



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

**Centro Nacional de Investigación
y Desarrollo Tecnológico**

Tesis de Maestría

**Modelo de autoeficacia para ambientes
inteligentes de aprendizaje aplicado en la
enseñanza de lógica matemática**

presentada por

Ing. Víctor Manuel Domínguez Lara

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Directora de tesis

Dra. María Yasmín Hernández Pérez

Codirector de tesis

Dr. Javier Ortiz Hernández

Cuernavaca, Morelos, México. Agosto de 2026



Centro Nacional de Investigación y Desarrollo Tecnológico
Departamento de Ciencias Computacionales

Cuernavaca, Mor., 24/JUNIO/2026

OFICIO No. DCC/134/2026

Asunto: Aceptación de documento de tesis
CENIDET-AC-004-M14-OFICIO

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de **Víctor Manuel Domínguez Lara** con número de control. **M24CE051**, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Modelo de autoeficacia para ambientes inteligentes de aprendizaje aplicado en la enseñanza de lógica matemática"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

ATENTAMENTE

Excelencia en Educación Tecnológica®
"Conocimiento y Tecnología al Servicio de México"



Dra. María Yasmín Hernández Pérez
Directora de tesis



Dr. Javier Ortiz Hernández
Codirector de tesis



Dr. Eddie Helbert Clemente Torres
Revisor 1



Dr. Hugo Estrada Esquivel
Revisor 2

C.c.p. Depto. Servicios Escolares.
Expediente / Estudiante



2026
año de
Margarita Maza



Centro Nacional de Investigación y Desarrollo Tecnológico
Subdirección Académica

Cuernavaca Mor, **25/junio/2026**

Oficio No. SAC/183/2026

Asunto: Autorización de impresión de tesis

VÍCTOR MANUEL DOMÍNGUEZ LARA
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
DE LA COMPUTACIÓN
P R E S E N T E

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"Modelo de autoeficacia para ambientes inteligentes de aprendizaje aplicado en la enseñanza de lógica matemática"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica®

"Conocimiento y Tecnología al servicio de México"

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO



c.c.p. Departamento de Ciencias Computacionales
Departamento de Servicios Escolares

CMAZ/lmz



2026
año de
Margarita
Maza

cenidet
Centro Nacional de Investigación
y Desarrollo Tecnológico



Interior Internado Palmira S/N, Col. Palmira,
C.P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4106,
e-mail: acad_cenidet@tecnm.mx | cenidet.tecnm.mx

Dedicatoria

A mi familia, colegas y amistades. Sepan que este trabajo siempre fue pensado como una semilla con la esperanza de verla crecer hacia la ciencia y la educación.

Agradecimientos

Expreso mi sincero agradecimiento a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (Secihti) por el apoyo brindado en el desarrollo de este proyecto de investigación, el cual ha sido fundamental para la realización de mi tesis de maestría.

De igual manera, agradezco al Centro Nacional de Investigación y Desarrollo Tecnológico (Cenidet) por el respaldo académico e institucional que me permitió llevar a cabo este trabajo y fortalecer mi formación durante el posgrado.

A mi directora de tesis, le expreso mi profundo reconocimiento por la confianza que me brindó y la paciencia con la que me orientó firmemente a lo largo de este proceso, respetando siempre mis propias ideas, lo cual me permitió crecer como investigador sin perder el rumbo del proyecto.

A mi codirector, valoro el optimismo que siempre transmitió y la oportunidad que me dio de integrarme al Cenidet, lo cual enriqueció mi experiencia académica y profesional.

A mis revisores, destaco su valiosa retroalimentación y apoyo, que fueron esenciales para el progreso de este proyecto.

Reconozco también la colaboración de las y los docentes Mario Avelar, Miguel Martínez, Marco Antonio Melchor, Mariana Gamboa, Lilia Bahena, Norma Domínguez, Lizbeth Juárez y Graciela Reyes, de quienes recibí generosidad y disposición, además de una contribución significativa para el desarrollo y conclusión de este proyecto.

Asimismo, extendo mi gratitud a quienes me acompañaron con apoyo constante y ánimo en todo momento: Nohema Pérez, Magali García, Eduardo Sánchez, Pedro Arcos, Julio Víctor, Ana Luisa, Jorge, Liz, junto con una extensa lista que podría continuar, reflejo de la fortuna que tengo al haber estado rodeado por personas tan valiosas.

Finalmente, Agradezco profundamente a mi familia: a mis padres Elida Lara Olmedo y Víctor E Domínguez Flores, por impulsarme siempre a cumplir con mis metas, y a mis hermanas Nelida y Victoria, por creer en mí y ser pilares fundamentales a lo largo de mi vida.

Resumen

Los Ambientes Inteligentes de Aprendizaje han avanzado en la adaptación basada en el conocimiento y desempeño de los estudiantes, así como en otros constructos psicológicos como la personalidad, las emociones y la motivación. La autoeficacia es la confianza en la propia capacidad para organizar y ejecutar acciones necesarias que permitan alcanzar metas específicas. Sin embargo, la incorporación de la autoeficacia como variable activa del modelo del estudiante permanece poco explorada.

La lógica matemática es una asignatura útil para el desarrollo de capacidades de razonamiento riguroso, análisis crítico y resolución estructurada de problemas. La enseñanza de lógica matemática en el nivel medio superior enfrenta el reto de adaptar la instrucción a estudiantes con distintos niveles de confianza en sus propias capacidades.

Se propone un Modelo de Autoeficacia integrado en un Ambiente Inteligente de Aprendizaje. El modelo se compone del Modelo de Autoeficacia del Estudiante, que clasifica a los aprendices en cuatro perfiles combinando el puntaje en la Escala de Autoeficacia General con el rendimiento académico, y del Modelo de Adaptación de Respuesta, que traduce cada perfil en intervenciones pedagógicas diferenciadas. El modelo de autoeficacia se integró en MateLog, un Ambiente Inteligente de Aprendizaje para la enseñanza de lógica matemática.

Se llevó a cabo un estudio experimental con 180 estudiantes de nivel medio superior. Los resultados mostraron una diferencia significativa en la ganancia de aprendizaje a favor del grupo experimental. La autoeficacia percibida presentó un cambio intragrupo significativo en el grupo experimental.

Los resultados respaldan la viabilidad del modelo como mecanismo de adaptación en un Ambiente Inteligente de Aprendizaje para el nivel medio superior, con efecto claro sobre el aprendizaje y en la autoeficacia percibida.

Abstract

Intelligent Learning Environments have advanced in adaptation based on students' knowledge and performance, as well as other psychological constructs such as personality, emotions, and motivation. Self-efficacy refers to confidence in one's own capacity to organize and execute the actions necessary to achieve specific goals. However, the incorporation of self-efficacy as an active variable in the student model remains largely unexplored.

Mathematical logic is a subject that contributes to the development of rigorous reasoning, critical analysis, and structured problem-solving skills. Teaching mathematical logic at the upper secondary level faces the challenge of adapting instruction to students with varying levels of confidence in their own abilities.

A Self-Efficacy Model integrated into an Intelligent Learning Environment is proposed. The model comprises the Student Self-Efficacy Model, which classifies learners into four profiles by combining scores from the General Self-Efficacy Scale with academic performance, and the Response Adaptation Model, which translates each profile into differentiated pedagogical interventions. The self-efficacy model was integrated into MateLog, an Intelligent Learning Environment for the teaching of mathematical logic.

An experimental study was conducted with 180 upper secondary students. Results showed a significant difference in learning gains in favor of the experimental group. Perceived self-efficacy showed a significant within-group change in the experimental group.

The results support the viability of the model as an adaptation mechanism in an Intelligent Learning Environment at the upper secondary level, with a clear effect on both learning outcomes and perceived self-efficacy.

Tabla de contenido

Dedicatoria	i
Agradecimientos.....	ii
Resumen	iii
Abstract.....	iv
Lista de tablas.....	x
Lista de figuras.....	xii
Capítulo 1. Introducción.....	1
1.1 Planteamiento del problema.....	2
1.2 Justificación.....	3
1.3 Propuesta de solución	4
1.4 Hipótesis de investigación.....	5
1.5 Objetivos.....	5
1.5.1 Objetivo general	5
1.5.2 Objetivos específicos.....	5
1.6 Alcances y limitaciones.....	6
1.6.1 Alcances	6
1.6.2 Limitaciones	6
1.7 Metodología	7
1.8 Estructura del documento.....	8
Capítulo 2. Marco teórico.....	9
2.1 Ambientes Inteligentes de Aprendizaje	9
2.1.1 Relación entre <i>e-learning</i> , AIA y STI	9
2.1.2 Características y componentes de los AIA.....	11
2.1.3 Ejemplos de AIA.....	12
2.2 Teoría de autoeficacia	13

2.2.1 Definición de autoeficacia	14
2.2.2 Fuentes de autoeficacia	16
2.2.3 Evaluación de la autoeficacia	18
Capítulo 3. Revisión de la literatura.....	21
3.1 Inteligencia Artificial en la educación.....	21
3.2 Ambientes Inteligentes de Aprendizaje	22
3.3 Autoeficacia	23
3.3.1 Autoeficacia en Ambientes Inteligentes de Aprendizaje.....	24
3.3.2 Autoeficacia en el aprendizaje de las matemáticas.....	25
3.4 Fuentes de autoeficacia en Ambientes Inteligentes de Aprendizaje.....	26
3.4.1 Modelado de autoeficacia	27
3.4.2 Modelado de experiencias de éxito.....	30
3.4.3 Modelado de persuasión verbal.....	32
3.4.4 Modelado de experiencias vicarias.....	33
3.5 Conclusiones de la revisión de la literatura	34
Capítulo 4. Modelo de Autoeficacia	37
4.1 Modelo de Autoeficacia del Estudiante	38
4.1.1 Selección del instrumento de medición.....	39
4.1.2 Nivel de autoeficacia	40
4.1.3 Rendimiento Académico.....	41
4.1.4 Perfiles del estudiante.....	41
4.2 Modelo de Adaptación de Respuesta	44
4.2.1 Fuentes de autoeficacia implementadas	44
4.2.2 Configuración de la dificultad	46
4.2.3 Respuesta al desempeño	47

4.2.4 Intervención por perfil	50
4.3 Especificación de parámetros operativos.....	53
Capítulo 5. MateLog	57
5.1 Arquitectura del Ambiente Inteligente de Aprendizaje.....	57
5.2 Actualización de MateLog.....	58
5.2.1 Actualización de la infraestructura	59
5.2.2 Incorporación de funcionalidades.....	60
5.2.3 Incorporación de contenido.....	63
5.2.4 Verificación operativa.....	64
5.3 Integración del Modelo de Autoeficacia	65
5.3.1 Integración del instrumento de evaluación	66
5.3.2 Funcionamiento diferenciado por perfil	68
Capítulo 6. Evaluación del Modelo de Autoeficacia	72
6.1 Protocolo del estudio	72
6.1.2 Aplicación del estudio experimental	74
6.1.3 Análisis estadístico.....	75
6.1.3.1 Verificación de supuestos.....	75
6.1.3.2 Comparación intragrupo e intergrupo.....	75
6.2. Resultados.....	76
6.2.1 Descripción de la muestra	76
6.2.2 Verificación de supuestos.....	77
6.2.2.1 Normalidad.....	78
6.2.2.2 Homogeneidad de varianzas.....	79
6.2.3 Comparación intragrupo e intergrupo	80
6.2.3.1 Equivalencia inicial entre grupos	80
6.2.3.2 Comparación intragrupo.....	81

6.2.3.3 Comparación intergrupo.....	84
6.3 Discusión	86
6.3.1 Observaciones sobre la ejecución del experimento.....	88
Capítulo 7. Conclusiones y trabajo futuro.....	90
7.1 Cumplimiento de objetivos	90
7.2 Conclusiones.....	91
7.3 Contribuciones de la investigación	93
7.4 Trabajo futuro	94
Referencias.....	96
Anexo A. Interfaz de MateLog	109
A.1 Registro e inicio de sesión	109
A.2 Escala de Autoeficacia General — pre-test.....	110
A.3 Examen diagnóstico	111
A.4 Inicio del curso y vista de lecciones y temas.....	112
A.5 Teoría y ejemplos	113
A.6 Sección de ejercicios	114
A.7 Botón de ayuda contextual	115
A.8 Retroalimentación inmediata por perfil.....	116
A.9 Ejemplos adicionales.....	117
A.10 Opción de rescate	118
A.11 Opción de reto.....	119
A.12 Opción para terminar curso	120
A.13 Escala de Autoeficacia General — post-test.....	121
A.14 Examen final.....	122
A.15 Valoración de la plataforma.....	123
Anexo B. Publicaciones.....	124

