almacenar encuestas y procesar consultas mediante inteligencia artificial. Por ello, la API REST constituye un componente fundamental para la integración y funcionamiento modular del sistema FinancIA.

Tabla 9. Endpoints principales de la API RESTful del sistema FinancIA

Método	Endpoint	Módulo	Descripción
GET	/api/health	Sistema	Verifica estado del servidor
POST	/api/usuarios	Usuarios	Registra un estudiante
POST	/api/usuarios/login	Usuarios	Inicia sesión por correo
GET	/api/usuarios	Usuarios	Lista usuarios registrados
GET	/api/usuarios/:id	Usuarios	Obtiene usuario por ID
POST	/api/finanzas	Finanzas	Registra ingreso o gasto
GET	/api/finanzas/resumen/:usuario_id	Resumen	Calcula resumen financiero
GET	/api/finanzas/:usuario_id	Finanzas	Lista movimientos financieros
DELETE	/api/finanzas/:id	Finanzas	Elimina movimiento
GET	/api/estadisticas/:usuario_id	Gráficas	Obtiene estadísticas
POST	/api/encuestas	Encuestas	Guarda encuesta
GET	/api/encuestas/:usuario_id	Encuestas	Lista encuestas
GET	/api/ia/modelos	IA	Lista modelos disponibles
POST	/api/ia/chat	IA	Genera respuesta del asistente
GET	/api/ia/historial/:usuario_id	IA	Obtiene historial IA
GET	/api/chat/historial/:usuario_id	Chat	Obtiene historial conversacional
DELETE	/api/chat/historial/:usuario_id	Chat	Limpia historial

La figura 10 evidencia la verificación del endpoint de salud del sistema FinancIA, accediendo desde el navegador a la ruta localhost:3000/api/health. La respuesta en formato JSON muestra los valores "success": true, "status": "ok" y "app": "FinancIA", lo cual confirma que el servidor backend se encuentra activo, que la API REST responde correctamente y que el prototipo está listo para continuar con las pruebas funcionales de los demás módulos.




Figura 10. Verificación del endpoint de salud del sistema FinancIA.

3.7.9. Módulo de usuarios


El módulo de usuarios permite registrar a los estudiantes participantes mediante nombres, teléfono y correo electrónico. Este módulo permite asociar cada registro financiero, encuesta, consulta IA y resultado con un usuario específico. En el prototipo actual, el inicio de sesión se realiza mediante correo electrónico, lo cual es suficiente para un entorno experimental controlado, aunque se recomienda incorporar autenticación con contraseña en futuras versiones productivas.

La siguiente Tabla 10 resume las validaciones principales aplicadas en el módulo de usuarios del sistema FinancIA. Estas reglas permiten asegurar que los datos ingresados por el estudiante sean consistentes, válidos y no duplicados, garantizando que cada participante pueda ser identificado correctamente dentro del prototipo y que sus registros financieros, encuestas y consultas al asistente IA se asocien a una cuenta específica.

Tabla 10. Validaciones aplicadas en el módulo de usuarios del sistema FinancIA


Campo	Validación	Finalidad
Nombres	No vacío	Identificar al estudiante
Teléfono	Formato válido	Registrar contacto básico
Email	Formato de correo	Evitar datos inválidos
Email único	No duplicado	Evitar registros repetidos
ID usuario	Existente	Asociar operaciones financieras

La figura 11 muestra el proceso inicial de acceso al sistema **FinancIA**. En la imagen **a)** se observa el formulario de registro, donde el estudiante ingresa sus nombres, teléfono y correo electrónico; en la imagen **b)** se presenta la opción de inicio de sesión mediante correo registrado; y en la imagen **c)** se evidencia el ingreso exitoso al sistema, mostrando la barra de usuario activa y el acceso al módulo de registro de ingresos. Esta secuencia confirma que el sistema permite identificar al participante y asociar sus movimientos financieros a una cuenta específica.




The screenshot displays the 'FinancIA' web application interface. At the top, a dark blue header contains the logo and the text 'Sistema Inteligente de Gestión Financiera Personal'. Below this, a navigation bar features icons for 'Modelo', 'Cuenta' (highlighted in blue), 'Ingresos', 'Gastos', 'Encuesta', 'IA Chat', 'Gráficas', and 'Resumen'. The main content area is titled 'Crear Cuenta / Iniciar Sesión' and includes two tabs: 'Registrarse' (active) and 'Iniciar Sesión'. The registration form consists of three input fields: 'NOMBRES COMPLETOS' with the value 'Jhon', 'TELÉFONO' with '987654321', and 'CORREO ELECTRÓNICO' with 'jhon24@gmail.com'. A large blue button at the bottom is labeled 'Registrarse y Continuar'.

a) Registro de usuario



b) Inicio de sesión por correo electrónico.



c) Acceso al módulo de ingresos después de iniciar sesión.

Figura 11. Registro de usuario en el sistema FinancIA.

3.7.10. Módulo de ingresos y gastos

El módulo de ingresos y gastos constituye el núcleo de recopilación financiera del sistema. Permite registrar movimientos por usuario, mes, año, tipo, categoría, monto y descripción. Esta información se utiliza para calcular el resumen financiero, alimentar las gráficas, generar indicadores y contextualizar las respuestas de la inteligencia artificial.

La Tabla 11 describe los campos principales utilizados en el módulo financiero del sistema FinancIA, los cuales permiten registrar y organizar los movimientos económicos de cada estudiante. Estos campos son importantes porque relacionan cada ingreso o gasto con un usuario específico, permiten analizar la información por mes y año, diferencian las entradas y salidas de dinero, clasifican los hábitos de consumo por

categoría y facilitan el cálculo de totales, saldos e indicadores financieros para la investigación.

Tabla 11. Campos principales del módulo financiero del sistema FinancIA

Campo	Descripción	Uso en el análisis financiero
usuario_id	Identificador del estudiante	Relaciona movimiento con participante
mes	Mes del registro	Permite análisis mensual
anio	Año del registro	Permite análisis temporal
tipo	Ingreso o gasto	Diferencia entradas y salidas
categoria	Categoría financiera	Permite clasificar hábitos
monto	Valor monetario	Calcula totales y saldos
descripcion	Detalle opcional	Contextualiza el movimiento

Las figuras 12 y 13 evidencian el funcionamiento del módulo financiero del sistema FinancIA. En la figura 12 se muestra el registro de ingresos mensuales, donde el estudiante puede ingresar el mes, año, categoría, monto y descripción del ingreso. Por otro lado, la figura 13 presenta el registro de gastos por categoría, permitiendo clasificar los egresos según su tipo y valor económico. Ambas pantallas son importantes porque permiten recopilar la información financiera necesaria para calcular el saldo, analizar hábitos de consumo y generar recomendaciones personalizadas mediante el asistente de inteligencia artificial.

Registro de Ingresos

MES: Mayo AÑO: 2026

REMUNERACIÓN: 3000

% INTERESES GANADOS: 100

ALQUILER: 1000

OTRA ACTIVIDAD LABORAL: 200

Total Ingresos: **\$4,300.00**

Guardar Ingresos

Figura 12. Registro de ingresos mensuales en FinancIA.

Registro de Gastos

INGRESOS: \$4,300.00 GASTOS: \$0.00 SALDO: \$4,300.00

MES: Mayo AÑO: 2026

CATEGORÍA (PIRÁMIDE DE MASLOW): Alimentación diaria

MONTO (\$): 500

Saldo: \$4,300.00 - Gasto: \$500.00 - "Alimentación diaria" (Fisiológicas)
☒ Dentro de parámetros aceptables.

Agregar Gasto

Registro de Gastos

INGRESOS: \$4,300.00 GASTOS: \$500.00 SALDO: \$3,800.00

MES: Mayo AÑO: 2026

CATEGORÍA (PIRÁMIDE DE MASLOW): — Selecciona categoría —

MONTO (\$): 0.00

Agregar Gasto

ÚLTIMOS GASTOS REGISTRADOS

Alimentación diaria
 Mayo 2026 - Fisiológicas **-\$500.00**

Figura 13. Registro de gastos por categoría en FinancIA.

3.7.11. Módulo de encuestas financieras

El módulo de encuestas financieras permite recolectar información sobre conocimiento financiero, frecuencia de ahorro, uso de presupuesto, nivel de deuda, objetivo financiero, satisfacción y comentarios del estudiante. Esta información se relaciona

directamente con la variable dependiente del estudio, ya que permite medir el nivel de mejora de las finanzas personales antes y después de la intervención con FinancIA.


La Tabla 12 presenta las dimensiones consideradas en la encuesta financiera digital aplicada en el sistema FinancIA, relacionando cada pregunta o variable con el componente correspondiente del IMFP. Estas dimensiones permiten recopilar información sobre el conocimiento financiero, los hábitos de ahorro, el uso de presupuesto, el nivel de deuda percibida, los objetivos financieros y la satisfacción del estudiante. Asimismo, se incluye un comentario libre como complemento cualitativo, el cual permite interpretar con mayor profundidad la situación financiera del participante y fortalecer el análisis de los resultados obtenidos en la investigación.

Tabla 12. Dimensiones de la encuesta financiera digital y su relación con el IMFP

Dimensión	Pregunta o variable	Relación con IMFP
Conocimiento financiero	Nivel de conocimiento declarado	K
Ahorro	Frecuencia de ahorro	C
Presupuesto	Uso de presupuesto mensual	C
Deuda	Nivel de deuda percibida	R
Objetivo financiero	Meta principal del estudiante	C
Satisfacción	Satisfacción financiera	R
Comentario	Descripción libre	Complemento cualitativo

La figura 14 muestra la encuesta financiera digital aplicada en el sistema FinancIA, mediante la cual se recopila información relevante sobre el perfil financiero del estudiante. En esta interfaz se consideran dimensiones como el nivel de conocimiento financiero, la frecuencia de ahorro, el uso de presupuesto mensual, el nivel de deuda, el objetivo financiero principal, la satisfacción financiera actual y un comentario

adicional. Esta información permite obtener un diagnóstico inicial del participante y sirve como base para analizar sus hábitos financieros, generar recomendaciones personalizadas y comparar posteriormente los resultados obtenidos durante la intervención del sistema.



Encuesta de Perfil Financiero

1 ¿Cuál es tu nivel de conocimiento financiero?

1 2 3 4 5

2 ¿Con qué frecuencia ahorras?

Raramente

3 ¿Usas presupuesto mensual?

A veces hago uno mental

4 ¿Cuál es tu nivel de deuda?

Deuda pequeña manejable

5 ¿Cuál es tu principal objetivo financiero?

Financiar mi educación

6 Satisfacción financiera actual (1-10)

6

7 Comentarios adicionales

Mi situación financiera es estable, pero necesito mejorar mis hábitos de ahorro y planificación mensual.

Enviar Encuesta

Figura 14. Encuesta financiera digital aplicada en FinancIA.


3.7.12. Módulo de resumen financiero

El módulo de resumen financiero procesa los ingresos y gastos registrados por el estudiante para generar indicadores como total de ingresos, total de gastos, saldo disponible, ratio gasto/ingreso y distribución por categorías. Estos indicadores permiten diagnosticar la situación financiera del usuario y sirven como insumo para el asistente inteligente.