Anexo C. Retribuciones.....	127
-----------------------------	-----

Lista de tablas

Tabla 2.1 Comparación entre <i>e-learning</i> , AIA y STI.....	10
Tabla 2.2 Ejemplos de AIA según su dominio y mecanismo de adaptación.....	13
Tabla 2.3 Comparación entre la autoeficacia y constructos afines.....	15
Tabla 2.4 Fuentes principales de autoeficacia (Bandura, 1977).....	17
Tabla 2.5 Estrategias para fortalecer las fuentes de autoeficacia en el contexto académico.....	18
Tabla 3.1 Modelado de autoeficacia.....	28
Tabla 3.2 Modelado de experiencias de éxito.....	31
Tabla 3.3 Modelado de persuasión verbal.....	33
Tabla 3.4 Modelado de experiencias vicarias.....	34
Tabla 4.1 Análisis comparativo de instrumentos de medición de autoeficacia.....	39
Tabla 4.2 Escala General de Autoeficacia, en idioma español (Sanjuán Suárez et al., 2000).....	40
Tabla 4.3 Definición del nivel de autoeficacia.....	41
Tabla 4.4 Nivel de rendimiento académico.....	41
Tabla 4.5. Perfiles del Modelo de Autoeficacia del Estudiante.....	42
Tabla 4.6. Reglas de clasificación y actualización del perfil por tema.....	42
Tabla 4.7 Análisis de las fuentes de autoeficacia para su integración en el modelo de autoeficacia.....	45
Tabla 4.8 Perfiles y condiciones de dificultad de los ejercicios.....	47
Tabla 4.9 Módulos del Ambiente Inteligente de Aprendizaje y su relación con el Modelo de Autoeficacia.....	48
Tabla 4.10 Retroalimentación guiada (andamiaje pedagógico) por perfil.....	49
Tabla 4.11 Clasificación de perfiles y tipo de intervención.....	50

Tabla 4.12 Mensajes de apoyo generales por perfil ante respuesta incorrecta.....	51
Tabla 4.13 Mensajes de apoyo por condición específica.....	52
Tabla 4.14 Datos preliminares utilizados para la configuración de las condiciones experimentales.....	54
Tabla 5.1 Módulos del Ambiente Inteligente de Aprendizaje y su relación con el Modelo de Autoeficacia.....	57
Tabla 5.2 Comparación de la infraestructura entre MateLog previo (Mendoza, 2023) y MateLog actual.....	60
Tabla 5.3 Comparación de funcionalidades entre MateLog previo (Mendoza, 2023) y MateLog actual.....	62
Tabla 5.4 Aspectos operativos verificados.....	65
Tabla 5.5 Correspondencia entre fuentes de autoeficacia, intervenciones del Modelo de Adaptación de Respuesta y funcionalidades de MateLog.....	65
Tabla 5.6 Secuencia de etapas del flujo de acceso al curso.....	68
Tabla 5.7 Diferencias entre la condición control y la condición experimental.....	69
Tabla 5.8 Integración del Modelo de Autoeficacia en MateLog: datos registrados y acciones ejecutadas.....	70
Tabla 6.1 Instrumentos de medición aplicados durante el protocolo.....	73
Tabla 6.2 Análisis estadísticos principales.....	75
Tabla 6.3 Distribución de participantes por plantel y grupo.....	76
Tabla 6.4 Prueba de Shapiro-Wilk a las variables de interés.....	77
Tabla 6.5 Prueba de Levene a las variables de interés.....	78
Tabla 6.6 Comparación pre-test entre grupos.....	80
Tabla 6.7 Comparaciones intragrupo pre-post.....	81
Tabla 6.8 Distribución de cambios individuales pre-post.....	81
Tabla 6.9 Comparación intergrupo de ganancias pre-post.....	84

Lista de figuras

Figura 1.1 Metodología de solución.....	8
Figura 2.1 Arquitectura de un STI y las relaciones entre sus componentes. Adaptado de Burns y Capps (1988).....	12
Figura 4.1 Estructura del Modelo de Autoeficacia.....	38
Figura 4.2 Asignación de perfiles adaptativos del Modelo de Autoeficacia del Estudiante.....	44
Figura 4.3 Distribución de puntajes de escala general de autoeficacia y clasificación por nivel de autoeficacia.....	55
Figura 4.4 Distribución de intentos en el Tema 1.....	55
Figura 5.1 Arquitectura de MateLog con la integración del Modelo de Autoeficacia.....	58
Figura 6.1 Secuencia de actividades del protocolo para ambos grupos.....	72
Figura 6.2 Muestra y disponibilidad de datos por subconjunto.....	76
Figura 6.3 Comparación pre-test entre grupos control y experimental.....	80
Figura 6.4. Trayectoria pre-post de autoeficacia y rendimiento académico por grupo.....	81
Figura 6.5 Distribución de cambios individuales en autoeficacia.....	82
Figura 6.6 Distribución de cambios individuales en rendimiento académico.....	83
Figura 6.7 Ganancias pre-post por grupo.....	84
Figura A.1 Pantalla de bienvenida e ingreso del código de acceso.....	107
Figura A.2 Pantalla de instrucciones de la Escala de Autoeficacia General, e interfaz de respuesta de los 10 ítem de la escala con sus cuatro opciones.....	108
Figura A.3 Pantalla de instrucciones del examen diagnóstico, los 10 reactivos de opción múltiple que incluyen la opción “No lo sé” y pantalla de conclusión del examen diagnóstico.....	109

Figura A.4 Pantalla con descripción e instrucciones del curso, vista principal de la lección, los cinco temas y el estado de desbloqueo.....	110
Figura A.5 Segmento de teoría con texto y ejemplos integrados en el flujo de aprendizaje.....	111
Figura A.6 Pantallas con ejercicios con las alternativas de respuesta..	112
Figura A.7 Ejercicio en estado estándar, con el botón de ayuda disponible activado, y su variante que aparece después del tercer intento para los perfiles de AE_ALTA_B y AE_BAJA_B únicamente en los ejercicios que tuvieron respuesta incorrecta en el intento anterior.....	113
Figura A.8 Ejemplos de retroalimentación obtenida en respuestas incorrectas y correctas	114
Figura A.9 Opción de ver ejemplos adicionales relacionados con los ejercicios incorrectos del último intento.....	115
Figura A.10 Pantalla de oferta de rescate presentada al perfil AE_ALTA_B tras tres intentos no aprobados.....	116
Figura A.11 Pantalla de oferta de reto presentada al perfil AE_BAJA_A al aprobar un tema, interfaz de ejercicios de nivel difícil tras aceptar el reto y reconocimiento entregado al aprobar los ejercicios del reto.....	117
Figura A.12 Pantalla con el botón desbloqueado para terminar curso	118
Figura A.13 Pantalla de instrucciones de la Escala de Autoeficacia General en su aplicación post-test e interfaz de respuesta de los ítems del cuestionario post-test.....	119
Figura A.14 Pantalla de instrucciones del examen final y reactivos del examen final con su formato de opción múltiple.....	120
Figura A.15 Pantalla de valoración de la plataforma con la escala de estrellas y el campo de comentario abierto seguido de la pantalla de agradecimiento por haber participado.....	121
Figura B.1 Encabezado y Abstract del artículo publicado en el Workshop on Intelligent Learning Environments (WILE), MICAI 2025.....	122
Figura B.2 Encabezado y Abstract del artículo de congreso “HECTutor: Conversational Tutor based on Generative Artificial Intelligence for Teaching Mathematical Logic“	123

Figura B.3 Encabezado y Abstract del capítulo de libro en prensa en Studies in Big Data, Springer Nature.....	124
Figura C.1 Constancia de participación como presentador de póster en ICARIS 2025.....	125
Figura C.2 Constancia de participación como ponente en el Congreso Tecnologías del Futuro.....	126
Figura C.3 Constancia de participación en el concurso 3 Minutos de mi Tesis, Cenidet.....	127
Figura C.4 Constancias de participación como staff voluntario en CITCA 2024 y COMIA 2026.....	128

Capítulo 1. Introducción

Los Ambientes Inteligentes de Aprendizaje (AIA) son sistemas de software cuyo objetivo es proporcionar un medio en el que los estudiantes aprendan de manera más efectiva, adaptando el contenido de enseñanza a las necesidades individuales de cada uno (Mavrikis & Holmes, 2019; Archundia Sierra et al., 2021; Tang et al., 2023). Esta capacidad los convierte en una herramienta relevante para la lógica matemática, un área que requiere abstracción, razonamiento deductivo y construcción de argumentos formales (Capone, 2022; Suppes & Hill, 2000).

Para una enseñanza efectiva es necesario que exista interés y compromiso por parte del estudiante (Díaz Mujica et al., 2022), lo que puede representar un reto en un Ambiente Inteligente de Aprendizaje donde no se cuenta con supervisión directa. Este interés y compromiso están estrechamente relacionados con la autoeficacia, un concepto fundamental de la psicología educativa que se refiere a la creencia del individuo en su propia capacidad para realizar una tarea específica o lograr un objetivo determinado (Díaz Mujica et al., 2022; Shimizu, 2022). La autoeficacia puede emplearse para adaptar la enseñanza en los Ambientes Inteligentes de Aprendizaje considerando tanto las principales fuentes de influencia de Bandura (1977) como el nivel de autoeficacia de cada estudiante. Se propone un Modelo de Autoeficacia (MA) para Ambientes Inteligentes de Aprendizaje, con el fin de adaptar la instrucción en función del perfil de autoeficacia de cada estudiante.

El modelo se probó en MateLog, un Ambiente Inteligente de Aprendizaje orientado a la enseñanza de lógica matemática a nivel preparatoria. Su efectividad se evaluó mediante un estudio experimental con usuarios reales, comparando el desempeño académico y el nivel de autoeficacia de estudiantes que interactuaron con MateLog con el Modelo de Autoeficacia activo frente a quienes lo hicieron sin él.

1.1 Planteamiento del problema

La enseñanza tradicional a menudo carece de la capacidad de adaptarse a las necesidades individuales de cada estudiante (Bradáč et al., 2022). Los métodos de enseñanza convencionales pueden resultar poco motivadores, lo que afecta el rendimiento y el compromiso con el aprendizaje (Carbonell Bernal & Hernández Prados, 2024; Shimizu, 2022). Los estudiantes presentan diferentes niveles de conocimiento, habilidades y necesidades (Valencia Vallejo, 2021), por lo que los Ambientes Inteligentes de Aprendizaje deben ser capaces de adaptarse a estas diferencias para ofrecer una experiencia más efectiva y personalizada.

A pesar del avance, el impacto y el potencial de los Ambientes Inteligentes de Aprendizaje para transformar la educación, estos aún enfrentan desafíos importantes en la adaptabilidad (AlAli & Wardat, 2024), ya que son múltiples los factores que pueden influir en el aprendizaje. Entre las características del estudiante que pueden utilizarse para la adaptación se encuentran el estado afectivo, la motivación y la autoeficacia, entre otros.

La autoeficacia es un constructo fundamentado en la Teoría Social Cognitiva de Albert Bandura (1977), que se refiere al juicio que hace el individuo sobre su propia capacidad para afrontar y gestionar situaciones futuras. Los estudiantes con alta autoeficacia son más propensos a establecer metas ambiciosas y a persistir en su logro, incluso cuando enfrentan dificultades (Shimizu, 2022). Sin embargo, la autoeficacia varía según la tarea y el contexto, por lo que integrarla en un AIA requiere herramientas que permitan establecer un perfil inicial confiable del estudiante, a partir del cual el sistema pueda determinar las estrategias pedagógicas más adecuadas (Díaz Mujica et al., 2022).

1.2 Justificación

La autoeficacia ha demostrado ser un factor determinante en el rendimiento académico y la motivación, ya que quienes presentan un nivel alto de autoeficacia muestran mayor persistencia ante las dificultades, mayor compromiso con el aprendizaje y mejores resultados académicos (Bandura, 1997; Schunk, 1989; Zimmerman, 2000; Shimizu, 2022; AlAli & Wardat, 2024).

En el contexto del aprendizaje mediado por tecnología, la autoeficacia cobra especial relevancia: estudios recientes señalan que influye significativamente en la aceptación y el aprovechamiento de los Ambientes Inteligentes de Aprendizaje (Chahal, 2022; Masimba & Maguraushe, 2022; Zhang & Li, 2021).

Sin embargo, la revisión de la literatura revela que su incorporación como variable activa en el proceso de adaptación de los Ambientes Inteligentes de Aprendizaje —es decir, como parte del modelo del estudiante que orienta las decisiones pedagógicas del sistema— no ha sido consolidada en la práctica. Los estudios encontrados se han enfocado en dos aspectos: por un lado, en inferir computacionalmente la autoeficacia a partir de datos de comportamiento y fisiológicos (McQuiggan, Mott, & Lester, 2008; Bounhar, Yamak, Havard, & Baudry, 2022); por otro lado, en apoyarla mediante mecanismos de autorreporte en contextos acotados (Sergent, Daniel, Bouchet, & Carron, 2024), sin que en ningún caso se haya consolidado su uso operativo como entrada activa para las decisiones pedagógicas adaptativas del sistema (Fernández-Herrero, 2024).

Atender este vacío resulta particularmente relevante considerando que los Ambientes Inteligentes de Aprendizaje tienen la capacidad de ofrecer una enseñanza personalizada sin requerir la presencia continua de un instructor, lo cual amplía su aplicación a contextos donde la supervisión directa no es posible y donde las necesidades motivacionales del estudiante quedan desatendidas.

1.3 Propuesta de solución

Para resolver el problema, se propone un Modelo de Autoeficacia (MA) dentro de un Ambiente Inteligente de Aprendizaje orientado a la enseñanza de lógica matemática. El modelo se compone de dos componentes: el Modelo de Autoeficacia del Estudiante (MAE) y el Modelo de Adaptación de Respuesta (MAR).

El MAE tiene como propósito representar el perfil de autoeficacia del aprendiz. Para ello, integra dos variables: el nivel de autoeficacia, obtenido mediante la Escala de Autoeficacia General, y el desempeño académico, proveniente del modelo del estudiante. La combinación de ambas variables permite construir un perfil que caracteriza la relación entre la confianza del estudiante y su rendimiento, y que sirve como entrada para el proceso de adaptación.

El MAR determina las acciones pedagógicas que el sistema debe ejecutar en función del perfil establecido por el MAE. Estas acciones comprenden decidir el nivel de dificultad de los ejercicios, los apoyos pedagógicos y las intervenciones de retroalimentación acordes al perfil del estudiante.

El Modelo de Autoeficacia se integra en MateLog, un Ambiente Inteligente de Aprendizaje para enseñar lógica matemática, cuyo contenido teórico con ejemplos y ejercicios del libro Introducción a la lógica matemática de Suppes y Hill (1968). Para verificar la efectividad del modelo, se llevó a cabo un estudio de evaluación con usuarios reales. Se comparan el desempeño académico y la autoeficacia de los estudiantes bajo dos condiciones: con y sin adaptación basada en autoeficacia.

1.4 Hipótesis de investigación

La efectividad del Modelo de Autoeficacia depende de que su integración en el sistema produzca un efecto medible sobre las variables que busca influir. Con base en los fundamentos teóricos de Bandura y en el diseño del modelo descrito, se formula la siguiente hipótesis de investigación: la integración de un Modelo de Autoeficacia en un Ambiente Inteligente de Aprendizaje produce una diferencia estadísticamente significativa en el desempeño académico y en el nivel de autoeficacia de los estudiantes, en comparación con el uso del sistema sin dicho modelo.

1.5 Objetivos

A partir del problema identificado en la Sección 1.2 y de la oportunidad que representa integrar la autoeficacia como variable activa del modelo del estudiante en un Ambiente Inteligente de Aprendizaje, este trabajo plantea el siguiente objetivo general y objetivos específicos.

1.5.1 Objetivo general

Construir un Modelo de Autoeficacia que identifique el nivel de autoeficacia del estudiante y adapte la enseñanza a las necesidades particulares de cada estudiante en un Ambiente Inteligente de Aprendizaje.

1.5.2 Objetivos específicos

1. Construir el Modelo de Autoeficacia del Estudiante para representar computacionalmente el perfil del estudiante a partir de su nivel de autoeficacia y su rendimiento académico.
2. Construir el Modelo de Adaptación de Respuesta para determinar las acciones pedagógicas apropiadas en función del perfil identificado por el Modelo de Autoeficacia del Estudiante.
3. Integrar y evaluar el Modelo de Autoeficacia en MateLog para adaptar la enseñanza a las necesidades específicas de cada estudiante y verificar su efecto sobre el aprendizaje y la autoeficacia percibida.

1.6 Alcances y limitaciones

La investigación presenta alcances y limitaciones que delimitan las fuentes de autoeficacia que integra el modelo, el instrumento de evaluación empleado y las restricciones relacionadas con la validación pedagógica y la duración de la intervención.

1.6.1 Alcances

El modelo integra únicamente las fuentes de autoeficacia consideradas más relevantes y compatibles con un sistema web de aprendizaje individual, sin abarcar la totalidad de las fuentes identificadas por Bandura. La autoeficacia se evalúa mediante una escala aplicada antes de iniciar el curso, sin mediciones intermedias durante el recorrido de aprendizaje.

1.6.2 Limitaciones

El diseño de las intervenciones pedagógicas no cuenta con validación directa por parte de especialistas en psicología educativa o pedagogía de la autoeficacia; las decisiones se fundamentan en la teoría de Bandura pero no son sometidas a juicio de expertos externos. El uso del Ambiente Inteligente de Aprendizaje con estudiantes se limita a una sola sesión, lo que restringe la observación de efectos acumulativos del modelo sobre la autoeficacia.

1.7 Metodología

La investigación se desarrolló como un proceso aplicado organizado en cinco fases interdependientes, cuya secuencia se ilustra en la Figura 1.1.

La primera fase corresponde al análisis de fundamentos, en la que se definieron las decisiones conceptuales que sustentan el modelo: la selección del instrumento de medición de la autoeficacia, la identificación de las fuentes de autoeficacia compatibles con un sistema web de aprendizaje individual, y la ubicación de los componentes del modelo dentro de la arquitectura del Ambiente Inteligente de Aprendizaje.

La segunda fase aborda la actualización de MateLog. A partir de una versión previa de la plataforma, se realizaron modificaciones de infraestructura —migración tecnológica hacia una arquitectura desacoplada con *backend* en Django REST *Framework* y *frontend* en React— y ampliaciones de funcionalidad orientadas a soportar el registro detallado de interacciones y las exigencias del diseño experimental.

La tercera fase, central en la metodología, corresponde a la especificación del Modelo de Autoeficacia. El modelo se articula en dos componentes: el Modelo de Autoeficacia del Estudiante, encargado de identificar el perfil de cada aprendiz a partir de su nivel de autoeficacia y su rendimiento académico, y el Modelo de Adaptación de Respuesta, responsable de convertir ese perfil en intervenciones pedagógicas concretas.

La cuarta fase comprende la integración del Modelo de Autoeficacia en MateLog, incluyendo la incorporación del instrumento de evaluación inicial, la configuración de los parámetros operativos del modelo y la adaptación funcional de la plataforma para operar de forma diferenciada según la condición asignada a cada estudiante.

La quinta fase corresponde a la evaluación del modelo mediante un estudio experimental con usuarios reales y al análisis estadístico de los resultados. El Capítulo 6 reporta con detalle el protocolo, los resultados y la discusión de este estudio.

Fase 1 Análisis de fundamentos	Fase 2 Actualización de MateLog	Fase 3 Construcción del Modelo de Autoeficacia	Fase 4 Integración del Modelo de Autoeficacia	Fase 5 Evaluación del Modelo de Autoeficacia
Selección del instrumento de medición de autoeficacia	Análisis de la versión previa de MateLog	Construcción del Modelo de Autoeficacia del Estudiante (MAE)	Integración del instrumento de evaluación	Diseño del protocolo experimental
Selección de fuentes de autoeficacia a implementar	Actualización de infraestructura		Configuración de MateLog con Modelo de Autoeficacia activo o inactivo	Desarrollo del experimento
Ubicación del Modelo de Autoeficacia en la arquitectura del Ambiente Inteligente de Aprendizaje	Incorporación de funcionalidades	Construcción del Modelo de Adaptación de Respuesta (MAR)	Adaptación de funcionalidades según perfil	Análisis estadístico de resultados
	Incorporación de contenido			
	Verificación operativa			

Figura 1.1 Metodología de solución

1.8 Estructura del documento

El presente documento se organiza en siete capítulos. El Capítulo 1 contextualiza el problema, justifica la investigación, describe la propuesta de solución, establece la hipótesis de investigación y declara los objetivos, alcances, limitaciones y metodología del trabajo. El Capítulo 2 expone el marco teórico, que comprende los fundamentos conceptuales de los Ambientes Inteligentes de Aprendizaje y la teoría de autoeficacia de Bandura como bases del modelo propuesto. El Capítulo 3 presenta la revisión de la literatura, organizada en torno a las fuentes de autoeficacia y los trabajos sobre sistemas tutores inteligentes, y cierra con el posicionamiento de MateLog respecto al vacío identificado en el estado del arte. El Capítulo 4 describe el Modelo de Autoeficacia: sus componentes, la lógica de clasificación de perfiles y las intervenciones pedagógicas que cada perfil activa. El Capítulo 5 expone el proceso de construcción e integración del modelo en MateLog, incluyendo las decisiones de diseño, la actualización de la plataforma y las pruebas de validación funcional. El Capítulo 6 reporta el protocolo del estudio experimental, los resultados estadísticos y la discusión de los hallazgos. El Capítulo 7 consolida las conclusiones del estudio, declara las contribuciones originales al campo y traza las líneas de trabajo futuro.

Capítulo 2. Marco teórico

Este capítulo presenta los fundamentos teóricos que sustentan la investigación: los Ambientes Inteligentes de Aprendizaje como entorno de implementación del modelo y la teoría de autoeficacia de Bandura como base conceptual del mismo.

2.1 Ambientes Inteligentes de Aprendizaje

Un Ambiente Inteligente de Aprendizaje (AIA) se define como un sistema de software que utiliza técnicas de Inteligencia Artificial (IA) para proporcionar un medio en el que los estudiantes aprendan de manera más efectiva, ya que el sistema se adapta a las necesidades individuales de cada estudiante mediante la adaptación del contenido, la retroalimentación y la ruta de aprendizaje (Mavrikis & Holmes, 2019; Tang et al., 2023). A diferencia de las plataformas de aprendizaje convencionales, los AIA no se limitan a entregar contenido digital, sino que construyen una representación dinámica del estudiante para tomar decisiones pedagógicas en función de su estado cognitivo, afectivo y de desempeño (Vandewaetere et al., 2011).

2.1.1 Relación entre *e-learning*, AIA y STI

Para comprender el alcance de los AIA es necesario delimitar su relación con dos conceptos cercanos: el *e-learning* y los Sistemas Tutores Inteligentes (STI). Estos tres términos suelen utilizarse de manera intercambiable, aunque hacen referencia a categorías de sistemas con distintos grados de adaptabilidad y uso de IA, como se detalla a continuación.

El *e-learning* es el término más amplio y se refiere a cualquier tipo de aprendizaje mediado por medios electrónicos, como Internet, software, videos o plataformas de gestión del aprendizaje (Chahal, 2022). Engloba desde cursos en línea masivos (como Coursera o edX) hasta materiales digitales estáticos (como libros electrónicos o videos educativos en

YouTube), sin que ello implique necesariamente adaptación o inteligencia. Los AIA constituyen un subconjunto del *e-learning* caracterizado por su capacidad de adaptarse a las características del alumno, tales como su estilo de aprendizaje, nivel de conocimiento, ritmo de progreso o estado afectivo (Vandewaetere et al., 2011).

Por su parte, los STI son un tipo específico de AIA enfocado en simular la tutoría humana mediante modelos del dominio, del estudiante y de la estrategia pedagógica, con el fin de ofrecer instrucción personalizada y retroalimentación adaptativa (Marouf et al., 2024; Rodríguez Chávez, 2021). En esencia, todo STI es un AIA, y todo AIA es una forma de *e-learning*, pero no a la inversa.

La Tabla 2.1 presenta las principales diferencias entre estos tres conceptos a partir de cinco criterios: el grado de adaptación, el uso de IA, el tipo de modelo del estudiante que mantienen y el carácter de la retroalimentación que ofrecen.

Tabla 2.1 Comparación entre *e-learning*, AIA y STI

Criterio	<i>E-learning</i>	AIA	STI
Adaptación al estudiante	Mínima o nula; contenido igual para todos (Chahal, 2022)	Adapta contenido, ritmo o ruta según características del alumno (Vandewaetere et al., 2011)	Adapta contenido, retroalimentación e intervención pedagógica con base en modelos formales (Marouf et al., 2024); Rodríguez Chávez, 2021)
Uso de IA	No es requisito	Habitualmente sí (reglas, clasificación, <i>Machine Learning</i>) (Mavrikis & Holmes, 2019; Tang et al., 2023)	Sí, central al diseño (sistemas expertos, redes bayesianas, ML, NLP) (Eryilmaz & Adabashi, 2020)
Modelo del estudiante	No existe o es estático	Representación dinámica de algunas variables	Modelo explícito y actualizado del conocimiento, errores y, en ocasiones, del estado afectivo (Sierra et al., s/f; Burns & Capps, 1988)
Retroalimentación	Estandarizada o ausente	Diferenciada por perfil o desempeño (Vandewaetere et al., 2011)	Personalizada, contextual y pedagógicamente guiada (Marouf et al., 2024)

2.1.2 Características y componentes de los AIA

Los AIA, y particularmente los STI, comparten un conjunto de características que los distinguen de otros sistemas educativos digitales: la adaptabilidad al comportamiento y a las necesidades del estudiante, la interacción continua a través de la interfaz, la representación formal del conocimiento del dominio, el diagnóstico del estado del estudiante y la orientación pedagógica basada en dicho diagnóstico (Rodríguez Chávez, 2021; Sierra et al., s/f).

Para cumplir con las funciones anteriormente descritas, los AIA se organizan en cuatro módulos que interactúan entre sí: (i) Módulo experto, (ii) Modelo del estudiante, (iii) Módulo tutor, y (iv) Módulo interfaz. La Figura 2.1 representa esta arquitectura modular y las interacciones entre sus componentes.