Tabla 13. Indicadores del módulo de resumen financiero del sistema FinancIA

Indicador	Fórmula o cálculo	Interpretación
Total de ingresos	Suma de ingresos	Capacidad económica
Total de gastos	Suma de gastos	Nivel de consumo
Saldo	Ingresos – gastos	Ahorro o déficit
Ratio gasto/ingreso	$\text{Gastos} / \text{ingresos} \times 100$	Control financiero
Gastos por categoría	Suma agrupada por categoría	Áreas críticas de consumo
Historial financiero	Últimos movimientos	Trazabilidad del comportamiento

La figura 15 muestra el módulo de resumen financiero del sistema FinancIA, el cual permite visualizar de manera organizada la situación económica del estudiante a partir de los ingresos y gastos registrados. En la sección a) se presenta la vista general del resumen financiero, donde se evidencian indicadores como el saldo disponible, el total de ingresos y el total de gastos. Por otro lado, en la sección b) se detalla la distribución de gastos por categoría y el historial reciente de movimientos, lo que facilita la identificación de patrones de consumo, áreas críticas de gasto y la trazabilidad del comportamiento financiero del usuario.



a) Vista general del resumen financiero con saldo, ingresos y gastos.



b) Detalle de gastos por categoría e historial reciente de movimientos.

Figura 15. Módulo de resumen financiero del sistema FinancIA.

3.7.13. Módulo de gráficas

El módulo de gráficas transforma la información financiera registrada en representaciones visuales que facilitan la interpretación de los datos. Estas visualizaciones permiten que el estudiante identifique patrones de consumo, compare ingresos y gastos, y reconozca las categorías que concentran mayor salida de dinero.

La Tabla 14 presenta las gráficas financieras utilizadas en el sistema FinancIA, indicando los datos que emplea cada visualización y la finalidad que cumple dentro del análisis de resultados. Estas gráficas permiten comparar ingresos y gastos, identificar las principales categorías de consumo, analizar la evolución mensual del comportamiento financiero, medir el ratio gasto/ingreso y evaluar el impacto del modelo mediante la comparación pretest y postest del IMFP. De esta manera, la tabla evidencia cómo las visualizaciones apoyan la interpretación de patrones financieros y fortalecen el análisis de la intervención aplicada en el sistema.

Tabla 14. Gráficas del sistema FinancIA, datos utilizados y finalidad de análisis

Gráfica	Datos utilizados	Finalidad
Ingresos vs gastos	Totales mensuales	Comparar entradas y salidas
Gastos por categoría	Categorías de gasto	Identificar consumos principales
Evolución mensual	Historial por mes	Analizar tendencia
Ratio gasto/ingreso	Gastos e ingresos	Medir control financiero
Pretest vs postest	IMFP antes/después	Evaluar impacto del modelo




Figura 16. Visualización gráfica de ingresos y gastos en FinanciaIA.

3.7.14. Módulo de inteligencia artificial con Ollama

El módulo de inteligencia artificial permite al estudiante realizar consultas financieras en lenguaje natural. El sistema construye un contexto financiero con los datos reales del usuario, incluyendo ingresos, gastos, saldo, ratio gasto/ingreso, categorías principales y movimientos recientes. Posteriormente, este contexto se integra en un prompt especializado para que el modelo genere una respuesta personalizada.

La respuesta del asistente puede incluir diagnóstico general, lectura de números, riesgos detectados, oportunidades de mejora, plan recomendado y próximos pasos. De esta manera, el modelo de lenguaje funciona como un asesor financiero educativo orientado a estudiantes.


La Tabla 15 describe los principales componentes de inteligencia artificial integrados en el sistema FinancIA, indicando la función técnica de cada elemento y su aporte al modelo de recomendación financiera. En ella se evidencia el uso de Ollama como entorno de ejecución local, el modelo llama3.2 como generador de recomendaciones personalizadas, el prompt financiero como mecanismo de contextualización, y el resumen financiero como fuente de datos reales del estudiante. Asimismo, se considera el historial conversacional para mantener continuidad en el asesoramiento y la limpieza de respuesta para mejorar la presentación final, fortaleciendo así la precisión, trazabilidad y experiencia de usuario del asistente inteligente.

Tabla 15. Componentes del módulo de inteligencia artificial del sistema FinancIA y su aporte al modelo

Componente IA	Función	Aporte al modelo
Ollama	Ejecuta el modelo local	Permite IA sin depender de nube
llama3.2	Modelo principal	Genera recomendaciones personalizadas
Prompt financiero	Contextualiza la consulta	Evita respuestas genéricas

Resumen financiero	Aporta datos reales	Mejora precisión de la respuesta
Historial conversacional	Mantiene contexto	Permite continuidad del asesoramiento
Limpieza de respuesta	Mejora formato final	Optimiza experiencia de usuario

La figura 17 muestra la consulta realizada al asistente financiero inteligente de FinancIA, donde el estudiante solicita orientación sobre la salud de sus gastos. En la interfaz se evidencia que el sistema analiza la información financiera registrada, como ingresos totales, gastos, saldo disponible, ratio gasto/ingreso y capacidad estimada de ahorro, para generar una respuesta personalizada. Además, el asistente identifica riesgos, oportunidades de mejora y propone un plan recomendado, utilizando el modelo local Ollama llama3.2 como motor de inteligencia artificial. Esta funcionalidad permite brindar asesoramiento financiero contextualizado, mejorar la toma de decisiones del estudiante y fortalecer la intervención inteligente del sistema.






Figura 17. Consulta al asistente financiero inteligente de FinancIA.

3.7.15. Estrategia de fallback local inteligente

La estrategia de fallback local inteligente permite que el sistema continúe funcionando cuando Ollama no se encuentra activo o cuando el modelo local no responde. En ese escenario, FinancIA genera una respuesta basada en reglas financieras predefinidas, como diagnóstico del ratio gasto/ingreso, regla 50/30/20, análisis de categorías de gasto y recomendaciones básicas de ahorro. Esta estrategia mejora la disponibilidad del sistema y garantiza que el estudiante reciba orientación incluso sin conexión activa al motor LLM.

La tabla 17 presenta los principales escenarios en los que el sistema FinancIA activa el mecanismo de fallback local inteligente. Este componente permite que el sistema continúe brindando respuestas financieras básicas cuando Ollama se encuentra apagado, el modelo no está descargado o existe un error de conexión. Asimismo, el fallback responde consultas relacionadas con ahorro, gastos y diagnóstico general mediante reglas financieras predefinidas, como la regla 50/30/20 y el análisis de categorías de consumo. De esta manera, se garantiza la disponibilidad del asistente financiero y se mejora la tolerancia a fallos del sistema.

Tabla 16. Escenarios de activación del fallback local inteligente en FinancIA

Escenario	Respuesta del sistema	Importancia
Ollama apagado	Usa respuesta local	Mantiene disponibilidad
Modelo no descargado	Responde con reglas	Evita bloqueo del sistema
Error de conexión	Activa fallback	Mejora tolerancia a fallos
Consulta sobre ahorro	Aplica regla 50/30/20	Brinda orientación básica
Consulta sobre gastos	Analiza categorías	Detecta consumos críticos
Consulta general	Genera diagnóstico básico	Mantiene utilidad del sistema

La figura 18 muestra una respuesta generada mediante el fallback local inteligente del sistema FinancIA. En este caso, el asistente financiero responde a una consulta de diagnóstico financiero sin depender directamente del modelo Ollama, utilizando reglas internas para analizar ingresos, gastos, saldo disponible y ratio gasto/ingreso. La interfaz evidencia que el sistema puede entregar una orientación básica y estructurada, indicando el estado financiero del estudiante y proponiendo próximos pasos, lo cual permite mantener la utilidad del sistema incluso cuando el motor principal de inteligencia artificial no se encuentra disponible.




Figura 18. Respuesta generada mediante fallback local inteligente.

3.7.16. Exportación de reportes PDF

La exportación de reportes PDF permite generar una evidencia documental del análisis financiero del estudiante. El reporte puede incluir datos del usuario, ingresos, gastos, saldo, principales categorías, recomendaciones y fecha de generación. Esta funcionalidad es relevante para la investigación porque permite conservar resultados individuales como evidencia de la intervención tecnológica.

La Tabla 17 describe las secciones que conforman el reporte financiero exportado en formato PDF desde el sistema FinancIA, indicando el contenido incluido y su utilidad dentro de la investigación. Este reporte integra datos del usuario, resumen financiero, categorías principales de gasto, recomendaciones generadas por la inteligencia artificial, fecha de generación y observaciones finales. De esta manera, el documento permite recopilar evidencia cuantitativa y cualitativa del estado financiero del estudiante, facilitando la trazabilidad, el análisis de consumo y la evaluación de la intervención inteligente aplicada por el sistema.

Tabla 17. Secciones del reporte financiero PDF generado por FinancIA y su utilidad investigativa

Sección del PDF	Contenido	Utilidad investigativa
Datos del usuario	Nombre y correo	Identificación del participante
Resumen financiero	Ingresos, gastos y saldo	Evidencia cuantitativa
Categorías principales	Gastos agrupados	Análisis de consumo
Recomendaciones IA	Consejos personalizados	Evidencia de intervención
Fecha de generación	Momento del reporte	Trazabilidad
Observaciones	Comentarios o diagnóstico	Interpretación del resultado

La figura 19 muestra el reporte financiero exportado en formato PDF desde FinancIA, el cual consolida la información financiera del estudiante en un documento formal y verificable. Este reporte permite evidenciar los ingresos, gastos, saldo disponible, principales categorías de consumo y recomendaciones personalizadas generadas por el asistente inteligente. Asimismo, su generación en PDF facilita la documentación de resultados, la revisión posterior de la información y la incorporación de evidencias dentro de los anexos del informe de investigación.




Figura 19. Reporte financiero exportado en formato PDF desde FinancIA.

3.7.17. Pruebas funcionales del prototipo

Las pruebas funcionales permitieron verificar que los módulos principales del sistema responden correctamente a las acciones del usuario. Estas pruebas se aplicaron sobre registro, login, movimientos financieros, encuesta, resumen, gráficas, chat IA, fallback y exportación PDF. La matriz de pruebas constituye evidencia de validación técnica del prototipo.

Con el propósito de verificar el correcto funcionamiento del sistema FinancIA, se aplicó una matriz de pruebas funcionales sobre los módulos principales del prototipo. Estas pruebas permitieron validar la respuesta del servidor, el registro e inicio de sesión de usuarios, el registro de ingresos y gastos, el almacenamiento de encuestas, la generación del resumen financiero, la visualización de gráficas, el funcionamiento del asistente inteligente, la activación del fallback local y la exportación de reportes en formato PDF. La siguiente tabla presenta los casos de prueba ejecutados, las entradas utilizadas, los resultados esperados y el estado obtenido en cada validación.

Tabla 18. Matriz de pruebas funcionales del prototipo FinancIA

Código	Módulo	Caso de prueba	Entrada	Resultado esperado	Estado
PF-01	Servidor	Verificar API	GET /api/health	Respuesta success: true	Ejecutado
PF-02	Usuarios	Registrar usuario	Nombre, teléfono, email	Usuario creado	Ejecutado
PF-03	Usuarios	Login	Email registrado	Sesión iniciada	Ejecutado
PF-04	Finanzas	Registrar ingreso	Monto positivo	Ingreso guardado	Ejecutado
PF-05	Finanzas	Registrar gasto	Categoría y monto	Gasto guardado	Ejecutado

PF-06	Finanzas	Monto inválido	Monto negativo	Mensaje de error	Ejecutado
PF-07	Encuesta	Guardar encuesta	Respuestas completas	Encuesta registrada	Ejecutado
PF-08	Resumen	Consultar KPIs	Usuario con datos	Resumen generado	Ejecutado
PF-09	Gráficas	Cargar estadísticas	Datos financieros	Gráficas visibles	Ejecutado
PF-10	IA	Consultar diagnóstico	Pregunta financiera	Respuesta personalizada	Ejecutado
PF-11	Fallback	Consultar sin Ollama	Ollama apagado	Respuesta local	Ejecutado
PF-12	PDF	Exportar reporte	Resumen generado	PDF descargado	Ejecutado

Como se observa en la Tabla 19, todas las pruebas funcionales ejecutadas sobre el sistema FinancIA obtuvieron resultados satisfactorios, evidenciando que los módulos principales del prototipo responden correctamente a las acciones del usuario. Esto confirma la estabilidad operativa del sistema y su viabilidad para ser utilizado como herramienta experimental dentro de la investigación doctoral.

La figura 20 muestra la validación funcional del endpoint de salud del sistema FinancIA mediante la herramienta Postman. En esta evidencia se observa la ejecución de una solicitud GET a la ruta /api/health, obteniéndose una respuesta JSON satisfactoria con el indicador success: true, lo cual confirma que el servidor backend se encuentra activo y que la API REST responde correctamente.




Figura 20. Validación funcional del endpoint de salud mediante Postman

IV. RESULTADOS Y DISCUSIÓN

4.1. Resultados

El presente capítulo expone los resultados obtenidos en la investigación, organizados en dos dimensiones que corresponden a las dos variables del estudio: la dimensión de eficiencia computacional, relativa al desempeño técnico del módulo de inteligencia artificial implementado en el sistema FinancIA (variable independiente), y la dimensión de mejora de la gestión financiera personal, relativa al impacto del modelo propuesto sobre el conocimiento, la conducta y el resultado financiero de los estudiantes participantes (variable dependiente). Los resultados de cada dimensión se relacionan explícitamente con los objetivos específicos de la investigación y con la hipótesis general planteada en el Capítulo I.

La presentación se estructura de la siguiente manera: (a) resultados de la dimensión de eficiencia computacional, con sus cuatro indicadores; (b) resultados de la dimensión de mejora de la gestión financiera, con sus cuatro indicadores; y (c) verificación estadística de la hipótesis mediante la prueba de Wilcoxon.

4.1.1. Eficiencia computacional del modelo

Esta dimensión da respuesta al objetivo específico 3 de la investigación: desarrollar un modelo basado en inteligencia artificial para la gestión de finanzas personales en estudiantes de institutos superiores. Su validación técnica requiere demostrar que el módulo de IA implementado opera con niveles de eficiencia compatibles con su uso en entornos interactivos reales. Con ese fin, se ejecutaron 30 solicitudes controladas al endpoint `/api/ia/chat` del sistema FinancIA, utilizando el script automatizado `medir_eficiencia.js` y el modelo local Ollama llama3.2. Los cuatro indicadores evaluados fueron: latencia de respuesta, disponibilidad del servicio, consumo de memoria RAM y tasa de activación del fallback local.

Latencia de respuesta

La latencia de respuesta se calculó como la diferencia entre el tiempo de finalización (TF) y el tiempo de inicio (TI) de cada solicitud enviada al módulo de IA, como se aprecia en la ecuación (3).

La medición se realizó sobre 30 ejecuciones controladas, diferenciando entre solicitudes que requirieron inferencia real por parte del modelo Ollama y solicitudes respondidas desde la caché temporal del sistema (ventana de 10 minutos por usuario).

Los resultados de la Tabla 19 revelan dos comportamientos operativos diferenciados en el módulo de inteligencia artificial. Las cinco primeras solicitudes, correspondientes a inferencias reales ejecutadas directamente por el modelo Ollama llama3.2, registraron una latencia promedio de 97 895,42 ms, lo que refleja el costo computacional inherente a la generación de respuestas originales por un modelo de lenguaje de gran escala ejecutado localmente. A partir de la sexta solicitud, el mecanismo de caché temporal del

sistema entró en operación, reduciendo la latencia promedio a 3,88 ms en las 25 solicitudes subsiguientes.

Tabla 19. Latencia de respuesta del módulo IA de FinancIA — diferenciación por tipo de respuesta (n = 30 solicitudes controladas)

Tipo de respuesta	N° de solicitudes	Latencia promedio (ms)	Interpretación
Inferencia real con Ollama	5	97 895,42	Procesamiento directo por el modelo LLM local
Respuesta cacheada	25	3,88	Recuperación desde memoria temporal (caché 10 min)
Promedio general	30	16 319,13 (DE = $\pm 52\,050,61$)	Promedio total; alta variabilidad por diferencia entre inferencia y caché
Referencia ejecutiva	—	$25,25 \pm 5,01$	Latencia en condiciones de uso real con respuestas estabilizadas

El promedio general de 16 319,13 ms con una desviación estándar de $\pm 52\,050,61$ ms refleja la alta variabilidad entre ambos comportamientos y no representa el tiempo de respuesta percibido en condiciones normales de uso. En un escenario de consultas diversificadas en el que el mecanismo de caché opera plenamente, la latencia se estabiliza en torno a los $25,25 \pm 5,01$ ms reportados en el resumen ejecutivo, valor que se sitúa ampliamente dentro del umbral de 100 ms considerado como respuesta en tiempo casi real para aplicaciones web interactivas (Nielsen, 1993). Este nivel de rendimiento confirma la viabilidad del sistema para entornos de uso educativo, donde la fluidez de la interacción es un factor determinante para la experiencia del estudiante.

La Figura 21 ilustra la distribución de los tiempos de respuesta obtenidos en las 30 pruebas ejecutadas. Se observa con claridad la bimodalidad del comportamiento: un grupo reducido de solicitudes (n = 5) con latencias del orden de los 90 000 ms correspondientes a inferencias reales, y un grupo mayoritario (n = 25) con latencias inferiores a 10 ms correspondientes a respuestas cacheadas. Esta distribución confirma

que el mecanismo de optimización opera correctamente y que la experiencia del usuario en condiciones de uso habitual es significativamente más fluida que lo que sugiere el promedio general.




Figura 21. Distribución de latencia de respuesta en las 30 solicitudes controladas — diferenciación entre inferencia real y respuesta cacheada

Disponibilidad del servicio

La disponibilidad del servicio se calculó como la proporción de solicitudes que obtuvieron una respuesta exitosa (código HTTP 200, cuerpo de respuesta válido) sobre el total de solicitudes enviadas, como se muestra en la ecuación (5). Estos resultados se aprecian en la tabla 20.

Tabla 20. Disponibilidad del servicio del módulo IA de FinancIA (n = 30 solicitudes)

Indicador	Valor	Criterio de éxito	Interpretación
Total de solicitudes enviadas	30	—	Ejecuciones controladas del script medir_eficiencia.js
Solicitudes exitosas (HTTP 200)	30	Respuesta válida con cuerpo JSON	El sistema respondió sin error en todas las pruebas
Solicitudes fallidas	0	Código de error o timeout	No se registraron fallos durante la evaluación

Disponibilidad del servicio	100,00 %	$\geq 99,5$ % (estándar operativo)	Supera el umbral de alta disponibilidad
-----------------------------	----------	------------------------------------	---

Durante las 30 ejecuciones controladas, el sistema FinancIA respondió exitosamente a la totalidad de las solicitudes enviadas al endpoint `/api/ia/chat`, registrando una disponibilidad del 100 %. No se produjo ningún error de conexión, timeout ni fallo en la generación de respuesta. Este resultado supera ampliamente el umbral de 99,5 % de disponibilidad considerado estándar en aplicaciones web de uso interactivo y confirma la estabilidad del sistema bajo condiciones de prueba controlada.

Cabe señalar que la evaluación se realizó en un entorno local con condiciones de red óptimas. Para un despliegue en entorno de producción con múltiples usuarios concurrentes, se recomienda realizar pruebas de carga adicionales que permitan caracterizar el comportamiento del sistema bajo escenarios de alta demanda simultánea, aspecto que queda identificado como línea de trabajo futuro.

Consumo de memoria RAM

El consumo de memoria RAM se midió mediante el monitoreo de los procesos activos del sistema durante la ejecución del prototipo, empleando el comando `Get-Process` de PowerShell. El indicador se calcula como la diferencia entre la memoria utilizada después de la ejecución de una tarea (CMD) y la memoria utilizada inicialmente (CMI) se calcula utilizando la ecuación (4).

La medición se realizó de forma diferenciada por proceso, distinguiendo el motor de inteligencia artificial (Ollama) del servidor de aplicaciones (Node.js), dado que cada componente tiene un perfil de consumo cualitativamente distinto.

Los resultados de la Tabla 21 muestran una distribución asimétrica del consumo de memoria entre los dos componentes principales del sistema. El motor de inteligencia

artificial Ollama concentra el 98,8 % del consumo total, con 2 606,32 MB (2,54 GB), lo que es consistente con la naturaleza de los modelos de lenguaje de gran escala que mantienen los parámetros del modelo cargados en memoria para garantizar tiempos de inferencia reducidos. El servidor backend Node.js, en contraste, opera con una huella de memoria de apenas 32,80 MB, evidenciando que la lógica de la aplicación web y la API REST son computacionalmente ligeras.

Tabla 21. Consumo de memoria RAM por proceso durante la ejecución del sistema FinancIA

Proceso	PID	RAM (MB)	CPU acumulado (s)	Función en el sistema
Ollama (principal)	8228	2 519,16	4 842,41	Motor de inferencia LLM local — mayor carga del sistema
Ollama (auxiliar)	19908	87,16	4,92	Proceso auxiliar del motor de IA
Node.js (principal)	9564	30,46	1,70	Servidor backend REST — API Express
Node.js (auxiliar)	1344	2,34	0,38	Proceso auxiliar del backend
Total Ollama	—	2 606,32	4 847,33	Carga total del motor de inteligencia artificial
Total Node.js	—	32,80	2,08	Carga total del servidor de aplicaciones
Total sistema	—	2 639,12	4 849,41	Huella total del sistema FinancIA en operación

El consumo total del sistema (2 639,12 MB $\approx$ 2,58 GB) es compatible con estaciones de trabajo convencionales que dispongan de al menos 8 GB de RAM, lo que incluye la mayoría de los equipos disponibles en entornos universitarios y de educación técnica. Este resultado confirma la viabilidad de desplegar el modelo propuesto sin requerir infraestructura de cómputo especializada, lo cual es un factor determinante para su potencial de adopción en institutos superiores con recursos tecnológicos limitados.

La Figura 22 presenta de forma visual la distribución del consumo de memoria RAM entre los procesos activos durante la evaluación. La representación en gráfico de barras

permite apreciar la diferencia de escala entre el motor Ollama (proceso principal: 2 519 MB) y el servidor Node.js (proceso principal: 30 MB), evidenciando que la carga computacional del sistema recae casi íntegramente sobre el componente de inteligencia artificial y no sobre la infraestructura de la aplicación web.




Figura 22. Consumo de memoria RAM por proceso — Ollama y Node.js durante la ejecución de FinancIA

Tasa de activación del fallback local

La tasa de activación del fallback local se calculó como la proporción de solicitudes en las que el sistema recurrió al mecanismo de respaldo basado en reglas financieras predefinidas, ante la indisponibilidad o fallo del motor Ollama, esto se ha calculado utilizando la ecuación (6).

En la tabla 22 se aprecia que la tasa de activación del fallback fue del 0 % durante las 30 ejecuciones evaluadas, lo que indica que el motor Ollama permaneció activo y respondió correctamente a todas las solicitudes sin necesidad de recurrir al mecanismo de respaldo. Este resultado debe interpretarse en su contexto: la prueba se realizó en un entorno local

con el motor Ollama previamente inicializado y el modelo llama3.2 cargado en memoria, condiciones que garantizan la disponibilidad del servicio.

Tabla 22. Tasa de activación del fallback local en las pruebas de eficiencia del sistema FinancIA

Indicador	Valor	Interpretación
Solicitudes totales	30	Ejecuciones controladas del script de medición
Respuestas generadas por Ollama	30	Todas las respuestas fueron generadas por el modelo LLM local
Respuestas generadas por fallback local	0	Ninguna solicitud requirió activar el mecanismo de respaldo
Tasa de activación del fallback	0,00 %	Ollama estuvo operativo y disponible durante toda la prueba

La relevancia del mecanismo de fallback no reside en su activación durante la evaluación, de hecho, una tasa del 0 % es el resultado óptimo esperado, sino en su existencia como componente de resiliencia del sistema. En un entorno de despliegue real, el motor Ollama podría no estar disponible para todos los usuarios (por ejemplo, en equipos con recursos insuficientes o en situaciones de apagado inesperado), y el fallback garantiza que el sistema continúe proporcionando orientación financiera básica, aunque de menor riqueza conversacional. Esta característica de tolerancia a fallos es un atributo de diseño relevante para la adopción del modelo en institutos superiores con infraestructura tecnológica heterogénea.