El módulo del dominio o experto contiene el conocimiento del área de estudio; el modelo del estudiante registra el avance, aciertos, errores y características del aprendiz, y constituye el componente clave para la adaptación (Sierra et al., s/f); el módulo tutor o pedagógico traduce la información del modelo del estudiante en decisiones pedagógicas tales como seleccionar el siguiente ejercicio o el tipo de retroalimentación que se presentará al estudiante (Burns & Capps, 1988; Rodríguez Chávez, 2021); y el módulo de interfaz gestiona la interacción con el usuario y la presentación del contenido. Esta arquitectura de cuatro módulos es característica tanto de los Sistemas Tutores Inteligentes como de los Ambientes Inteligentes de Aprendizaje que incorporan componentes adaptativos, lo que establece la equivalencia funcional entre ambas categorías de sistemas (Burns & Capps, 1988; Rodríguez Chávez, 2021).

La adaptabilidad, entendida como la capacidad del sistema para ajustar su comportamiento al estado dinámico del estudiante, constituye el rasgo más distintivo y, al mismo tiempo, el más exigente de los AIA. Esta adaptabilidad se apoya en diversas técnicas de IA: redes neuronales y deep learning para clasificar a los estudiantes y analizar su comportamiento,

sistemas expertos y razonamiento basado en reglas para tomar decisiones pedagógicas, redes bayesianas para modelar el conocimiento del estudiante y su progreso, y lógica difusa para manejar la incertidumbre propia de la cognición humana (Eryilmaz & Adabashi, 2020; Rodríguez Chávez, 2021).




Figura 2.1 Arquitectura de un STI y las relaciones entre sus componentes. Adaptado de Burns y Capps (1988).

2.1.3 Ejemplos de AIA

Para ilustrar la diversidad de aplicaciones de los AIA y, en particular, las dimensiones de adaptabilidad que pueden incorporar, la Tabla 2.2 sintetiza una selección representativa de sistemas organizados en tres categorías: (i) AIA orientados al aprendizaje de matemáticas y lógica, dominio de aplicación del presente trabajo; (ii) AIA que adaptan la instrucción en función de variables cognitivo-afectivas semejantes a la autoeficacia; y (iii) AIA que ejemplifican otras estrategias de adaptabilidad relevantes.

En conjunto, los ejemplos de la Tabla 2.2 muestran que la adaptabilidad en los AIA puede operar en múltiples disciplinas y mediante diversas técnicas. La caracterización teórica de estos sistemas, junto con la delimitación conceptual entre *e-learning*, AIA y STI establecida en las secciones anteriores, constituye el marco de referencia para este trabajo de investigación.

Tabla 2.2 Ejemplos de AIA según su dominio y mecanismo de adaptación

Sistema	Dominio	Mecanismo de adaptación	Referencia
MATHia	Matemáticas (secundaria-universidad)	Aprendizaje adaptativo sobre desempeño; ajuste de problemas y materiales	Ritter, Anderson, Koedinger & Corbett (2007)
Smartick	Matemáticas (primaria)	Ajuste dinámico del nivel de dificultad según desempeño	Corona-González et al. (2024)
Andes Physics Tutor	Física (universidad)	Redes bayesianas para estimar dominio por elemento de conocimiento	VanLehn et al. (2005)
Logic Tutor	Lógica formal	Sistema pionero basado en reglas (años 60)	Carbonell (1970)
ASSISTments	Diversas materias	Evaluación diagnóstica continua	Heffernan & Heffernan (2014)
ALEKS	Diversas materias	Mapeo individualizado del estado del conocimiento	Doignon & Falmagne (1985)
Duolingo	Idiomas	Modelo basado en teoría de respuesta al ítem (IRT) combinado con gamificación	Bicknell, Brust & Settles (2023)
SQL-Tutor	Bases de datos	Modelado basado en restricciones (<i>constraint-based modeling</i>)	Mitrovic & Ohlsson (1999)

2.2 Teoría de autoeficacia

La teoría de la autoeficacia de Bandura (1977) explica y predice el cambio de comportamiento. Su idea central es que las expectativas de eficacia personal definen si una persona enfrentará una situación, cuánto esfuerzo le dedicará y por cuánto tiempo persistirá ante las dificultades. En educación, esta teoría es muy relevante porque las creencias de los estudiantes sobre sus propias capacidades afectan directamente su motivación, persistencia y rendimiento académico (Díaz Mujica et al., 2022; McQuiggan et al., 2008).

De acuerdo con Bandura (1977), las expectativas de autoeficacia moldean el comportamiento humano a través de tres mecanismos clave: (i) determinan la elección de actividades y entornos, ya que las personas tienden a involucrarse en situaciones que perciben dentro de sus capacidades y evitan aquellas que consideran amenazantes; (ii) influyen en el nivel de esfuerzo y persistencia, pues quienes confían en sus capacidades

invierten mayor energía y se mantienen comprometidos ante las dificultades; y (iii) modulan los patrones de pensamiento y las respuestas emocionales, favoreciendo la concentración y la regulación emocional en personas con alta autoeficacia.

2.2.1 Definición de autoeficacia

El concepto de autoeficacia fue introducido por Albert Bandura (1977) en el marco de su Teoría Social Cognitiva. Surgió como una propuesta para unificar diversos hallazgos sobre el cambio de comportamiento bajo un mismo constructo: la creencia que una persona tiene sobre su capacidad para producir determinados resultados. Bandura observó que las personas con habilidades equivalentes podían desempeñarse de manera muy distinta dependiendo de la confianza que tuvieran en sus propias capacidades, lo que motivó la formalización del concepto.

La autoeficacia percibida se define como la creencia que una persona tiene sobre sus propias capacidades para organizar y ejecutar los cursos de acción requeridos para producir determinados resultados (Bandura, 1977). No se trata de poseer las habilidades en sí mismas, sino del juicio o estimación sobre la propia capacidad para gestionar situaciones futuras. En el ámbito educativo, este concepto se expresa en las creencias de los estudiantes sobre su capacidad para aprender o completar una tarea académica determinada (Díaz Mujica et al., 2022).

Es importante distinguir la autoeficacia de otros constructos relacionados con las creencias sobre el control y el comportamiento, ya que la confusión entre ellos puede limitar su comprensión y aplicación (Schunk, 1989). En la Tabla 2.3 se presenta una comparación entre la autoeficacia y sus constructos afines. Las definiciones se sustentan en la literatura especializada, mientras que los ejemplos fueron adaptados de los planteamientos originales de los autores y, cuando fue posible, contextualizados en el aprendizaje de las matemáticas para facilitar la distinción entre cada concepto.

Tabla 2.3 Comparación entre la autoeficacia y constructos afines

Concepto	Definición	Ejemplo
Autoeficacia percibida	Creencia en la propia capacidad para organizar y ejecutar los cursos de acción necesarios para producir determinados logros (Bandura, 1997, 2006).	"Estoy seguro de que puedo resolver problemas matemáticos complejos" (adaptado de Bandura, 2006).
Expectativas de resultado	Juicios sobre los resultados que probablemente seguirán a la ejecución de un comportamiento determinado (Bandura, 1997, 2006).	"Si dedico tiempo a estudiar matemáticas, obtendré una buena calificación en el examen" (adaptado de Bandura, 1997).
Creencias de contingencia	Creencia en la existencia de una relación causa-efecto entre una acción y un resultado, sin necesariamente implicar la capacidad personal para ejecutarla (Flammer, 1995).	"Practicar ejercicios de matemáticas mejora el desempeño en exámenes" (adaptado de Flammer, 1995).
Autoconcepto	Autoevaluación general que incluye reacciones y sentimientos de autovalía (autoestima), pudiendo organizarse jerárquicamente por dominios (Shavelson, Hubner & Stanton, 1976; Marsh, 1990).	"Soy bueno en matemáticas" o "He sido siempre bueno en matemáticas" (ítems del <i>Self-Description Questionnaire</i> ; Marsh, 1990).
Competencia percibida	Creencia general en la propia capacidad para producir ciertas acciones, sin la especificidad contextual de la autoeficacia (Flammer, 1995; Zimmerman, 1995b).	"Aprendo cosas rápidamente en matemáticas" (ítem del <i>Self-Description Questionnaire</i> ; Marsh, 1990).
Locus de control	Percepción generalizada sobre si los resultados dependen de la propia conducta (interno) o de factores externos como la suerte o el destino (externo) (Rotter, 1966).	Interno: "Lo que me sucede en matemáticas depende de mis propias acciones." Externo: "Las malas calificaciones se deben a la mala suerte o a exámenes injustos" (adaptado de Rotter, 1966).
Control percibido	Construto amplio compuesto por creencias de contingencia y de competencia, referido a la creencia de que las propias acciones afectan los resultados (Flammer, 1995; Schneewind, 1995).	"Tengo control sobre cómo me va en el curso de matemáticas, porque dependen de mis acciones y de mi capacidad" (adaptado de Flammer, 1995).
Atribuciones	Juicios causales que las personas hacen sobre los resultados específicos de éxito o fracaso, considerando dimensiones de locus, estabilidad y controlabilidad (Weiner, 1985).	"Reprobé el examen de matemáticas porque no me esforcé lo suficiente" (causa interna, inestable, controlable) frente a "Reprobé porque no soy bueno en matemáticas" (causa interna, estable, incontrolable) (adaptado de Weiner, 1985).
Estilo explicativo	Tendencia recurrente y disposicional a explicar los eventos —especialmente los éxitos y fracasos— a lo largo de las dimensiones interno/externo, estable/inestable y global/específico (Peterson et al., 1982; Seligman, 1991).	Estilo pesimista: explicar consistentemente los fracasos académicos como "siempre soy malo para todas las materias" (causa estable y global) (adaptado de Peterson et al., 1982).

La autoeficacia se distingue de los demás constructos por ser un juicio prospectivo, específico de tarea y orientado a la capacidad de ejecutar acciones, a diferencia de aquellos que se enfocan en resultados, autoevaluaciones globales o explicaciones retrospectivas (Bandura, 1997; Schunk, 1989; Zimmerman, 2000).

Un aspecto fundamental de la autoeficacia percibida es que puede estar bien o mal calibrada respecto al desempeño real del individuo. Bandura (1977) advierte que las creencias de eficacia no son reflejos directos de las capacidades objetivas de la persona, por lo que es posible tanto sobreestimarlas como subestimarlas. Flammer (1995) documenta que esta desalineación puede manifestarse en ambas direcciones: la confianza puede superar el desempeño efectivo —como ocurre cuando un estudiante con alta autoeficacia rinde por debajo de lo esperado— o el desempeño puede superar la confianza declarada —como ocurre cuando un estudiante con baja autoeficacia obtiene buenos resultados—. Reconocer esta posible discrepancia entre autoeficacia percibida y desempeño real es relevante para el diseño de sistemas adaptativos, ya que un mecanismo que opere únicamente sobre la autoeficacia declarada puede responder de forma inadecuada a estudiantes cuya confianza y rendimiento no coinciden.

2.2.2 Fuentes de autoeficacia

La autoeficacia no es estática, sino que se construye mediante un proceso cognitivo de interpretación y evaluación de diversas experiencias. Bandura (1977) identificó cuatro fuentes principales de información a partir de las cuales se forman y modifican las creencias de autoeficacia: los logros de desempeño, la experiencia vicaria, la persuasión social y los estados fisiológicos y afectivos.

La forma en que la persona selecciona, pondera e integra la información de cada una de estas fuentes es lo que finalmente da forma a sus juicios de autoeficacia (Bandura, 1995). En la Tabla 2.4 se presenta una descripción de cada una de las cuatro fuentes y su nivel de influencia relativa sobre las creencias de autoeficacia, mientras que en la Tabla 2.5 se

describen las estrategias específicas para fortalecer cada fuente en el contexto académico, las cuales son particularmente relevantes para el diseño de intervenciones educativas como la que se plantea en este proyecto.

La influencia de cada fuente no es absoluta, sino mediada por la interpretación cognitiva de la persona y por factores personales, sociales y situacionales como las ideas preconcebidas, la dificultad percibida de la tarea, el esfuerzo requerido y las circunstancias del contexto (Bandura, 1995).

A partir de la comprensión de estas cuatro fuentes, la investigación en autoeficacia ha derivado en estrategias específicas para fortalecerlas dentro del contexto académico. La Tabla 2.5 resume esas estrategias, que sirven como guía directa para diseñar intervenciones educativas enfocadas en desarrollar la confianza que los estudiantes tienen en sus propias capacidades.