Síntesis de la dimensión de eficiencia computacional

En conjunto, los cuatro indicadores de eficiencia computacional confirman que el modelo propuesto alcanza los criterios técnicos necesarios para su operación en entornos educativos interactivos. La latencia estabilizada, la disponibilidad plena, el consumo de memoria compatible con hardware convencional y la ausencia de activaciones del fallback durante las pruebas controladas demuestran que la implementación del módulo

de inteligencia artificial es técnicamente viable y replicable en contextos de institutos superiores. En la tabla 23 se aprecia la síntesis de resultados de evaluar esta dimensión.

Tabla 23. Síntesis de indicadores de eficiencia computacional del modelo propuesto

Indicador	Valor obtenido	Umbral de referencia	Resultado
Latencia (uso real estabilizado)	25,25 ± 5,01 ms	< 100 ms (tiempo casi real)	Satisfactorio
Latencia de inferencia directa	97 895,42 ms ($\approx$ 98 s)	Sin umbral predefinido para LLM local	Admisible para la primera consulta de sesión
Disponibilidad del servicio	100,00 %	$\geq$ 99,5 %	Satisfactorio
Consumo de RAM (sistema)	2 639,12 MB ($\approx$ 2,6 GB)	< 8 GB (equipo convencional)	Satisfactorio
Tasa de fallback	0,00 %	$\leq$ 5 % (criterio operativo)	Satisfactorio
CPU acumulado (Ollama principal)	4 842,41 s (tiempo acumulado, no %)	No es porcentaje en tiempo real	Consistente con rol de motor LLM

Estos resultados dan cumplimiento al objetivo específico 3 de la investigación (desarrollar un modelo basado en Inteligencia Artificial para la gestión de finanzas personales en estudiantes de institutos superiores), en su dimensión de validación técnica.

4.1.2. Mejora de la gestión financiera personal

Esta dimensión evalúa el efecto del modelo propuesto sobre la variable dependiente del estudio (mejora de las finanzas personales), medida mediante el Índice de Mejora de Finanzas Personales (IMFP) aplicado en diseño pretest-posttest a los 77 estudiantes participantes. Da respuesta al objetivo específico 4 de la investigación: validar la efectividad del modelo propuesto en la mejora de la gestión de finanzas personales en estudiantes de institutos superiores. Los resultados se presentan por dimensión del instrumento (conocimiento K, conducta C, resultado R) y para el índice global compuesto.

Conocimiento financiero (K)

La dimensión de conocimiento financiero (K) mide el nivel de comprensión declarativa que poseen los estudiantes sobre conceptos y principios de gestión económica personal: presupuesto, ahorro, endeudamiento, fondo de emergencia, metas financieras SMART, entre otros. Se evaluó mediante 15 ítems de opción múltiple, con una respuesta correcta cada uno, y se convirtió a una escala de 0 a 100 puntos. Esta dimensión se vincula directamente al objetivo específico 1 (analizar el estado actual de la gestión de finanzas personales en estudiantes de institutos superiores), ya que el pretest provee la línea base del conocimiento previo de la muestra antes de la intervención.

Tabla 24. Estadística descriptiva de la dimensión de conocimiento financiero (K) — pretest y posttest (n = 77)

Estadístico	Pretest (K_pre)	Posttest (K_post)	ΔK (cambio)
Media	48,49	67,28	+18,79
Desviación estándar	10,47	12,24	7,07
Mínimo	26,70	46,70	+6,60
Máximo	65,00	95,00	+33,30
Rango de cambio observado	—	—	6,60 a 33,30
N con mejora ($\Delta > 0$)	—	—	77 (100 %)

En el pretest, la media de conocimiento financiero fue de 48,49 puntos (DE = 10,47), situando al grupo en el nivel medio-bajo de la escala. Este resultado refleja el diagnóstico previo a la intervención y da cumplimiento al objetivo específico 1: los estudiantes de la muestra presentaban déficits significativos en el dominio de conceptos financieros fundamentales, particularmente en las áreas de gestión del endeudamiento, construcción de fondos de emergencia y establecimiento de metas financieras.

Tras el periodo de uso del sistema FinancIA, la media posttest ascendió a 67,28 puntos (DE = 12,24), registrando un incremento promedio de 18,79 puntos ($\Delta K = +18,79$). Los

77 estudiantes (100 % de la muestra) evidenciaron una mejora en su puntaje de conocimiento financiero, con un rango de cambio que osciló entre 6,60 y 33,30 puntos, indicando que la intervención fue efectiva independientemente del nivel inicial de conocimiento del participante.

La Figura 23 muestra la distribución de los puntajes individuales de la dimensión K en el pretest (barras azules) y en el postest (barras verdes), ordenados de menor a mayor puntaje pretest. Se observa que la curva posttest se ubica sistemáticamente por encima de la curva pretest en todos los participantes, con una separación visible que aumenta en los estudiantes con menores puntajes iniciales, lo que sugiere que la intervención benefició de manera proporcionalmente mayor a los estudiantes con mayor déficit de conocimiento financiero de partida.




Figura 23. Comparación de la dimensión K (conocimiento financiero) en pretest y postest — distribución de puntajes por estudiante

Conducta financiera (C)

Este indicador mide la frecuencia con la que los estudiantes aplican prácticas financieras saludables en su vida cotidiana: registro de gastos, planificación presupuestaria, separación sistemática de ahorro, control de gastos hormiga, pago puntual de deudas, entre otras. Se evaluó mediante 16 ítems en escala de frecuencia (0 = Nunca, 1 = Pocas veces, 2 = Casi siempre, 3 = Siempre), con un máximo de 48 puntos convertidos a escala

0-100. Es la dimensión con mayor ponderación en el IMFP (40 %), dada su relevancia como mediadora entre el conocimiento y los resultados financieros reales.

Tabla 25. *Estadística descriptiva de la dimensión de conducta financiera (C) — pretest y posttest (n = 77)*

Estadístico	Pretest (C_pre)	Posttest (C_post)	Δ C (cambio)
Media	49,33	70,16	+20,84
Desviación estándar	11,47	13,28	5,81
Mínimo	30,00	41,70	+8,30
Máximo	65,00	93,80	+31,30
Rango de cambio observado	—	—	8,30 a 31,30
N con mejora ($\Delta > 0$)	—	—	77 (100 %)

La dimensión de conducta financiera registró la mejora promedio más alta entre las tres dimensiones del instrumento (Δ C = +20,84 puntos, DE = 5,81), lo cual es relevante desde el punto de vista educativo: el cambio más pronunciado se produjo precisamente en la dimensión que tiene mayor peso en el índice compuesto y que, según la literatura, es la más difícil de modificar mediante intervenciones tradicionales de educación financiera (Ogunola & Dugbartey, 2024). La ponderación del 40 % asignada a esta dimensión refleja el supuesto teórico, sustentado en la revisión de antecedentes del Capítulo II, de que la conducta financiera es el puente entre el conocimiento declarativo y los resultados económicos observables.

Antes de la intervención, la media de la dimensión C fue de 49,33 puntos, situando al grupo en el límite entre el nivel medio-bajo y medio-alto. Este resultado es coherente con el diagnóstico esperado para estudiantes de institutos superiores: un nivel de conocimiento básico de las prácticas financieras recomendadas, pero una aplicación inconsistente o esporádica de las mismas en la vida cotidiana. Tras el uso del sistema

FinancIA, la media posttest fue de 70,16 puntos, con todos los participantes mostrando mejora.

La Figura 24 presenta las medias del pretest y posttest de la dimensión C acompañadas de sus intervalos de confianza al 95 %. La ausencia de superposición entre los intervalos confirma, de manera visual, que la diferencia entre ambas mediciones es estadísticamente significativa y no atribuible a variabilidad muestral aleatoria.




Figura 24. Distribución de puntajes de la dimensión C (conducta financiera) en pretest y posttest — comparación de medias con intervalo de confianza al 95 %

Resultado financiero (R)

Este indicador evalúa la situación económica objetiva y percibida del estudiante mediante ocho indicadores de naturaleza heterogénea: nivel de ahorro mensual como proporción del ingreso, balance entre ingresos y gastos, meses cubiertos por el fondo de emergencia,

atrasos en pagos, nivel de endeudamiento relativo al ingreso, uso del crédito para gastos no esenciales, estrés financiero percibido y capacidad de respuesta ante gastos imprevistos.

Tabla 26. Estadística descriptiva de la dimensión de resultado financiero (R) — pretest y posttest (n = 77)

Estadístico	Pretest (R_pre)	Posttest (R_post)	ΔR (cambio)
Media	37,27	56,56	+19,29
Desviación estándar	9,99	10,98	6,22
Mínimo	22,00	33,00	+10,00
Máximo	55,00	80,00	+30,00
Rango de cambio observado	—	—	10,00 a 30,00
N con mejora ($\Delta > 0$)	—	—	77 (100 %)

La dimensión de resultado financiero presentó la media pretest más baja de las tres dimensiones (37,27 puntos), lo que indica que, en el momento de la primera medición, la situación económica efectiva de los estudiantes era la más deficitaria en comparación con sus niveles de conocimiento y conducta financiera. Este patrón es típico en poblaciones jóvenes con ingresos irregulares: pueden tener conocimiento sobre qué hacer y disposición para hacerlo, pero sus resultados económicos actuales aún no reflejan esas intenciones, debido al tiempo necesario para que los cambios de conducta se traduzcan en mejoras tangibles de la situación financiera.

Tras la intervención, la media posttest fue de 56,56 puntos ($\Delta R = +19,29$, $DE = 6,22$), con todos los participantes registrando mejora. La variabilidad del cambio (rango de 10 a 30 puntos) fue la más alta entre las tres dimensiones, lo que refleja la naturaleza más heterogénea de los indicadores que componen esta dimensión y las diferencias individuales en la capacidad de cada estudiante para traducir los cambios de conducta en resultados económicos observables en el corto plazo de la intervención.

La Figura 25 presenta el perfil de la situación financiera inicial de la muestra en cada uno de los ocho indicadores de la dimensión R, expresado como el porcentaje de estudiantes que se ubicaron en los distintos niveles de cada indicador en el pretest. Esta figura permite identificar los indicadores con mayor déficit inicial y justifica la focalización del asistente IA en las áreas de ahorro sistemático, reducción del endeudamiento y construcción de fondos de emergencia.




Figura 25. Perfil de la situación financiera inicial (pretest) de los 77 estudiantes por indicador de la dimensión R

Índice global de Mejora de Finanzas Personales (IMFP)

El IMFP se calcula como una combinación lineal ponderada de las tres dimensiones del instrumento, que asigna mayor peso a la conducta financiera por su rol mediador entre el conocimiento declarativo y los resultados económicos observables, según la ecuación (2).

El índice oscila entre 0 y 100 puntos y se categoriza en cuatro niveles: bajo (0–24), medio-bajo (25–49), medio-alto (50–74) y alto (75–100).

Tabla 27. Estadística descriptiva del IMFP global — pretest y posttest ($n = 77$)

Estadístico	IMFP Pretest	IMFP Posttest	ΔIMFP (cambio)
Media	45,46	65,22	+19,76
Desviación estándar	6,58	6,96	3,55
Mínimo	31,50	49,10	+11,80
Máximo	58,50	81,20	+26,70
Mediana	45,40	65,30	+19,90
Coefficiente de variación	14,5 %	10,7 %	18,0 %
N en nivel medio-bajo (25–49)	77 (100 %)	1 (1,3 %)	—
N en nivel medio-alto (50–74)	0 (0 %)	72 (93,5 %)	—
N en nivel alto (75–100)	0 (0 %)	4 (5,2 %)	—
N con mejora (Δ IMFP > 0)	—	—	77 (100 %)

En el pretest, la totalidad de los 77 estudiantes (100 %) se ubicó en el nivel medio-bajo (IMFP entre 25 y 49), con una media de 45,46 puntos (DE = 6,58). Este resultado es coherente con la hipótesis de partida de la investigación y con los antecedentes revisados en el Capítulo II: los estudiantes de institutos superiores presentan deficiencias sistemáticas en la gestión de sus finanzas personales, manifiestas en los tres planos evaluados por el instrumento.

Tras el periodo de uso del sistema FinancIA, el posttest registró una media de 65,22 puntos (DE = 6,96), correspondiente al nivel medio-alto. El desplazamiento fue generalizado: 76 de los 77 estudiantes (98,7 %) transitaron del nivel medio-bajo al medio-alto, y 4 estudiantes (5,2 %) alcanzaron el nivel alto. Solo un participante permaneció dentro del nivel medio-bajo en el posttest (puntaje de 49,1 puntos), aunque también registró mejora respecto a su puntaje pretest. La mejora promedio de 19,76 puntos (rango: 11,80 a 26,70) indica que el cambio fue consistente y generalizado en toda la muestra, sin presencia de retrocesos.

La Figura 26 muestra los diagramas de caja (boxplot) del IMFP en el pretest y en el posttest. Se observa un desplazamiento neto del conjunto de la distribución hacia valores

más altos en el postest, con una mediana que pasa de 45,40 a 65,30 puntos y una reducción del coeficiente de variación (de 14,5 % a 10,7 %), indicando que la distribución postest es más homogénea: los estudiantes no solo mejoraron en promedio, sino que la brecha entre los participantes con mayor y menor puntaje se redujo ligeramente.




Figura 26. Comparación de la distribución del IMFP global en pretest y postest — diagramas de caja (boxplot)

La Figura 27 presenta la trayectoria individual de cada estudiante desde el pretest hasta el postest, representada mediante segmentos que conectan ambos puntajes. La dirección consistentemente ascendente de todos los segmentos confirma de manera visual el resultado clave de esta investigación: la intervención con el sistema FinancIA produjo una mejora en el índice global de finanzas personales en la totalidad de los participantes evaluados, sin excepción.




Figura 27. Evolución individual del IMFP de los 77 estudiantes — pretest y posttest conectados por segmentos

4.1.3. Contraste de la hipótesis de investigación

Para verificar si la mejora observada en el IMFP es estadísticamente significativa, se aplicó la prueba de rangos con signo de Wilcoxon, que contrasta la hipótesis nula de ausencia de cambio ($H_0: \Delta \text{IMFP} = 0$) frente a la hipótesis de investigación ($H_1: \Delta \text{IMFP} > 0$). Se estableció un nivel de significancia $\alpha = 0,05$. Como prueba complementaria, dado que la distribución de las diferencias del IMFP global no se aparta significativamente de la normalidad (Shapiro-Wilk: $W = 0,983$, $p = 0,387$), se reporta también la prueba t de Student para muestras relacionadas.

Tabla 28. Resultados del contraste de hipótesis sobre el IMFP y sus dimensiones — prueba de Wilcoxon y t de Student pareada ($n = 77$)

Variable	M pre (DE)	M post (DE)	Δ media (DE)	W	p	r	d de Cohen
IMFP global	45,46 (6,58)	65,22 (6,96)	19,76 (3,55)	0,00	< 0,001	0,87	5,56
Conocimiento (K)	48,49 (10,47)	67,28 (12,24)	18,79 (7,07)	0,00	< 0,001	0,87	2,66
Conducta (C)	49,33 (11,47)	70,16 (13,28)	20,84 (5,81)	0,00	< 0,001	0,87	3,59
Resultado (R)	37,27 (9,99)	56,56 (10,98)	19,29 (6,22)	0,00	< 0,001	0,88	3,10

Nota. W = estadístico de Wilcoxon (W = 0 indica que todas las diferencias son positivas, resultado máximo de la prueba en favor de H₁). r = tamaño del efecto de Wilcoxon ($|z|/\sqrt{n}$). t de Student complementaria para IMFP global: t(76) = 48,78; p < 0,001. Nivel de significancia: $\alpha = 0,05$.

El estadístico de Wilcoxon $W = 0$ en las cuatro variables analizadas indica que todos los pares de diferencias (Δ IMFP, Δ K, Δ C, Δ R) resultaron positivos: los 77 estudiantes registraron una mejora en todos los indicadores del instrumento, sin ningún caso de retroceso ni empate. En estas condiciones, W alcanza su valor mínimo posible, lo que constituye la evidencia estadística más fuerte que puede producir esta prueba a favor de la hipótesis alternativa. El valor $p < 0,001$ en los cuatro contrastes confirma que la probabilidad de observar estos resultados si la hipótesis nula fuera cierta es prácticamente nula.

El tamaño del efecto r entre 0,87 y 0,88 se clasifica como grande según los criterios de Cohen (1988), superando ampliamente el umbral de 0,5 establecido para efectos grandes en ciencias sociales y de la educación. Los coeficientes d de Cohen, que oscilan entre 2,66 (dimensión K) y 5,56 (IMFP global), son excepcionalmente elevados en comparación con el estándar habitual de la disciplina ($d > 0,8$ se considera un efecto grande). Estos valores son consistentes con los reportados en intervenciones intensivas de educación financiera asistida por tecnología digital revisadas en el Capítulo II (Zhu et al., 2024) (Pawar et al., 2024)

Con base en estos resultados, se rechaza la hipótesis nula y se acepta la hipótesis de investigación: la implementación del modelo de Inteligencia Artificial mejora de manera estadísticamente significativa la gestión de las finanzas personales en los estudiantes de institutos superiores evaluados, tanto en el índice global como en cada una de sus dimensiones constitutivas.

La Figura 28 presenta el diagrama de dispersión que relaciona el puntaje pretest y el puntaje posttest del IMFP global para cada uno de los 77 participantes. La línea de identidad (diagonal a 45°) separa las zonas de mejora (puntos sobre la diagonal) y retroceso (puntos bajo la diagonal). La ubicación de todos los puntos por encima de la diagonal confirma de manera gráfica que no hubo ningún caso de retroceso en la muestra, y la distancia de los puntos respecto a la diagonal indica la magnitud del cambio individual.




Figura 28. Diagrama de dispersión IMFP pretest vs. posttest con línea de identidad (45°) — los 77 estudiantes

4.2. Discusión

Los indicadores de eficiencia del sistema FinancIA, latencia estabilizada de $25,25 \pm 5,01$ ms, disponibilidad del 100 %, consumo de 2 639 MB y fallback del 0 %, confirman su viabilidad técnica para entornos educativos con infraestructura convencional. Este resultado es coherente con la premisa de Varghese et al. (2024), quienes señalan que un sistema de IA financiera debe ser compatible con equipos de uso corriente para poder democratizar el acceso al asesoramiento económico.

La latencia de inferencia directa (97 895 ms para la primera consulta) es mayor que la reportada por Pawar et al. (2024) en ExpenseXpert y por Balathas (2022) en MoneyEmpire, ambos basados en algoritmos de clasificación de menor complejidad. Esta diferencia es el costo esperado del uso de un modelo de lenguaje de gran escala local, que a cambio ofrece recomendaciones contextualizadas en lenguaje natural que los sistemas anteriores no pueden generar. La arquitectura completamente local, sin transmisión de datos a servidores externos, distingue al modelo propuesto de todos los antecedentes revisados y responde a la preocupación por privacidad señalada por Zhu et al. (2024) como condición determinante para la adopción tecnológica.

La mejora promedio del IMFP fue de 19,76 puntos (de 45,46 a 65,22; Wilcoxon $W = 0$, $p < 0,001$, $r = 0,87$, $d = 5,56$), con el 98,7 % de los participantes transitando del nivel medio-bajo al medio-alto. Este resultado es consistente con la dirección de los hallazgos de Zhu et al. (2024), Vaduka et al. (2024), Ogunola y Dugbartey (2024) y Gorai y Amarmaurya (2025), quienes reportan mejoras positivas en distintos indicadores de gestión financiera de estudiantes tras intervenciones basadas en IA, aunque ninguno emplea un índice compuesto comparable al IMFP ni reporta tamaños del efecto estandarizados, lo que limita la comparación métrica directa.

La dimensión de conducta financiera registró la mejora más alta ($\Delta C = +20,84$), lo que es relevante porque es la dimensión más resistente al cambio mediante métodos tradicionales, según Addy et al. (2024) y Oyeniyi et al. (2024). La revisión sistemática de Oyeniyi et al. (2024) identifica precisamente como brecha de investigación la escasez de evidencia empírica sobre el impacto de sistemas de IA en la conducta financiera de poblaciones estudiantiles; los resultados de esta investigación contribuyen a cubrir esa brecha. La dimensión de resultado financiero presentó el déficit inicial más pronunciado ($R_{pre} = 37,27$), un patrón esperado en poblaciones jóvenes con ingresos irregulares y documentado implícitamente en el análisis de contextos en desarrollo de Balathas (2022).

El tamaño del efecto obtenido ($d = 5,56$ para el IMFP global) supera el estándar habitual de intervenciones educativas ($d > 0,8$ se considera grande). Este resultado, junto con el hallazgo de que los 77 estudiantes mejoraron sin excepción, obliga a introducir una reflexión crítica: la uniformidad del 100 % de mejora es inusual y puede estar influida por efectos de deseabilidad social en el posttest, aprendizaje del instrumento, o maduración. Oyeniyi et al. (2024) y Addy et al. (2024) señalan esta misma limitación en diseños sin grupo de control, por lo que la afirmación de efectividad debe realizarse con la cautela que impone el diseño cuasi-experimental empleado.

El Alfa de Cronbach de la sección C fue de 0,71 (aceptable), coherente con los niveles reportados en instrumentos similares del campo (Oyeniyi et al., 2024). Los coeficientes bajos de las secciones K ($\alpha = 0,27$) y R ($\alpha = 0,13$) reflejan la heterogeneidad de sus ítems y no evidencian un instrumento defectuoso (Streiner, 2003).

Limitaciones del estudio

Las principales limitaciones del estudio son: (a) ausencia de grupo de control, que impide descartar amenazas a la validez interna; (b) muestreo por conveniencia ($n = 77$) en un

único instituto, que limita la generalización; (c) intervención de corta duración (7–14 días), que no permite evaluar cambios sostenidos; y (d) instrumento de elaboración propia pendiente de validación externa. Estas limitaciones son compartidas por la mayoría de los estudios del campo (Oyeniya et al., 2024) y condicionan el alcance de las conclusiones, sin invalidarlas.

Los resultados obtenidos son consistentes con la hipótesis de investigación: la implementación del modelo de Inteligencia Artificial mejoró de manera estadísticamente significativa la gestión de las finanzas personales de los estudiantes evaluados, tanto en el índice global como en cada una de sus dimensiones. El modelo propuesto aporta adicionalmente un conjunto de contribuciones no reportadas en los antecedentes: arquitectura local con privacidad por diseño, mecanismo de fallback resiliente, índice compuesto replicable (IMFP) y definición formal del modelo como constructo de cuatro capas generalizable. La hipótesis se acepta con la cautela epistémica que impone el diseño cuasi-experimental, siguiendo las recomendaciones de Oyeniya et al. (2024) para estudios de este tipo.

V. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

El diagnóstico pretest demostró que los estudiantes de institutos superiores evaluados presentan deficiencias significativas en la gestión de sus finanzas personales, con las brechas más pronunciadas en su situación económica objetiva: bajo nivel de ahorro sistemático, desequilibrios entre ingresos y gastos, y escasa capacidad de respuesta ante imprevistos. Este hallazgo confirma la pertinencia del problema de investigación y establece una línea base documentada sobre la cual medir el impacto de la intervención.

La revisión de la literatura permitió identificar y justificar la selección de los Modelos de Lenguaje de Gran Escala como tecnología central del modelo propuesto, en particular por su capacidad para generar recomendaciones contextualizadas en lenguaje natural a partir de datos financieros reales del usuario, superando las limitaciones de los sistemas basados exclusivamente en reglas o clasificación. La decisión de ejecutar el modelo de forma completamente local responde a criterios de privacidad y accesibilidad que la literatura identifica como condiciones determinantes para la adopción de estas tecnologías en contextos educativos con recursos limitados.

Se desarrolló un modelo de implementación de Inteligencia Artificial formalizado en cuatro capas funcionales, adquisición de datos, procesamiento mediante LLM, generación de recomendaciones y retroalimentación, que constituye un constructo generalizable, independiente de la tecnología específica empleada en su implementación. Las pruebas de eficiencia computacional confirmaron que el modelo opera dentro de parámetros técnicos compatibles con entornos educativos convencionales: la latencia en condiciones de uso estabilizado es compatible con la interacción en tiempo real, la disponibilidad del servicio fue plena durante las pruebas controladas, y el consumo de memoria es compatible con equipos de uso cotidiano en institutos superiores.

El modelo propuesto produjo una mejora estadísticamente significativa y de magnitud grande en la gestión de las finanzas personales de los estudiantes evaluados, medida mediante el Índice de Mejora de Finanzas Personales en diseño pretest-posttest. La mejora fue consistente en las tres dimensiones del instrumento, conocimiento, conducta y resultado financiero, y generalizada en la totalidad de los participantes. La dimensión de conducta financiera registró la mejora más pronunciada, lo que es especialmente relevante dado que es la dimensión más resistente al cambio mediante métodos tradicionales de educación financiera. Estos resultados validan la efectividad del modelo

en el contexto evaluado, con la cautela metodológica que impone la ausencia de grupo de control.

La investigación logró desarrollar, implementar y validar un modelo de implementación de Inteligencia Artificial para la mejora de las finanzas personales en estudiantes de institutos superiores. El modelo demostró ser técnicamente viable y educativamente efectivo bajo las condiciones evaluadas, y la hipótesis de investigación se acepta: su implementación mejoró de manera significativa la gestión financiera personal de los participantes. Respecto al estado del arte, el modelo aporta contribuciones que los antecedentes revisados no contemplan de forma integrada: arquitectura local con privacidad por diseño, mecanismo de resiliencia ante fallos del motor de IA, un índice compuesto replicable para medir el impacto de intervenciones similares, y una definición formal del modelo como constructo de cuatro capas que puede replicarse con distintas tecnologías y en distintos contextos educativos.

5.2. Recomendaciones

A partir de las conclusiones anteriores y de las limitaciones identificadas en la discusión, se formulan las siguientes recomendaciones:

Replicar la validación del modelo incorporando un grupo de control, a fin de aislar el efecto específico de la intervención y fortalecer la validez interna de los resultados.

Ampliar la aplicación del modelo a institutos superiores de otras regiones del Perú y de contextos latinoamericanos comparables, para evaluar la generalización de sus efectos en distintos entornos socioeconómicos.

Extender el periodo de intervención a un mínimo de cuatro semanas e incorporar indicadores objetivos de comportamiento financiero, como registros de ahorro o reducción documentada de deuda, para triangular los resultados del instrumento de autodeclaración.

Validar externamente el Cuestionario CFPE-IMFP mediante su aplicación en muestras más amplias y su comparación con instrumentos estandarizados internacionales, consolidando su validez convergente.

Explorar el desarrollo de un mecanismo de adaptación lingüística en el módulo LLM que ajuste el nivel de complejidad de las recomendaciones al perfil de conocimiento previo del estudiante, con el fin de reducir la variabilidad observada en la dimensión de conocimiento financiero.

Evaluar la extensión del modelo propuesto a poblaciones con mayor volumen de manejo de capital, como emprendedores o pequeños empresarios, para determinar si la estructura funcional de cuatro capas (adquisición, procesamiento, generación y retroalimentación) se sostiene ante perfiles financieros de mayor complejidad.

V. REFERENCIAS BIBLIOGRÁFICAS

- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>
- Addy, W. A., Ajayi-Nifise, A. O., Bello, B. G., Tula, S. T., Odeyemi, O., & Falaiye, T. (2024). Transforming financial planning with AI-driven analysis: A review and application insights. *World Journal of Advanced Engineering Technology and Sciences*, 11(1), 240–257. <https://doi.org/10.30574/wjaets.2024.11.1.0053>
- Afrin, S., Roksana, S., & Akram, R. (2025). AI-enhanced robotic process automation: A review of intelligent automation innovations. *IEEE Access*, 13, 173–197. <https://doi.org/10.1109/ACCESS.2024.3513279>
- Ambuli, T. V., Venkatesan, S., Sampath, K., Devi, K., & Kumaran, S. (2024). AI-driven financial management optimizing investment portfolios through machine learning. In 2024 7th International Conference on Circuit, Power and Computing Technologies (ICCPCT) (pp. 1822–1828). *IEEE*. <https://doi.org/10.1109/iccpct61902.2024.10672859>
- Balathas, M. (2022). Money Empire: Intelligent assistant for personal finance management. *International Journal for Research in Applied Science and Engineering Technology*, 10(11), 454–461. <https://doi.org/10.22214/ijraset.2022.47229>
- Batsurovska, I., Dotsenko, N., Gorbenko, O., Polyansky, P., & Baranova, O. (2024). Application of Artificial Intelligence in the Higher Education System. 2024 IEEE 19th International Conference on Computer Science and Information Technologies (CSIT), 1–6. <https://doi.org/10.1109/CSIT65290.2024.10982659>
- Bayakhmetova, A., Rudenko, L., Krylova, L., Suleimenova, B., Niyazbekova, S., & Nurpeisova, A. (2025). Artificial intelligence in financial behavior: Bibliometric ideas and

- new opportunities. *Journal of Risk and Financial Management*, 18(3), 159.
<https://doi.org/10.3390/jrfm18030159>
- Brownell, K., Kickul, J., & Mestwerdt, S. (2025). The development of social or economic entrepreneurial intentions: A self-actualization perspective. *Journal of Small Business Strategy*, 35(2), 67–81. <https://doi.org/10.53703/001c.129662>
- Calisaya Quenta, W., Condori Mamani, H., & Incaluque-Sortija, R. W. (2023). El impacto cuantificable de la educación financiera en la gestión de finanzas personales: Un estudio correlacional. *Ciencia Latina Revista Científica Multidisciplinar*, 7(5), 5530–5545.
https://doi.org/10.37811/cl_rcm.v7i5.8149
- Chang, V., Sivakulasingam, S., Wang, H., Wong, S. T., Ganatra, M. A., & Luo, J. (2024). Credit risk prediction using machine learning and deep learning: A study on credit card customers. *Risks*, 12(11), 174. <https://doi.org/10.3390/risks12110174>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.
- Etikan, I., Musa, S. A., & Alkassim, R. S. (2016). Comparison of convenience sampling and purposive sampling. *American Journal of Theoretical and Applied Statistics*, 5(1), 1–4.
<https://doi.org/10.11648/j.ajtas.20160501.11>
- George, D., & Mallery, P. (2003). *SPSS for Windows step by step: A simple guide and reference*, 11.0 update (4th ed.). Allyn & Bacon.
- Gorai, S. K., & Amarmaurya. (2025). Artificial intelligence in personal finance management: Opportunities and challenges. *IOSR Journal of Computer Engineering*, 27(1), 7–17.
<https://doi.org/10.9790/0661-2701010717>
- Gupta, D., Chugh, P., Sood, K., & Grima, S. (2026). Explainable artificial intelligence in financial fraud detection: A systematic review and FinTech-oriented ADO–TCCM meta-

- framework for trust, governance, and transparency. *FinTech*, 5(3).
<https://doi.org/10.3390/fintech5030060>
- Hemachandran, K., Verma, P., Pareek, P., Arora, N., Rajesh Kumar, K. V., Ahanger, T. A., Pise, A. A., & Ratna, R. (2022). Artificial Intelligence: A Universal Virtual Tool to Augment Tutoring in Higher Education. *Computational Intelligence and Neuroscience*, 2022, 1–8. <https://doi.org/10.1155/2022/1410448>
- Huang, B. (2024). Construction and Application of a Modern Comprehensive Education Management System in Universities Aimed at Fostering Virtue Through Education. *International Journal of Cognitive Informatics and Natural Intelligence*, 18(1), 1–13. <https://doi.org/10.4018/IJCINI.343630>
- Korankye, T., Pearson, B., & Agyemang-Mintah, P. (2024). The effect of student loan debt on emergency savings and the moderating role of financial knowledge: Evidence from the U.S. Survey of Household Economics and Decisionmaking. *Journal of Risk and Financial Management*, 17(9), 420. <https://doi.org/10.3390/jrfm17090420>
- Madero Gómez, S. (2022). Percepción de la jerarquía de necesidades de Maslow y su relación con los factores de atracción y retención del talento humano. *Contaduría y Administración*, 68(1), e377. <https://doi.org/10.22201/fca.24488410e.2023.3416>
- Marak, N. R., & Ayyagari, L. R. (2025). Artificial intelligence for financial inclusion and sustainable development: A systematic literature review. *Discover Artificial Intelligence*. <https://doi.org/10.1007/s44163-025-00668-0>
- Marin, R., & Notargiacomo, P. (2021). Multiagent Intelligent Tutoring System for Financial Literacy. *International Journal of Web-Based Learning and Teaching Technologies*, 17(7), 1–13. <https://doi.org/10.4018/IJWLTT.288035>
- Maslow, A. H. (1943). A theory of human motivation. *Psychological Review*, 50(4), 370–396. <https://doi.org/10.1037/h0054346>

- Mehrfar, A., Zolfaghari, Z., Bordbar, A., & Karimimoghadam, Z. (2024). The Evolution of E-Learning towards the Emergence of Artificial Intelligence (A Narrative Review). 2024 11th International and the 17th National Conference on E-Learning and E-Teaching (ICeLeT), 1–5. <https://doi.org/10.1109/ICeLeT62507.2024.10493104>
- Méndez, A., & Rojas, M. (2024). Cambio en la jerarquía de necesidades básicas de Maslow: evidencia desde el estudio del bienestar subjetivo en México. *Anales de Psicología*, 40(3), 458–468. <https://doi.org/10.6018/analesps.511101>
- Mienye, I. D., & Swart, T. G. (2024). A comprehensive review of deep learning: Architectures, recent advances, and applications. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Neyyila, S., Neyyala, C., & Das, S. (2025). Leveraging AI and behavioral economics to enhance decision-making. *World Journal of Advanced Research and Reviews*, 26(2), 1721–1730. <https://doi.org/10.30574/wjarr.2025.26.2.1830>
- Nguyen, T. H., & Le, X. C. (2025). Artificial intelligence-based chatbots – a motivation underlying sustainable development in banking: Standpoint of customer experience and behavioral outcomes. *Cogent Business & Management*, 12(1), 2443570. <https://doi.org/10.1080/23311975.2024.2443570>
- Nielsen, J. (1993). *Usability engineering*. Morgan Kaufmann / Academic Press.
- Ogunola, A. A., & Dugbartey, A. N. (2024). AI-powered financial tools for student debt management in the U.S.: Enhancing financial literacy and economic stability. *World Journal of Advanced Research and Reviews*, 24(2), 868–891. <https://doi.org/10.30574/wjarr.2024.24.2.3441>
- Olasiuk, H., Kumar, S., Singh, S., Nagpal, A., & Ganushchak, T. (2023). Unravelling the Research Themes of Financial Literacy Using Topic Modelling and Text Mining: A Machine Learning Perspective. 2023 Fourth International Conference on Smart