Tabla 2.4 *Fuentes principales de autoeficacia (Bandura, 1977)*

Fuente	Descripción	Influencia
Experiencias de éxito	Experiencias directas de éxito en la superación de desafíos, que demuestran a la persona que posee las capacidades necesarias (Bandura, 1977; Zimmerman, 2000).	Alta. Es la fuente más influyente y efectiva (Bandura, 1995).
Experiencia vicaria	Observación de las acciones de otros y sus resultados, frecuentemente a través de un proceso de comparación social (Schunk, 1989). Es particularmente relevante cuando la persona tiene poca experiencia previa con la tarea (Bandura, 1977).	Moderada-alta. Mayor cuando el modelo es percibido como similar al observador (Schunk, 1986).
Persuasión verbal	Convencer verbalmente a una persona de que posee las capacidades necesarias para lograr algo (Bandura et al., 1999).	Limitada. Depende de la credibilidad del persuasor y de que las expectativas transmitidas sean realistas (Schunk, 1989).
Estados fisiológicos y afectivos	Reacciones corporales y estados emocionales (estrés, fatiga, ansiedad, estado de ánimo) que experimentan las personas al enfrentar una tarea (Bandura, 1977). Lo relevante no es su intensidad, sino su interpretación.	Indirecta. Funcionan como indicadores de eficacia cuya interpretación influye en las creencias (Oettingen, 1995).

Tabla 2.5 Estrategias para fortalecer las fuentes de autoeficacia en el contexto académico

Fuente	Estrategias de fortalecimiento en el contexto académico
Experiencias de éxito	Brindar oportunidades estructuradas de éxito en tareas alcanzables pero desafiantes, considerar los progresos parciales como parte de la mejora, y enfatizar la superación personal sobre la comparación con otros (Bandura, 1995).
Experiencia vicaria	Exponer a los estudiantes a modelos competentes (profesores) que transmitan conocimientos y estrategias, y a modelos similares (compañeros) que refuercen la creencia en la propia capacidad. Incluir modelos de afrontamiento que normalicen el error y la corrección (Schunk, 1986; Zimmerman, 1995b).
Persuasión verbal	Acompañar el refuerzo verbal con oportunidades estructuradas de éxito. La retroalimentación atribucional basada en el desempeño resulta más potente que la persuasión verbal general (Schunk, 1983).
Estados fisiológicos y afectivos	Fomentar un entorno de apoyo, ayudar a interpretar las señales corporales como preparación para la acción y no como debilidad, y disminuir el estrés y la ansiedad académica (Bandura, 1995; Meng & Zhang, 2023).

Estas estrategias son aplicables en distintos entornos educativos, incluidas las plataformas digitales como los Ambientes Inteligentes de Aprendizaje, lo que fundamenta el diseño de sistemas que busquen desarrollar la confianza de los estudiantes en sus propias capacidades (Valencia Vallejo, 2021). Las creencias iniciales de autoeficacia afectan si una persona intenta una tarea, cuánto se esfuerza y por cuánto tiempo persiste. El resultado de ese intento (especialmente si logra éxito) retroalimenta esas creencias y las modifica para el futuro (Schunk, 1989). Este ciclo permite que la autoeficacia evolucione con el tiempo, y por eso es clave para diseñar intervenciones educativas que busquen fortalecer la confianza de los estudiantes.

2.2.3 Evaluación de la autoeficacia

La medición de la autoeficacia percibida no se basa en una cualidad global o rasgo general de la personalidad, sino en juicios personales sobre las propias capacidades para organizar y ejecutar cursos de acción dirigidos a alcanzar determinados resultados (Zimmerman, 2000). A diferencia de las medidas más globales del autoconcepto o el control percibido, las medidas de autoeficacia son específicas del dominio y dependientes del contexto.

No obstante, esta especificidad presenta una limitación importante: cuando una persona se enfrenta a tareas novedosas o desconoce el dominio en cuestión, no puede formular juicios de autoeficacia específicos, pues carece de las habilidades o experiencias previas sobre las cuales basar dicha evaluación (Pajares, 1997).

En estos casos, las personas tienden a generalizar desde logros previos en situaciones percibidas como similares o a apoyarse en creencias más amplias sobre sus capacidades (Pajares, 1997). Por ello, la literatura ha reconocido la utilidad complementaria de la autoeficacia general, definida como la creencia en la propia competencia para afrontar tareas novedosas y lidiar con la adversidad en un amplio rango de situaciones desafiantes (Schwarzer et al., 2005).

Esta medida resulta particularmente útil en situaciones nuevas y ambiguas, donde la persona tiene poca experiencia personal (Mencl et al., 2012). En consecuencia, cuando se evalúa la autoeficacia en contextos donde el dominio específico puede ser desconocido o parcialmente familiar para los participantes —como ocurre frecuentemente al introducir nuevas herramientas o entornos de aprendizaje— resulta preferible incorporar una medida de autoeficacia general que complemente las medidas específicas del dominio.

Zimmerman (1995b) plantea tres dimensiones para entender la autoeficacia: (i) el nivel (qué tan difíciles son las tareas que la persona cree poder resolver), (ii) la generalidad (si esa confianza se extiende a otras áreas), y (iii) la fuerza (qué tan segura se siente la persona). Estas dimensiones sirven tanto para escalas específicas como generales, y ayudan a interpretar los resultados de cualquier prueba de autoeficacia.

Un aspecto clave de cómo se mide la autoeficacia es que se basa en lo que la persona es capaz de lograr por sí misma (criterio de maestría), y no en comparar su desempeño con el de los demás (criterio normativo o social). Por ejemplo, se pregunta a los estudiantes cuán seguros están de poder resolver problemas de cierta dificultad, no cuán bien esperan hacerlo en comparación con otros estudiantes (Zimmerman, 1995b).

En cuanto a la edad apropiada para medir la autoeficacia, Schneewind (1995) sugiere que este concepto requiere un nivel relativamente alto de funcionamiento cognitivo, lo que dificulta su evaluación en niños pequeños, quienes tienden a sobreestimar sus capacidades o subestimar la dificultad de las tareas (Flammer, 1995). El desarrollo de las estructuras cognitivas subyacentes a los juicios de autoeficacia se completa estructuralmente en la adolescencia, al menos en dominios como el educativo, lo que convierte a esta etapa en un período clave para evaluar e influir en el nivel de autoeficacia, especialmente ante desafíos académicos significativos como el ingreso al nivel superior.

2.2.3.1 Escalas de autoeficacia

Las escalas de autoeficacia evalúan las creencias de una persona sobre su capacidad para ejecutar acciones en un dominio determinado. Bandura (2006) enfatiza la importancia de personalizarlas al dominio de interés, pues las medidas demasiado generales pierden validez al incluir ítems irrelevantes; por ejemplo, un ejecutivo puede tener alta autoeficacia en gestión, pero baja en crianza (Sherer et al., 1982).

No obstante, dado que las experiencias de dominio pueden generalizarse, la literatura distingue entre dos grandes tipos: las escalas específicas, que evalúan la autoeficacia frente a tareas o dominios concretos (como la escritura académica, matemáticas o aplicación de fortalezas; Mitchell et al., 2021; Tsai et al., 2014; Van Zyl et al., 2022), y las generales, que evalúan la creencia transversal sobre la capacidad para afrontar diversas situaciones desafiantes (Schwarzer & Jerusalem, 1995).

Entre estas últimas, la Escala de Autoeficacia General (GSE por sus siglas en inglés) de Baessler y Schwarzer (1996), adaptada al español por Sanjuán Suárez et al. (2000), es una de las más reconocidas y empleadas: consta de 10 ítems unidimensionales (Likert de 4 puntos), con propiedades validadas transculturalmente y alfas de Cronbach entre 0.79 y 0.93 en España, México, Chile, Perú, Ecuador y otros países (Espada et al., 2012; Padilla et al., 2006; Scholz et al., 2002).

Capítulo 3. Revisión de la literatura

La autoeficacia del estudiante es un factor crucial para el éxito en el aprendizaje, incluso en Ambientes Inteligentes de Aprendizaje. Estudiantes con alta autoeficacia muestran mayor motivación, perseverancia y mejores resultados académicos, lo que subraya la importancia de identificar qué elementos de estos entornos pueden favorecer su desarrollo (Conati et al., 2015).

3.1 Inteligencia Artificial en la educación

Las tecnologías basadas en inteligencia artificial (IA) están transformando la educación al crear oportunidades para mejorar los resultados de aprendizaje mediante la personalización de contenidos y la provisión de retroalimentación inmediata (Shahzad et al., 2024). El estudio de Shahzad et al. (2024) sobre el impacto de la IA generativa —que incluye modelos de lenguaje extenso como ChatGPT y otros chatbots educativos— demuestra que el uso de estas tecnologías mejora las creencias de los estudiantes sobre sus propias capacidades, promueve entornos de aprendizaje más equitativos y fomenta la creatividad, factores que en conjunto contribuyen a un mejor rendimiento académico.

Sin embargo, la incorporación de la IA generativa en contextos educativos también presenta riesgos que deben abordarse con cuidado: el posible uso indebido para el plagio, la difusión de información inexacta que puede pasar desapercibida si no se contrasta con otras fuentes, y las limitaciones de estas herramientas en la interpretación de las solicitudes del usuario (Graefen & Fazal, 2024). Asimismo, una dependencia excesiva de la IA puede llevar al estudiante a sustituir el esfuerzo propio por el apoyo externo, lo que debilita el desarrollo de la autoconfianza y disminuye el papel de la autoeficacia en el aprendizaje (Graefen & Fazal, 2024).

Desde una perspectiva más amplia, Liang et al. (2020) analizan cómo la IA reconfigura los métodos de enseñanza y aprendizaje —desde los sistemas tutores inteligentes hasta los robots educativos— y subrayan la

necesidad de adaptar los objetivos educativos y la práctica docente a las nuevas realidades de la era de la inteligencia artificial. La clave para un uso pedagógico efectivo radica en encontrar un equilibrio entre las capacidades de la tecnología y el rol del docente como mentor y guía del proceso de aprendizaje (Liang et al., 2020).

3.2 Ambientes Inteligentes de Aprendizaje

En el panorama educativo actual, los ambientes inteligentes de aprendizaje constituyen una de las manifestaciones más representativas de la IA aplicada a la enseñanza, pues combinan herramientas tecnológicas con estrategias pedagógicas adaptativas orientadas a personalizar la experiencia educativa (Tang et al., 2021). La investigación en este campo ha crecido de manera sostenida, concentrándose en cuatro áreas principales: (i) los sistemas adaptativos y de personalización, (ii) la evaluación y valoración del aprendizaje, (iii) el perfilado y la predicción del comportamiento del estudiante, (iv) y los sistemas tutores inteligentes (Tang et al., 2021).

La pandemia por COVID-19 funcionó como catalizador de esta expansión. La suspensión de las clases presenciales impulsó la adopción masiva de plataformas educativas en línea y evidenció la necesidad de contar con entornos de aprendizaje mediados por tecnología capaces de preservar la calidad del proceso formativo (Masimba & Maguraushe, 2022; Susanti & Wulandari, 2021). Los estudios han comprobado un alto nivel de aceptación de los ambientes inteligentes por parte de los estudiantes, así como su contribución favorable al rendimiento académico (Hu, 2021). La adopción exitosa de estos entornos depende, no obstante, de la autoeficacia tanto de docentes como de estudiantes: quienes perciben las herramientas digitales como útiles y accesibles logran integrarse de manera más efectiva en la práctica educativa mediada por tecnología (Masimba & Maguraushe, 2022).

3.3 Autoeficacia

La autoeficacia se refiere a las creencias que tienen los individuos sobre sus capacidades para aprender o completar una tarea determinada, lo que implica la identificación de las oportunidades y los desafíos asociados a dicha tarea (Díaz Mujica et al., 2022). En el contexto educativo, los estudiantes con alta autoeficacia tienden a obtener mejores resultados académicos, dado que su confianza en las propias capacidades los predispone a realizar un esfuerzo sostenido orientado al logro (Lumbantobing, 2021).

La medición de la autoeficacia requiere precisión conceptual e instrumental. Dado que las creencias de autoeficacia pueden variar significativamente según el dominio de actividad, es necesario operacionalizar el constructo de manera específica para el área de interés y utilizar escalas diseñadas expresamente con este fin (Díaz Mujica et al., 2022). Una fuente frecuente de error en la literatura consiste en emplear instrumentos orientados a medir conceptos relacionados —como la motivación, la autorregulación o la confianza general— y etiquetarlos de manera incorrecta como medidas de autoeficacia (Díaz Mujica et al., 2022).

Más allá de su especificidad de dominio, la autoeficacia es un constructo dinámico que puede cambiar con el tiempo y la experiencia. Las intervenciones diseñadas para fortalecerla —como la provisión de retroalimentación positiva, la creación de oportunidades para el éxito y la exposición a modelos de referencia— pueden tener un impacto significativo sobre el rendimiento académico y el bienestar del estudiante (Lumbantobing, 2021).

Las subsecciones siguientes examinan la autoeficacia en dos contextos relevantes para este trabajo: su presencia en ambientes de aprendizaje mediados por tecnología y su relación con el rendimiento en dominios de razonamiento formal.