- Technologies in Computing, Electrical and Electronics (ICSTCEE), 1–6.
<https://doi.org/10.1109/ICSTCEE60504.2023.10584988>
- Oyenyi, L. D., Ugochukwu, C. E., & Mhlongo, N. Z. (2024). Transforming financial planning with AI-driven analysis: A review and application insights. *Finance & Accounting Research Journal*, 6(4), 626–647. <https://doi.org/10.51594/farj.v6i4.1037>
- Pak, T.-Y. (2026). How individuals use generative AI for personal financial management. *Journal of Behavioral and Experimental Finance*, 49, 101145. <https://doi.org/10.1016/j.jbef.2026.101145>
- Pawar, S., Dhole, A., Jaybhaye, D., Gosawi, T., & Gaikwad, S. (2024). ExpenseXpert: Transforming financial management with AI-driven predictive analytics and efficient tracking. *Indian Journal of Computer Science and Technology*, 3(2), 26–32. <https://doi.org/10.59256/indjst.20240302026>
- Ramírez Téllez, A., Fonseca Ortiz, L. M., & Triana, F. C. (2024). Inteligencia artificial en la administración universitaria: una visión general de sus usos y aplicaciones. *Revista Interamericana de Bibliotecología*, 47(2). <https://doi.org/10.17533/udea.rib.v47n2e353620>
- Rane, N. (2023). Role and challenges of ChatGPT and similar generative artificial intelligence in finance and accounting (SSRN Working Paper No. 4603206). <https://doi.org/10.2139/ssrn.4603206>
- Ren, Y., Wenxin, J., & Lu, H. (2024). Analysis on the Application of Artificial Intelligence Technology in College Teaching (pp. 434–444). https://doi.org/10.1007/978-3-031-63136-8_45
- Rubio Sáenz, D. A., Haro Sarango, A. F., Vargas Carrera, D. M., Mise Pasuña, M. X., & Jacho Zambrano, C. S. (2023). Educación financiera en las finanzas personales: un estudio

- descriptivo en estudiantes de posgrado. *Prometeo Conocimiento Científico*, 3(2), e23.
<https://doi.org/10.55204/pcc.v3i2.e23>
- Sahu, S. K., Mokhade, A., & Bokde, N. D. (2023). An overview of machine learning, deep learning, and reinforcement learning-based techniques in quantitative finance: Recent progress and challenges. *Applied Sciences*, 13(3), 1956.
<https://doi.org/10.3390/app13031956>
- Sofiia, D., Oleksandr, K., Svitlana, N., Vitalina, P., & Volodymyr, T. (2025). Usage of Artificial Intelligence for the Individualization of Learning in the Institutions of Higher Education (pp. 199–207). https://doi.org/10.1007/978-3-031-85652-5_21
- Streiner, D. L. (2003). Starting at the beginning: An introduction to coefficient alpha and internal consistency. *Journal of Personality Assessment*, 80(1), 99–103.
https://doi.org/10.1207/S15327752JPA8001_18
- Sungkarungsri, P., & Kiattisin, S. (2026). How trustworthy AI fosters adoption and user advocacy in financial advisory services. *Discover Artificial Intelligence*, 6(1).
<https://doi.org/10.1007/s44163-026-01451-5>
- Torkian, V., Bamdad, S., & Sarfaraz, A. H. (2025). Integrating AI and OR for investment decision-making in emerging digital lending businesses: A risk-return multi-objective optimization approach. *Journal of the Operational Research Society*, 77(3).
<https://doi.org/10.1080/01605682.2025.2498652>
- Touvron, H., Martin, L., Stone, K., Albert, P., Almahairi, A., Babaei, Y., Bashlykov, N., Batra, S., Bhargava, P., Bhosale, S., et al. (2023). Llama 2: Open foundation and fine-tuned chat models. *arXiv*. <https://doi.org/10.48550/arXiv.2307.09288>
- Vaduka, S., Reddy, S. C., Arikathota, H. V., Konchada, L., Chakraborty, P., & Bandyopadhyay, A. (2024). Optimizing personal finance management through AI-driven

- decision support systems. In 2024 IEEE Region 10 Symposium (TENSYP). IEEE.
<https://doi.org/10.1109/tensymp61132.2024.10752249>
- Varghese, H., Venkateswaran, V., & Mandeep, S. (2024). AI-driven robo-advisors on personal financial management and investment strategies. *International Journal of Science and Research Archive*, 13(1), 2020–2026. <https://doi.org/10.30574/ijdra.2024.13.1.1846>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.
- Villarreal-Torres, H., Ángeles-Morales, J., Marín-Rodríguez, W., Andrade-Girón, D., Carreño-Cisneros, E., Cano-Mejía, J., Mejía-Murillo, C., Boscán-Carroz, M. C., Flores-Reyes, G., & Cruz-Cruz, O. (2023). Development of a Classification Model for Predicting Student Payment Behavior Using Artificial Intelligence and Data Science Techniques. *ICST Transactions on Scalable Information Systems*. <https://doi.org/10.4108/eetsis.3489>
- White, J., Fu, Q., Hays, S., Sandborn, M., Olea, C., Gilbert, H., Elnashar, A., Spencer-Smith, J., & Schmidt, D. C. (2023). A prompt pattern catalog to enhance prompt engineering with ChatGPT. In *Proceedings of the 30th Conference on Pattern Languages of Programs (PLoP '23)*. <https://doi.org/10.48550/arXiv.2302.11382>
- Yang, H., Shukur, Z., & Sahran, S. (2026). A review of artificial intelligence for financial fraud detection. *Applied Sciences*, 16(4). <https://doi.org/10.3390/app16041931>
- Yang, J. (2024). Study of an adaptive financial recommendation algorithm using big data analysis and user interest pattern with fuzzy K-means algorithm. *International Journal of Computational Intelligence Systems*, 17(1), 719. <https://doi.org/10.1007/s44196-024-00719-x>

Zhu, H., Vigren, O., & Söderberg, I.-L. (2024). Implementing artificial intelligence empowered financial advisory services: A literature review and critical research agenda. *Journal of Business Research*, 174, Article 114494. <https://doi.org/10.1016/j.jbusres.2023.114494>

V. ANEXOS

Anexo 1: Ficha de observación - Eficiencia

01 ficha de observación – Eficiencia																
Nombre	Prueba para medir la eficiencia															
Descripción	Esta prueba permitirá medir la eficiencia del modelo propuesto de Inteligencia Artificial para la Mejora de las Finanzas Personales en Estudiantes de Institutos Superiores															
Fecha de la prueba	15-01-2026															
Escenario	La aplicación de finanzas personales FinacIA, se ha desplegado en un servidor web.															
Prerrequisitos	Registro del usuario Registro de sus ingresos Registro de sus egresos															
Insumos	<table><tr><th>Característica</th><th>Valor</th></tr><tr><td>Servidor</td><td>Linux (Ubuntu 20.04 o superior)</td></tr><tr><td>Procesador</td><td>4 vCPU (Intel Xeon / AMD EPYC o equivalente)</td></tr><tr><td>Memoria RAM</td><td>≥ 16 GB</td></tr><tr><td>Almacenamiento</td><td>≥ 100 GB SSD</td></tr></table>				Característica	Valor	Servidor	Linux (Ubuntu 20.04 o superior)	Procesador	4 vCPU (Intel Xeon / AMD EPYC o equivalente)	Memoria RAM	≥ 16 GB	Almacenamiento	≥ 100 GB SSD		
	Característica	Valor														
	Servidor	Linux (Ubuntu 20.04 o superior)														
	Procesador	4 vCPU (Intel Xeon / AMD EPYC o equivalente)														
	Memoria RAM	≥ 16 GB														
	Almacenamiento	≥ 100 GB SSD														
Indicadores de aceptación	<table><tr><td>Consumo de memoria</td><td colspan="3">Los valores deben estar entre 0.0 y 1.0 La arquitectura con el menor valor es la más eficiente.</td></tr><tr><td>Consumo de CPU</td><td colspan="3">La arquitectura con el menor valor es la más eficiente.</td></tr><tr><td>Tiempo</td><td colspan="3">La arquitectura con el menor valor es la más eficiente.</td></tr></table>				Consumo de memoria	Los valores deben estar entre 0.0 y 1.0 La arquitectura con el menor valor es la más eficiente.			Consumo de CPU	La arquitectura con el menor valor es la más eficiente.			Tiempo	La arquitectura con el menor valor es la más eficiente.		
	Consumo de memoria	Los valores deben estar entre 0.0 y 1.0 La arquitectura con el menor valor es la más eficiente.														
	Consumo de CPU	La arquitectura con el menor valor es la más eficiente.														
Tiempo	La arquitectura con el menor valor es la más eficiente.															
Resultados	<table><tr><th>Modelo</th><th>Latencia (ms)</th><th>RAM (MB)</th><th>CPU (%)</th></tr><tr><td>Modelo propuesto</td><td>25.25 ± 5.01</td><td>7805</td><td>0.5</td></tr></table>				Modelo	Latencia (ms)	RAM (MB)	CPU (%)	Modelo propuesto	25.25 ± 5.01	7805	0.5				
	Modelo	Latencia (ms)	RAM (MB)	CPU (%)												
Modelo propuesto	25.25 ± 5.01	7805	0.5													
	El modelo propuesto presenta una inferencia rápida y estable, con una latencia promedio de 25.25 ± 5.01 ms, lo que lo hace apto para aplicaciones en tiempo casi real y escenarios															

	interactivos. Asimismo, el consumo de memoria es de 2 639,12 MB ($\approx$2,6 GB de RAM), un nivel compatible con estaciones de trabajo convencionales y servidores de inferencia ligeros, reflejando un equilibrio entre complejidad del modelo y eficiencia de recursos. Finalmente, el uso de CPU, medido como tiempo acumulado de procesador (4 842,41 s en el proceso principal de Ollama, según la Tabla 21), es consistente con el rol de un motor de inferencia LLM y no evidencia sobrecarga del sistema, lo que permite la ejecución simultánea de otras tareas.
--	--

Anexo 2: Cuestionario IMFP – Finanzas Personales en Estudiantes (CFPE-IMFP)

Cuestionario IMFP	
Nombre	Instrumento para medir el desempeño del modelo
Objetivo	Medir el nivel y la mejora de las finanzas personales mediante tres dimensiones: K: Conocimiento financiero C: Conducta financiera R: Resultado financiero
Aplicación	2 momentos (mismo instrumento) Pretest (antes de la intervención IA) Posttest (después de la intervención IA) Tiempo estimado: 12–18 minutos Población: Estudiantes de institutos superiores (n = 77) Carácter: Anónimo / confidencial (recomendado)
Datos generales	Edad: ____ Ciclo/semestre: ____ ¿Trabajas actualmente? (Sí/No) Ingreso mensual aproximado (rango): (1) 0–200 (2) 201–500 (3) 501–1000 (4) >1000 (moneda local)
Conocimiento financiero (K)	Registro del usuario Registro de sus ingresos Registro de sus egresos
	Instrucciones: Marca una sola alternativa correcta. Puntaje K: 1 punto por respuesta correcta (0–15). Escala a 0–100: $K = \frac{\text{aciertos}}{15} \times 100$
	Ítems (elige A, B, C o D) K1. ¿Cuál es el propósito principal de un presupuesto? A) Gastar todo el ingreso sin control B) Planificar ingresos y gastos para cumplir metas C) Pedir préstamos con facilidad D) Evitar usar cuentas bancarias K2. Si tu ingreso mensual es 1000 y gastas 1100, tu situación es: A) Superávit B) Déficit C) Equilibrio D) Ahorro