3.3.1 Autoeficacia en Ambientes Inteligentes de Aprendizaje

La investigación sobre autoeficacia en entornos de aprendizaje mediados por tecnología ha adoptado aproximaciones diversas tanto en la medición del constructo como en las estrategias para fortalecerlo. Sun y Rogers (2021) presentan el desarrollo y la validación de la *Online Learning Self-efficacy Scale* (OLSS), un instrumento diseñado específicamente para medir la autoeficacia en contextos de aprendizaje en línea. A partir de un modelo de ecuaciones estructurales aplicado a datos de 366 estudiantes, los autores redujeron la escala a 31 ítems agrupados en cuatro factores: autoeficacia en el uso de la tecnología, en las tareas de aprendizaje en línea, en la interacción con instructores y compañeros, y en la autorregulación y la motivación.

En una línea metodológica diferente, Bounhar et al. (2022) proponen un enfoque de medición basado en datos fisiológicos — electroencefalograma, seguimiento ocular, respuesta galvánica de la piel y electrocardiograma— para evaluar la autoeficacia en entornos de realidad virtual de carácter industrial. Aunque los autores demuestran que es posible predecir el nivel de autoeficacia a partir de estas señales, el estudio presenta limitaciones relevantes para su extrapolación a contextos educativos convencionales: el tamaño de la muestra fue reducido (15 participantes) y los sensores empleados pueden resultar costosos, complejos de configurar e intrusivos.

Desde el punto de vista de la intervención pedagógica, Sergent et al. (2024) estudian cómo las indicaciones de autorregulación y la retroalimentación adaptativa pueden mejorar la autoevaluación y la autoeficacia en niños de entre cinco y ocho años dentro de una aplicación de alfabetización. Los resultados indican que las indicaciones visuales y auditivas, combinadas con retroalimentación específica sobre el desempeño, favorecen el desarrollo de una percepción más precisa de las propias habilidades y contribuyen al incremento de la confianza del estudiante. Masimba y Maguraushe (2022), por su parte, señalan que la

autoeficacia tanto de docentes como de estudiantes es un factor determinante en la percepción de utilidad y facilidad de uso de los entornos de *e-learning*, lo que subraya la necesidad de fortalecer este constructo como condición para el éxito en la adopción de plataformas educativas digitales.

3.3.2 Autoeficacia en el aprendizaje de las matemáticas

La investigación sobre autoeficacia en el aprendizaje matemático es pertinente para este trabajo porque la lógica matemática, como dominio de alta carga simbólica y razonamiento formal, comparte con las matemáticas las condiciones en las que la autoeficacia influye en el rendimiento del estudiante. A diferencia de las matemáticas, la lógica matemática no forma parte de ningún temario ni asignatura del bachillerato en México, por lo que los estudiantes de ese nivel no han desarrollado creencias de autoeficacia específicas sobre este dominio antes de su primer contacto con él. Esta diferencia de contexto distingue el presente trabajo de los estudios revisados en esta sección, donde la autoeficacia se mide en estudiantes con experiencia previa en el dominio.

La relación entre autoeficacia y rendimiento matemático ha sido documentada en distintos contextos y niveles educativos (Afari & Eksail, 2022; Shimizu, 2022). Afari y Eksail (2022) investigan esta relación en tres universidades de Abu Dhabi, encontrando que la autoeficacia académica actúa como mediador entre la participación en clase y el éxito académico en matemáticas. Los resultados validan la importancia de construir ambientes de aprendizaje positivos y participativos como condición para fomentar la autoeficacia del estudiante y, a través de ella, mejorar su rendimiento.

En un nivel de educación básica, Shimizu (2022) analiza la red de relaciones entre la resolución de problemas de demostración matemática, la ansiedad matemática, la autoeficacia, el compromiso de aprendizaje y el razonamiento inverso, a partir de una encuesta aplicada a 160 estudiantes de octavo grado. Los resultados muestran que la autoeficacia mantiene una

relación positiva con la capacidad para resolver problemas de demostración, tanto de manera directa como de manera indirecta a través de su efecto sobre la ansiedad matemática y sobre el uso del razonamiento inverso. Estos hallazgos sugieren que fortalecer la autoeficacia en el contexto del aprendizaje matemático puede contribuir no solo al desempeño en tareas específicas, sino también al desarrollo de estrategias de resolución de problemas más sofisticadas.

3.4 Fuentes de autoeficacia en Ambientes Inteligentes de Aprendizaje

Los ambientes inteligentes de aprendizaje y los sistemas tutores inteligentes comparten la misma arquitectura modular —módulo experto, modelo del estudiante, módulo tutor y módulo de interfaz—, como se desarrolla en el Capítulo 2. La diferencia entre ambos es de énfasis y alcance, no de estructura: mientras que los sistemas tutores se centran en la interacción pedagógica directa con el estudiante, los ambientes inteligentes integran ese componente en un entorno educativo más amplio. Esta equivalencia implica que los principios de modelado de autoeficacia documentados en el contexto de sistemas tutores son transferibles al diseño de MateLog, que es un ambiente inteligente de aprendizaje. La literatura revisada en las subsecciones siguientes es, por esta razón, directamente pertinente para este trabajo, independientemente del rótulo bajo el que se enmarquen los estudios de origen.

Los sistemas tutores inteligentes son una categoría específica dentro de los ambientes inteligentes de aprendizaje, orientada a adaptar la enseñanza a las necesidades individuales del estudiante mediante evaluación continua y retroalimentación personalizada (Castro-Schez et al., 2021). La información recogida permite ajustar la dificultad de los ejercicios, seleccionar estrategias pedagógicas adecuadas y planificar rutas de aprendizaje individualizadas; el análisis de los errores, además, ayuda a identificar patrones de dificultad y orientar la retroalimentación hacia la

reflexión sobre el propio desempeño (Castro-Schez et al., 2021). Una tendencia reciente en estos sistemas es la incorporación de computación afectiva para detectar y responder a los estados emocionales del estudiante (Bradáč et al., 2022b; Pourmirzaei et al., 2023).

Las siguientes subsecciones presentan los estudios revisados, organizados en función de las fuentes de autoeficacia que cada uno modela o fortalece: el modelado de autoeficacia, el modelado de experiencias de éxito y el modelado de persuasión verbal. Una subsección adicional reúne las fuentes que fueron identificadas en la literatura, pero no implementadas en el presente trabajo, junto con la justificación de su exclusión.

3.4.1 Modelado de autoeficacia

Esta categoría consiste en artículos que exploran el modelado de autoeficacia en Sistemas Tutores Inteligentes (STI). Se identificaron 7 artículos relevantes, los cuales se presentan en la Tabla 3.1.

Los artículos de esta categoría, publicados entre 2006 y 2021, comparten una base teórica fundamentada en la autoeficacia de Bandura y destacan su importancia en el aprendizaje y la motivación. Todos exploran la autoeficacia dentro de entornos educativos mediados por tecnología (Alqurashi, 2016; Hodges, 2008; Kookan et al., 2021; McQuiggan & Lester, 2006; McQuiggan et al., 2008; Shi et al., 2021; Zarrin & Montazer, 2019).

Hodges (2008) señala que, a diferencia de los entornos tradicionales donde la relación entre autoeficacia y rendimiento está bien establecida, la investigación sobre su papel en el aprendizaje online es más reciente, menos definida y suele arrojar resultados inconsistentes. Alqurashi (2016) sostiene, al igual que Hodges (2008), que aún es necesario profundizar en la investigación para comprender plenamente la naturaleza de esta relación.

Tabla 3.1 Modelado de autoeficacia

Nº	Título	Referencia	Descripción
1	<i>Self-Efficacy In Online Learning Environments: A Literature Review</i>	Alqurashi (2016)	Enfatiza la necesidad de investigar más a fondo la relación entre la autoeficacia y el aprendizaje <i>online</i> .
2	<i>Self-Efficacy in the Context of Online Learning Environment: A Review of the Literature and Directions for Research</i>	Hodges (2008)	Resalta la relevancia de la autoeficacia en el aprendizaje y la motivación en plataformas de aprendizaje <i>online</i> .
3	<i>Diagnosing Self-Efficacy in Intelligent Tutoring Systems: An Empirical Study</i>	McQuiggan & Lester (2006)	Sostiene que diagnosticar la autoeficacia de los estudiantes en tiempo real puede mejorar la pedagogía y potenciar el aprendizaje en los STI.
4	<i>Modeling self-efficacy in intelligent tutoring systems: An inductive approach</i>	McQuiggan et al. (2008)	Propone un enfoque inductivo para construir modelos de autoeficacia que orienten las decisiones pedagógicas en tiempo real dentro de los STI.
5	<i>Personalizing e-learning environment based on learner's self-efficacy</i>	Zarrin & Montazer (2019)	Infiere automáticamente la autoeficacia académica del estudiante mediante lógica difusa y adapta el entorno de e-learning en consecuencia.
6	<i>Simulating the dynamics of self-regulation, emotion, grit, and student performance in cyber-learning environments</i>	Kookan et al. (2021)	Integra la autoeficacia como variable dinámica dentro del sistema MathSpring, donde orienta la adaptación de la dificultad de los ejercicios.
7	<i>The Adaptive Features of an Intelligent Tutoring System for Adult Literacy</i>	Shi et al. (2021)	Describe el sistema AT-ARC, que selecciona el tipo de diálogo pedagógico a partir de las características del aprendiz, incluyendo su nivel de autoeficacia.

Los estudios de McQuiggan y Lester (2006) y McQuiggan et al. (2008) sostienen que la capacidad de diagnosticar o modelar la autoeficacia de los estudiantes puede mejorar la pedagogía, optimizar las interacciones tutoriales y apoyar el aprendizaje. Ambas investigaciones destacan que la autoeficacia es un factor clave para predecir el comportamiento del estudiante, incluyendo la selección de problemas, la persistencia y el esfuerzo. Asimismo, identifican criterios similares para un diagnóstico eficaz: debe ejecutarse en tiempo real durante las sesiones de aprendizaje, ser eficiente para no comprometer la interactividad y evitar interrupciones en el proceso educativo. Además, advierten que los instrumentos aplicados

antes del aprendizaje pueden resultar insuficientes, dado que la autoeficacia es una variable dinámica que puede cambiar con el tiempo.

Zarrin y Montazer (2019) presentan un sistema tutor inteligente que modela la autoeficacia académica del estudiante de manera automática, sin recurrir a cuestionarios externos, mediante un sistema de lógica difusa que infiere el nivel de autoeficacia a partir del comportamiento observable del estudiante durante la interacción con la plataforma. El nivel inferido, combinado con el estilo de aprendizaje identificado, determina la selección de los objetos de aprendizaje y las recomendaciones presentadas al estudiante. Los resultados del estudio reportan un 75 % de progreso educativo y un incremento en la satisfacción de los participantes, lo que constituye evidencia empírica de que la adaptación basada en autoeficacia produce mejoras medibles en el aprendizaje.

Kooken et al. (2021) modelan la experiencia del estudiante en el sistema MathSpring mediante el Modelo de Aprendizaje Autorregulado Cíclico, en el que la autoeficacia y la motivación se actualizan dinámicamente a partir de la reflexión del estudiante sobre su dominio y sus logros en cada ciclo de aprendizaje. Este modelo establece un bucle de retroalimentación interna: la reflexión sobre el progreso modifica la fase de previsión, lo que a su vez afecta la motivación y la autoeficacia del estudiante, influyendo en el desempeño posterior. El sistema adapta la dificultad de los problemas subsiguientes en función del nivel de dominio recalculado, lo que demuestra que la autoeficacia puede integrarse como componente funcional dentro de la arquitectura adaptativa de un sistema educativo en el dominio matemático.

Shi et al. (2021) describen AT-ARC (*AutoTutor for Adult Reading Comprehension*), un sistema tutor inteligente diseñado para adaptarse a múltiples características del aprendiz, entre las que se incluyen el conocimiento, las habilidades, la motivación y la autoeficacia. Una de sus funciones adaptativas centrales es la selección del tipo de triálogo — formato de interacción entre el aprendiz, un agente tutor y un agente estudiante— en función de las características detectadas, incluyendo

explícitamente el nivel de autoeficacia. Este trabajo evidencia que, en sistemas publicados después de 2016, la autoeficacia ha pasado de ser tratada como variable de resultado a convertirse en parámetro de entrada que orienta directamente las decisiones pedagógicas del sistema.

El modelado de la autoeficacia en los sistemas educativos inteligentes ha avanzado desde los trabajos fundacionales de diagnóstico y predicción de McQuiggan y Lester (2006) y McQuiggan et al. (2008) hacia implementaciones que integran la autoeficacia como variable dinámica capaz de orientar decisiones pedagógicas en tiempo real (Kookan et al., 2021; Shi et al., 2021; Zarrin & Montazer, 2019). Sin embargo, los sistemas identificados modelan la autoeficacia en combinación con otras variables —motivación, estilo de aprendizaje o nivel de dominio— sin que ninguno de ellos la evalúe de forma aislada con el propósito explícito de clasificar al estudiante en perfiles adaptativos diferenciados.

3.4.2 Modelado de experiencias de éxito

Dentro de esta categoría se identificaron cuatro artículos relevantes, los cuales se presentan en la Tabla 3.2.

Guzmán y Conejo (2015) proponen un modelo basado en la Teoría de Respuesta al Ítem (TRI) que permite diagnosticar de manera precisa tanto el conocimiento como las concepciones erróneas de los estudiantes. Al detectar y corregir ideas equivocadas desde el principio, se evita la frustración cuando se avanza a contenidos más complicados y se generan condiciones para que el estudiante experimente el éxito de manera progresiva.

Papoušek y Pelánek (2015) analizan cómo el comportamiento de los sistemas educativos adaptativos puede influir en la motivación de los estudiantes con respecto a la relación entre la dificultad de las tareas y el nivel de compromiso. Los autores identifican que ajustar las preguntas al nivel de conocimiento del estudiante evita un aumento innecesario de dificultad, incrementa sus oportunidades de éxito y contribuye a una experiencia de aprendizaje más positiva.

Tabla 3.2 Modelado de experiencias de éxito

Nº	Título	Referencia	Descripción
1	<i>Measuring Misconceptions Through Item Response Theory</i>	Guzmán & Conejo (2015)	Propone un modelo basado en la Teoría de Respuesta al Ítem para diagnosticar con precisión el conocimiento y las concepciones erróneas de los estudiantes.
2	<i>Impact of Adaptive Educational System Behavior on Student Motivation</i>	Papoušek & Pelánek (2015)	Analiza cómo el ajuste adaptativo de la dificultad de las tareas influye en la motivación y las oportunidades de éxito del estudiante.
3	<i>Improving learning maps using an adaptive testing system (PLACEments)</i>	Adjei & Heffernan (2015)	Desarrolla un sistema de pruebas adaptativo que ajusta las preguntas según las respuestas del estudiante para asegurar el dominio de prerrequisitos.
4	<i>The Pedagogical Model of SIAL: An Adaptive and Open-Ended Intelligent Tutoring System for First Order Logic</i>	Maestro-Prieto & Simon-Hurtado (2018)	Describe SIAL, un STI para enseñar lógica de primer orden que diagnostica errores y acepta múltiples soluciones válidas.

Adjei y Heffernan (2015) crearon un sistema de pruebas adaptativo capaz de cambiar las preguntas realizadas al estudiante dependiendo de cómo va respondiendo. Si un estudiante responde correctamente, se le presentan habilidades posteriores; si responde incorrectamente, se le presentan habilidades prerrequisito. Al adaptar la secuencia de aprendizaje a las necesidades individuales y al asegurar que se dominen los prerrequisitos adecuados, se mejora significativamente la trayectoria de aprendizaje y se aumentan las posibilidades de éxito.

Maestro-Prieto y Simon-Hurtado (2018) describen SIAL, un sistema tutor inteligente para enseñar Lógica Computacional. SIAL utiliza un Probador Automático de Teoremas para Lógica de Primer Orden como modelo de dominio, lo que le permite realizar un diagnóstico preciso de errores y aceptar múltiples soluciones válidas para un mismo problema. La capacidad de ofrecer refuerzo específico para las áreas de dificultad contribuye a que los estudiantes experimenten el éxito como resultado de su propio esfuerzo y razonamiento.

Los artículos de esta categoría muestran cómo los sistemas tutores inteligentes pueden diseñarse para favorecer experiencias de éxito en los estudiantes mediante la adaptación pedagógica y la personalización del nivel de dificultad de las tareas (Adjei & Heffernan, 2015; Guzmán & Conejo, 2015; Maestro-Prieto & Simon-Hurtado, 2018; Papoušek & Pelánek, 2015).

3.4.3 Modelado de persuasión verbal

Dentro de esta categoría se identificaron 5 artículos relevantes, los cuales se presentan en la Tabla 3.3.

Grawemeyer et al. (2015) investigaron el impacto de siete tipos específicos de retroalimentación en los estados afectivos de los estudiantes durante tareas matemáticas. La investigación confirma la importancia de la retroalimentación para mejorar los estados afectivos y subraya la necesidad de adaptarla al estado afectivo del estudiante, particularmente cuando están confundidos, para ayudarles a transicionar a estados más positivos.

Holmes et al. (2015) investigaron el diseño de una retroalimentación efectiva y adaptativa, analizando su implementación a partir de dos dimensiones clave: su propósito, que depende de las necesidades específicas de la tarea del estudiante, y el nivel, que depende de sus necesidades cognitivas. Su investigación destaca la importancia del cómo se entrega la retroalimentación, planteando que su modalidad — interruptiva o no interruptiva— debe ajustarse a las necesidades del estudiante.

Espasa et al. (2022) encontraron que el canal de feedback no tuvo un impacto significativo en el rendimiento académico, aunque las percepciones y preferencias de los estudiantes varían según el canal; para aspectos de interacción y cercanía, prefirieron el canal de video.

Van Der Kleij et al. (2015) concluyeron que el feedback elaborado fue significativamente más efectivo que el feedback simple, especialmente para el desarrollo de habilidades de orden superior. Asimismo, encontraron que el nivel educativo y el momento en que se proporciona el feedback influyen directamente en su efectividad.

Tabla 3.3 Modelado de persuasión verbal

Nº	Título	Referencia	Descripción
1	<i>Affect Matters: Exploring the Impact of Feedback During Mathematical Tasks in an Exploratory Environment</i>	Grawemeyer et al. (2015)	Investiga cómo distintos tipos de retroalimentación verbal influyen en los estados afectivos de los estudiantes durante tareas matemáticas.
2	<i>Purpose and Level of Feedback in an Exploratory Learning Environment for Fractions</i>	Holmes et al. (2015)	Estudia el diseño de retroalimentación adaptativa a partir de dos dimensiones: su propósito según la tarea y su nivel según las necesidades cognitivas del estudiante.
3	<i>Does the type of feedback channel used in online learning environments matter? Students' perceptions and impact on learning</i>	Espasa et al. (2022)	Analiza el efecto de diferentes canales de feedback —texto, audio y video— en el rendimiento y las percepciones de los estudiantes.
4	<i>Effects of Feedback in a Computer-Based Learning Environment on Students' Learning Outcomes: A Meta-Analysis</i>	Van Der Kleij et al. (2015)	Concluye, mediante metaanálisis, que el feedback elaborado es más efectivo que el simple para el desarrollo de habilidades de orden superior.
5	<i>The effect of feedback type in the e-learning environment on students' achievement and motivation</i>	Al-Darei & Elhag (2022)	Analiza el efecto de diferentes tipos de feedback —confirmatorio, correctivo e interpretativo— en el aprendizaje y la motivación en entornos online.

Al-Darei y Elhag (2022) indican que el feedback interpretativo —que no solo informa si la respuesta es correcta y cuál es la correcta, sino que también explica su fundamento— es la estrategia más eficaz para mejorar tanto el aprendizaje como el interés de los estudiantes en un entorno virtual.

Los artículos de esta categoría demuestran cómo los sistemas tutores inteligentes pueden emplear diversas estrategias de retroalimentación y comunicación verbal para actuar como persuasores, influyendo en la autoeficacia de los estudiantes (Al-Darei & Elhag, 2022; Grawemeyer et al., 2015; Van Der Kleij et al., 2015).

3.4.4 Modelado de experiencias vicarias

Dentro de esta categoría se identificaron 3 artículos relevantes sobre experiencias vicarias, los cuales se presentan en la Tabla 3.4.

La revisión de la literatura sobre experiencias vicarias muestra que la observación de pares interactuando con sistemas tutores puede generar ganancias de aprendizaje significativas (Craig et al., 2004), que un modelo de habilidad moderada resulta más efectivo que uno consistentemente correcto para mantener la atención del observador (Mills et al., 2019), y que los diseños multiagente permiten modelar comportamientos y estrategias ideales, en particular para estudiantes con bajo conocimiento previo (Lippert et al., 2020).

Tabla 3.4 Modelado de experiencias vicarias

Nº	Título	Referencia	Descripción
1	<i>Reducing Mind-Wandering During Vicarious Learning from an Intelligent Tutoring System</i>	Mills et al. (2019)	Examina cómo la habilidad percibida del modelo observado influye en la atención del observador durante el aprendizaje vicario en un STI.
2	<i>Multiple Agent Designs in Conversational Intelligent Tutoring Systems</i>	Lippert et al. (2020)	Propone diseños multiagente en STI conversacionales donde los agentes interactúan entre sí como modelos de comportamiento para el estudiante.
3	<i>Constructing knowledge from dialog in an intelligent tutoring system: Interactive learning, vicarious learning, and pedagogical agents</i>	Craig et al. (2004)	Compara el aprendizaje interactivo con un tutor inteligente frente al aprendizaje vicario mediante la observación de la interacción de otros estudiantes.

3.5 Conclusiones de la revisión de la literatura

La revisión de la literatura no identificó estudios que integren de manera práctica más de una fuente de autoeficacia con el propósito explícito de adaptar el comportamiento del sistema educativo (Alqurashi, 2016; Hodges, 2008; Kookan et al., 2021; McQuiggan & Lester, 2006; McQuiggan et al., 2008; Shi et al., 2021; Zarrin & Montazer, 2019). Si bien algunos sistemas incorporan la autoeficacia como variable interna y la utilizan para orientar decisiones pedagógicas, ninguno la evalúa de forma aislada con el propósito explícito de clasificar al estudiante en perfiles adaptativos diferenciados.

El vacío identificado a lo largo de esta revisión puede caracterizarse en tres dimensiones. En primer lugar, ninguno de los sistemas analizados integra más de una fuente de autoeficacia con el propósito explícito de evaluar y fortalecer el nivel de autoeficacia del estudiante. En segundo lugar, los trabajos que sí incorporan modelado de autoeficacia —como los de McQuiggan y Lester (2006), McQuiggan et al. (2008), Zarrin y Montazer (2019) y Shi et al. (2021)— modelan la autoeficacia en combinación con otras variables como el estilo de aprendizaje, la motivación o el dominio del contenido, y ninguno la evalúa de manera aislada para clasificar al estudiante en perfiles adaptativos basados exclusivamente en su nivel de autoeficacia. En tercer lugar, el sistema más cercano al dominio de interés, el ambiente inteligente SIAL (Maestro-Prieto & Simon-Hurtado, 2018), enseña lógica de primer orden con capacidades de diagnóstico de errores, pero no incorpora componente alguno de modelado de autoeficacia ni adaptación afectiva.

MateLog ocupa este espacio no explorado. A diferencia de los trabajos revisados, el sistema integra dos fuentes de autoeficacia —las experiencias de éxito y la persuasión verbal— dentro de un ambiente inteligente de aprendizaje, con el propósito explícito de identificar el nivel de autoeficacia del estudiante y adaptar la respuesta del sistema en consecuencia. Para ello, MateLog incorpora un Modelo de Autoeficacia (MA) compuesto por dos submodelos: el Modelo de Autoeficacia del Estudiante (MAE), que clasifica al estudiante en función de su nivel de autoeficacia y su rendimiento académico, y el Modelo de Adaptación de Respuesta (MAR), que determina la intervención pedagógica adecuada para cada perfil identificado.

En cuanto al dominio, MateLog se enfoca en la simbolización de proposiciones lógicas en educación media superior. Ninguno de los sistemas revisados en las categorías de modelado de experiencias de éxito y de persuasión verbal aborda este contenido ni esta población, lo que amplía la originalidad de la propuesta más allá del componente de autoeficacia.

La aportación diferencial de MateLog respecto a la literatura revisada no reside en un rasgo aislado, sino en la confluencia de factores que los trabajos analizados mantienen siempre dissociados. Mientras que los sistemas existentes modelan la autoeficacia de manera fragmentaria y sin propósito evaluativo explícito, MateLog articula dos fuentes dentro de un mismo ambiente y vincula esa evaluación con una respuesta adaptativa diferenciada por perfil del estudiante. Que este diseño se aplique además a la simbolización de proposiciones lógicas en educación media superior — dominio que ninguno de los sistemas revisados aborda desde una perspectiva de autoeficacia— acentúa su originalidad y delimita con precisión el espacio que la propuesta ocupa en la literatura revisada.

Capítulo 4. Modelo de Autoeficacia

El Modelo de Autoeficacia tiene como función clasificar a los estudiantes en perfiles específicos y determinar, en función de esa clasificación, las intervenciones pedagógicas que el sistema debe ejecutar. Su diseño se fundamenta en la teoría de la autoeficacia de Albert Bandura, la cual sostiene que la percepción que tiene el individuo sobre su propia capacidad influye de manera decisiva en su desempeño y en la persistencia frente a los retos.

Para comprender la lógica del modelo es necesario partir de una consideración teórica central: la autoeficacia medida mediante la Escala de Autoeficacia General es independiente del dominio y, por tanto, apropiada para un contenido nuevo como la lógica matemática, pero esa medición no es suficiente, por sí sola, para orientar la adaptación. Bandura (1977) advierte que las creencias de eficacia pueden estar descalibradas respecto a las capacidades reales del individuo, dando lugar tanto a la sobreestimación como a la subestimación de las propias posibilidades (Flammer, 1995). En consecuencia, un estudiante puede declarar autoeficacia alta y desempeñarse por debajo de lo esperado, o bien declarar autoeficacia baja y obtener un buen rendimiento. Un sistema que adapte sus intervenciones únicamente a partir de la autoeficacia declarada ignoraría precisamente estos casos, que son pedagógicamente los más complejos. Por esta razón, el modelo combina la dimensión de autoeficacia con una dimensión de rendimiento para generar perfiles que distinguen situaciones de coincidencia —donde la confianza declarada y el desempeño observado se alinean— de situaciones de discrepancia, que requieren intervenciones diferenciadas.