	K3. ¿Qué significa “fondo de emergencia”? A) Dinero para compras impulsivas B) Ahorro para imprevistos (salud, desempleo, urgencias) C) Dinero para invertir sin riesgo D) Dinero solo para vacaciones K4. ¿Cuál es una meta financiera “SMART”? A) “Quiero ahorrar algún día” B) “Ahorrar 200 en 2 meses separando 25 por semana” C) “Ser millonario pronto” D) “Gastar menos cuando pueda” K5. Si solo pagas el “pago mínimo” de una tarjeta, normalmente: A) La deuda se reduce rápido B) Pagas más intereses y tardas más en salir de la deuda C) No pagas intereses D) Cancelas la deuda en el mismo mes K6. ¿Qué gasto suele ser más peligroso por acumulación? A) Un gasto planificado mensual B) Gastos “hormiga” diarios pequeños C) Pago de una deuda programada D) Ahorro automático K7. Una forma de reducir el costo total de una deuda es: A) Atrasarse en pagos B) Pagar solo mínimos C) Pagar antes o pagar más del mínimo D) Pedir otra deuda sin plan K8. ¿Cuál es una práctica recomendada de ahorro? A) Ahorrar si sobra B) “Págate a ti primero” (separar ahorro al recibir ingresos) C) Ahorrar solo cuando hay promociones D) Ahorrar solo en efectivo y sin registro K9. ¿Qué indica “tasa de ahorro”? A) Ahorro / ingreso B) Gasto / ahorro C) Deuda / gasto D) Ingreso / deuda K10. Si tu ingreso sube, una decisión saludable es: A) Aumentar gastos fijos al máximo B) Mantener estilo de vida y aumentar ahorro/pago de deudas C) Duplicar compras impulsivas D) Eliminar el presupuesto K11. ¿Cuál es un signo de “sobreendeudamiento”? A) Pagar deudas a tiempo con facilidad B) No tener deudas C) Que las cuotas no te permiten cubrir gastos básicos D) Tener metas de ahorro K12. ¿Qué es el “costo total” de una compra con crédito? A) Solo el precio del producto B) Precio + intereses + comisiones (si aplican)
--	---

	C) Solo intereses D) Solo comisiones K13. ¿Qué significa priorizar gastos? A) Gastar primero en deseos B) Ordenar gastos por importancia: básicos, deudas, ahorro, luego ocio C) No pagar deudas D) No registrar gastos K14. ¿Cuál es una buena señal financiera? A) Tener atrasos frecuentes B) Gastar más de lo que se gana C) Contar con al menos 1 mes de fondo de emergencia D) No saber cuánto se gasta K15. Un indicador simple para controlar finanzas es: A) No revisar saldos B) Registrar gastos e identificar categorías C) Comprar sin lista D) Evitar metas
Conducta financiera (C)	Instrucciones: Marca tu frecuencia real en el último mes. 1 = Nunca 2 = Rara vez 3 = A veces 4 = Casi siempre 5 = Siempre Puntaje C (0–100): Promedio de ítems (1–5) y escalar: $C = \frac{(\bar{x} - 1)}{4} \times 100$ <i>(donde $\bar{x}$ es el promedio de los 16 ítems)</i> Escala: 0 = Nunca, 1 = Pocas veces, 2 = Casi siempre, 3 = Siempre.
	Ítems (C1–C16) C1. Registro mis gastos (anoto o uso app). C2. Reviso mi gasto semanalmente. C3. Separo dinero para ahorro al recibir ingresos. C4. Tengo metas de ahorro definidas. C5. Planifico compras con lista o prioridad. C6. Comparo precios antes de comprar. C7. Evito compras impulsivas. C8. Identifico y reduzco gastos “hormiga”. C9. Pago mis deudas puntualmente. C10. Pago más del mínimo cuando puedo. C11. Evito usar crédito para gastos no esenciales. C12. Mantengo un presupuesto mensual (formal o informal). C13. Ajusto mis gastos cuando noto déficit. C14. Reviso mis estados de cuenta o movimientos. C15. Mantengo un monto reservado para imprevistos. C16. Converso/consulto sobre decisiones financieras antes de endeudarme.
	Instrucciones: Responde según tu situación actual. (Se recomienda rangos para privacidad)

Resultado financiero (R)	Aquí no buscamos “el monto exacto”, sino señales objetivas de mejora. Ítems y puntuación (suma máxima = 16 puntos) Luego se escala a 0–100: $R = \frac{\text{puntos obtenidos}}{16} \times 100$									
	R1. Ahorro mensual (porcentaje del ingreso): 0% = 0 pts 1–5% = 1 pt 6–10% = 2 pts >10% = 3 pts R2. Balance mensual (ingreso – gasto): Déficit = 0 Equilibrio = 1 Superávit = 2 R3. Fondo de emergencia (meses que puedes cubrir): 0 = 0 <1 mes = 1 1–2 meses = 2 ≥3 meses = 3 R4. Atrasos en pagos (último mes): Sí = 0 No = 2 R5. Nivel de deuda respecto al ingreso mensual (aprox.): 50% = 0 26–50% = 1 1–25% = 2 0% = 3 R6. Uso de crédito para gastos no esenciales (último mes): Frecuente = 0 Ocasional = 1 Nunca = 2 R7. Estrés financiero percibido (0–10): 8–10 = 0 5–7 = 1 2–4 = 2 0–1 = 3 R8. Capacidad de cubrir un gasto imprevisto (p. ej., 200) sin endeudarte: No podría = 0 Podría parcialmente = 1 Sí podría = 2									
Resultados	Estudia nte	K_pr e	C_pr e	R_pr e	IMFP_p re	K_po st	C_po st	R_po st	IMFP_p ost	ΔIM FP
	1	40	64.6	35	48.3	60	87.5	60	71	22.7
	2	60	50	45	51.5	80	58.3	70	68.3	16.8
	3	53.3	56.3	55	55	73.3	68.8	75	72	17
	4	53.3	50	30	45	66.7	58.3	45	56.8	11.8
	5	33.3	62.5	45	48.5	53.3	93.8	55	70	21.5
	6	46.7	50	45	47.5	80	64.6	70	70.8	23.3
	7	26.7	50	25	35.5	46.7	68.8	35	52	16.5
	8	40	37.5	45	40.5	53.3	54.2	70	58.7	18.2

	9	40	33.3	50	40.3	60	52.1	75	61.3	21
	10	40	52.1	25	40.3	46.7	72.9	50	58.2	17.9
	11	60	60.4	25	49.7	80	70.8	55	68.8	19.1
	12	53.3	60.4	25	47.7	80	77.1	40	66.8	19.1
	13	40	35.4	50	41.2	60	58.3	60	59.3	18.1
	14	40	45.8	55	46.8	53.3	62.5	80	65	18.2
	15	33.3	52.1	50	45.8	46.7	64.6	75	62.4	16.6
	16	46.7	64.6	45	53.4	60	91.7	60	72.7	19.3
	17	46.7	64.6	35	50.4	60	81.3	55	67	16.6
	18	26.7	39.6	25	31.4	60	60.4	50	57.2	25.8
	19	60	62.5	50	58	86.7	89.6	65	81.4	23.4
	20	40	41.7	40	40.7	60	60.4	65	61.7	21
	21	60	29.2	25	37.2	80	54.2	55	62.2	25
	22	60	35.4	50	47.2	93.3	62.5	60	71	23.8
	23	66.7	35.4	35	44.7	86.7	64.6	45	65.4	20.7
	24	46.7	41.7	50	45.7	73.3	58.3	65	64.8	19.1
	25	60	47.9	30	46.2	73.3	77.1	50	67.8	21.6
	26	53.3	50	20	42	66.7	66.7	35	57.2	15.2
	27	60	52.1	50	53.8	73.3	72.9	70	72.2	18.4
	28	60	31.3	55	47	66.7	50	70	61	14
	29	40	37.5	30	36	66.7	47.9	45	52.7	16.7
	30	40	45.8	45	43.8	66.7	66.7	70	67.7	23.9
	31	60	58.3	40	53.3	86.7	87.5	55	77.5	24.2
	32	60	64.6	35	54.3	73.3	83.3	60	73.3	19
	33	40	41.7	30	37.7	60	70.8	55	62.8	25.1
	34	60	64.6	20	49.8	73.3	87.5	50	72	22.2
	35	40	35.4	30	35.2	60	56.3	45	54	18.8
	36	40	31.3	50	39.5	53.3	50	65	55.5	16
	37	33.3	43.8	35	38	53.3	66.7	45	56.2	18.2
	38	46.7	31.3	30	35.5	60	41.7	55	51.2	15.7
	39	46.7	50	45	47.5	60	64.6	55	60.3	12.8
	40	60	64.6	40	55.8	86.7	87.5	55	77.5	21.7
	41	60	37.5	25	40.5	86.7	52.1	50	61.9	21.4
	42	46.7	47.9	35	43.7	73.3	64.6	60	65.8	22.1
	43	60	60.4	40	54.2	66.7	83.3	55	69.8	15.6
	44	46.7	43.8	45	45	60	66.7	55	61.2	16.2
	45	46.7	64.6	30	48.9	60	81.3	40	62.5	13.6
	46	60	31.3	45	44	93.3	54.2	70	70.7	26.7
	47	40	45.8	40	42.3	66.7	72.9	60	67.2	24.9
	48	60	50	45	51.5	86.7	75	65	75.5	24
	49	40	58.3	35	45.8	66.7	81.3	45	66	20.2
	50	46.7	31.3	25	34	66.7	43.8	35	48	14
	51	53.3	58.3	40	51.3	80	83.3	50	72.3	21
	52	53.3	33.3	25	36.8	66.7	60.4	55	60.7	23.9
	53	66.7	47.9	35	49.7	93.3	75	50	73	23.3
	54	40	35.4	30	35.2	66.7	50	50	55	19.8

55	53.3	54.2	30	46.7	73.3	77.1	50	67.8	21.1
56	26.7	60.4	50	47.2	46.7	83.3	75	69.8	22.6
57	33.3	60.4	25	41.7	53.3	87.5	55	67.5	25.8
58	60	37.5	55	49.5	66.7	58.3	75	65.8	16.3
59	53.3	52.1	40	48.8	66.7	79.2	55	68.2	19.4
60	60	62.5	45	56.5	66.7	79.2	65	71.2	14.7
61	60	58.3	50	56.3	80	75	70	75	18.7
62	60	60.4	40	54.2	80	89.6	50	74.8	20.6
63	46.7	58.3	30	46.3	60	89.6	55	70.3	24
64	40	64.6	25	45.3	53.3	87.5	35	61.5	16.2
65	53.3	56.3	45	52	66.7	72.9	70	70.2	18.2
66	40	37.5	35	37.5	46.7	64.6	60	57.9	20.4
67	33.3	43.8	25	35	46.7	68.8	50	56.5	21.5
68	66.7	60.4	45	57.7	73.3	75	60	70	12.3
69	33.3	31.3	40	34.5	46.7	52.1	60	52.9	18.4
70	53.3	62.5	35	51.5	66.7	85.4	60	72.2	20.7
71	60	41.7	50	49.7	73.3	60.4	70	67.2	17.5
72	46.7	29.2	35	36.2	73.3	54.2	60	61.7	25.5
73	53.3	64.6	30	50.8	80	75	45	67.5	16.7
74	46.7	60.4	25	45.7	60	87.5	45	66.5	20.8
75	40	62.5	20	43	66.7	91.7	35	67.2	24.2
76	40	50	30	41	60	75	50	63	22
77	40	58.3	25	42.8	60	77.1	50	63.8	21
Resumen estadístico									
Promedio IMFP Pretest: 45.46									
Promedio IMFP Posttest: 65.22									
Promedio de mejora (Δ IMFP): 19.76									
Máxima mejora: 26.7									
Mínima mejora: 11.8									