El modelo se articula en dos componentes principales, cuya estructura general se presenta en la Figura 4.1. El Modelo de Autoeficacia del Estudiante (MAE) se encarga de identificar el perfil correspondiente a partir de ambas dimensiones. El Modelo de Adaptación de Respuesta (MAR)

interpreta ese perfil y lo convierte en intervenciones pedagógicas concretas. En conjunto, ambos componentes activan la lógica adaptativa orientada a sostener la motivación del estudiante y prevenir la disminución de su autoeficacia.




Figura 4.1 Estructura del Modelo de Autoeficacia

4.1 Modelo de Autoeficacia del Estudiante

El Modelo de Autoeficacia del Estudiante tiene como propósito establecer el perfil de cada estudiante mediante la combinación de dos fuentes de información: su nivel de autoeficacia, obtenido a partir de la Escala de Autoeficacia General, y su nivel de rendimiento, inferido a partir del desempeño en los ejercicios del curso. La combinación de ambas dimensiones genera cuatro perfiles adaptativos, que constituyen la entrada para el componente de respuesta. Combinar ambas dimensiones —y no operar únicamente con la autoeficacia declarada— es lo que permite distinguir perfiles concordantes de perfiles de discrepancia y adaptar la intervención en consecuencia.

4.1.1 Selección del instrumento de medición

Las escalas de autoinforme son el instrumento principal para medir la autoeficacia (Bandura, 2006). La selección de una escala adecuada es una decisión relevante para el modelo, ya que de ella depende la validez de la clasificación inicial del estudiante y, por extensión, la pertinencia de las acciones adaptativas posteriores.

Para el presente trabajo se analizaron distintos tipos de escalas en función del dominio de aplicación: la lógica matemática. La Tabla 4.1 resume el análisis comparativo de los instrumentos considerados. Se determinó que las escalas altamente específicas, como las orientadas al dominio matemático o académico general, resultaban inadecuadas para este contexto por dos razones principales. En primer lugar, la lógica matemática constituye un campo nuevo para la mayoría de los estudiantes de preparatoria, quienes la tienden a asociar erróneamente con la aritmética o el álgebra, lo que podría introducir un sesgo sistemático en sus respuestas. En segundo lugar, las escalas de autoeficacia académica evalúan la confianza en contextos escolares estrechamente vinculados a las experiencias previas del estudiante (García-Fernández et al., 2016), lo cual añadiría una varianza irrelevante a los datos al tratarse de una tarea fundamentalmente novedosa.

Tabla 4.1 *Análisis comparativo de instrumentos de medición de autoeficacia*

Instrumento	Especificidad	Limitación	Considerado
Escalas específicas de matemáticas	Alta (dominio matemático)	Sesgo por asociación con aritmética o álgebra en un dominio nuevo	No
Escalas de autoeficacia académica	Media (contexto escolar)	Varianza irrelevante asociada a experiencias escolares previas	No
Escala de Autoeficacia General	Baja (dominio independiente)	Ninguna relevante para este estudio	Sí

Con base en este análisis, se concluyó que la Escala de Autoeficacia General (GSE, por sus siglas en inglés) de Baessler y Schwarzer (1996), en su adaptación al español por Sanjuán Suárez et al. (2000), constituía la opción

más apropiada. Este instrumento evalúa la creencia global y estable del individuo en su capacidad para afrontar retos, estresores y situaciones imprevistas de manera independiente del dominio (Sanjuán Suárez et al., 2000), característica que la hace idónea para medir la confianza ante un contenido con el que los participantes no tienen familiaridad previa.

4.1.2 Nivel de autoeficacia

Para identificar el nivel de autoeficacia se utilizó la versión en español de la Escala de Autoeficacia General, que consta de 10 ítems con un formato de respuesta tipo Likert de cuatro puntos (Baessler & Schwarzer, 1996), como se muestra en la Tabla 4.2. Las respuestas se codifican numéricamente en un rango de 0 a 3: 0 corresponde a "Nunca", 1 a "Algunas veces", 2 a "Muchas veces" y 3 a "Siempre". Este procedimiento permite cuantificar el resultado total y clasificar el nivel de autoeficacia dentro de un rango de 0 a 30, que representan los valores mínimo y máximo posibles.

Tabla 4.2 *Escala General de Autoeficacia, en idioma español (Sanjuán Suárez et al., 2000)*

Ítem	Nunca (0)	Algunas veces (1)	Muchas veces (2)	Siempre (3)
1. Puedo encontrar la manera de obtener lo que quiero aunque alguien se me oponga				
2. Puedo resolver problemas difíciles si me esfuerzo lo suficiente				
3. Me es fácil persistir en lo que me he propuesto hasta llegar a alcanzar mis metas				
4. Tengo confianza en que podría manejar eficazmente acontecimientos inesperados				
5. Gracias a mis cualidades y recursos puedo superar situaciones imprevistas				
6. Cuando me encuentro en dificultades puedo permanecer tranquilo/a porque cuento con las habilidades necesarias para manejar situaciones difíciles				
7. Venga lo que venga, por lo general soy capaz de manejarlo				
8. Puedo resolver la mayoría de los problemas si me esfuerzo lo necesario				
9. Si me encuentro en una situación difícil, generalmente se me ocurre qué debo hacer				
10. Al tener que hacer frente a un problema, generalmente se me ocurren varias alternativas de cómo resolverlo				

Tabla 4.3 Definición del nivel de autoeficacia

Nivel	Criterio (puntaje Escala General de Autoeficacia)	Caracterización conductual
AE Baja	0 – 15 puntos	Mayor riesgo de abandono ante la dificultad; tendencia a subestimar las propias capacidades
AE Alta	16 – 30 puntos	Mayor persistencia ante obstáculos; tendencia a elegir tareas desafiantes

4.1.3 Rendimiento Académico

Para diagnosticar el rendimiento, el Tema 1 se muestra de manera idéntica a todos los estudiantes, independientemente de su grupo, con los ejercicios de mayor dificultad disponibles. Esta decisión responde a la naturaleza diagnóstica del tema: presentar ejercicios difíciles a todos permite obtener la mayor cantidad de información sobre el desempeño real de cada estudiante antes de activar la adaptación. Si el estudiante aprueba el Tema 1 con dos intentos o menos, se le asigna un rendimiento alto; si necesita más de dos intentos, su rendimiento se considera bajo. La Tabla 4.4 presenta los niveles de rendimiento académico y sus criterios de diagnóstico.

Tabla 4.4 Nivel de rendimiento académico

Nivel	Criterio (intentos en el Tema 1)	Diagnóstico
Rendimiento Alto	2 intentos o menos	El estudiante aprueba el Tema 1 en los primeros dos intentos a pesar de tener los ejercicios en modalidad difícil
Rendimiento Bajo	Más de 2 intentos	El estudiante necesita múltiples intentos para aprobar el Tema 1 en modalidad difícil

4.1.4 Perfiles del estudiante

El perfil del estudiante se obtiene de la combinación del nivel de autoeficacia y del nivel de rendimiento en el Tema 1, lo que da lugar a cuatro perfiles, que se presentan en la Tabla 4.5. El nivel de autoeficacia se asigna al completar la escala y se mantiene fijo durante toda la lección. En cambio, el nivel de rendimiento se actualiza al término de cada tema, según la cantidad de intentos que el estudiante necesite para aprobar los ejercicios,

de modo que el perfil responde a cambios en su desempeño a lo largo del curso.

Tabla 4.5 *Perfiles del Modelo de Autoeficacia del Estudiante*

	Rendimiento Bajo (más de dos intentos en el Tema 1)	Rendimiento Alto (dos intentos o menos en el Tema 1)
Autoeficacia Baja (0 – 15)	BAJA_B	BAJA_A
Autoeficacia Alta (16 – 30)	ALTA_B	ALTA_A

A partir del Tema 2, el nivel de rendimiento deja de ser un diagnóstico fijo y pasa a recalcularse al término de cada tema en función del número de intentos que el estudiante necesita para aprobarlo. El umbral que separa el rendimiento alto del bajo no es, sin embargo, idéntico para todos: depende del nivel de autoeficacia del estudiante. La Tabla 4.6 formaliza las reglas de clasificación aplicadas en el Tema 1 y las reglas de actualización que rigen desde el Tema 2 hasta el Tema 5, incluyendo el umbral diferenciado por nivel de autoeficacia.

Tabla 4.6 *Reglas de clasificación y actualización del perfil por tema*

Momento	Nivel de AE (fijo)	Umbral: Rendimiento Alto	Umbral: Rendimiento Bajo	Perfil resultante
Al completar el Tema 1 (clasificación inicial)	AE Alta (16 – 30)	≤ 2 intentos	> 2 intentos	AE_ALTA_A o AE_ALTA_B
Al completar el Tema 1 (clasificación inicial)	AE Baja (0 – 15)	≤ 2 intentos	> 2 intentos	AE_BAJA_A o AE_BAJA_B
Al completar los Tems 2–5 (actualización)	AE Alta (16 – 30)	≤ 2 intentos	> 2 intentos	AE_ALTA_A o AE_ALTA_B
Al completar los Tems 2–5 (actualización)	AE Baja (0 – 15)	≤ 3 intentos	> 3 intentos	AE_BAJA_A o AE_BAJA_B

El nivel de autoeficacia permanece fijo durante todo el curso; solo el nivel de rendimiento varía tema a tema. En el Tema 1 los umbrales son idénticos para ambos niveles de autoeficacia, pues el propósito es diagnóstico. La diferenciación en el umbral de rendimiento comienza a partir del Tema 2.

El umbral diferenciado para los perfiles de autoeficacia baja responde a un principio de apoyo gradual derivado de la teoría de autoeficacia. Conceder un intento adicional a los estudiantes con autoeficacia baja antes de clasificarlos como de bajo rendimiento les otorga un margen mayor para demostrar lo que son capaces de lograr, reconociendo que tienden a subestimar sus propias capacidades (Flammer, 1995) y que son más vulnerables a interpretar el fracaso reiterado como una confirmación de su incapacidad, lo que puede acelerar el desánimo ante la dificultad (Bandura, 1995). Para los estudiantes con autoeficacia alta, en cambio, se conserva el umbral más estricto de dos intentos, coherente con su mayor disposición a persistir y a enfrentar tareas desafiantes (Bandura, 1977): mantener una exigencia más alta evita subestimar su capacidad real y preserva el valor del reto como sostén de su motivación.

Es importante distinguir este umbral de clasificación —que determina si el rendimiento en un tema es alto o bajo y, por tanto, qué perfil se asigna— de los umbrales que activan las intervenciones del Modelo de Adaptación de Respuesta, como la retroalimentación guiada o la opción de rescate. La Figura 4.2 ilustra este algoritmo de clasificación basado en reglas —consistente con las técnicas de Inteligencia Artificial que caracterizan a los Ambientes Inteligentes de Aprendizaje (Sección 2.1)— aplicado a partir de las dos variables de entrada.




Figura 4.2 Asignación de perfiles adaptativos del Modelo de Autoeficacia del Estudiante.

Nota: la letra "T" significa Tema, y la letra "i" significa intento.

4.2 Modelo de Adaptación de Respuesta

El Modelo de Adaptación de Respuesta convierte el perfil asignado por el Modelo de Autoeficacia del Estudiante en intervenciones pedagógicas concretas, a partir del Tema 2. Estas intervenciones se organizan en dos dimensiones: la configuración de la dificultad de los ejercicios y la respuesta al desempeño.

4.2.1 Fuentes de autoeficacia implementadas

El diseño de las intervenciones del Modelo de Adaptación de Respuesta está determinado por las fuentes de autoeficacia que el modelo operacionaliza. De las cuatro fuentes identificadas por Bandura (1977) y descritas en la Sección 2.2.2, la selección debía atender simultáneamente dos criterios: la magnitud del efecto reportado en la literatura y la factibilidad de su incorporación en un sistema web de aprendizaje individual. La Tabla 4.7 sintetiza el análisis efectuado sobre las cuatro fuentes.

Tabla 4.7 *Análisis de fuentes de autoeficacia para su integración en el Modelo de Autoeficacia*

Fuente de autoeficacia (Bandura, 1977)	Efecto sobre AE	Compatibilidad con el proyecto	Implementación en el MA	Decisión
Experiencias de éxito	Muy alto	Alta	Configuración adaptativa del nivel de dificultad	Incluida
Persuasión verbal	Alto	Alta	Retroalimentación pedagógica y mensajes de apoyo	Incluida
Experiencias vicarias	Moderado	Baja	Requiere módulo colaborativo o modelado social	Excluida
Estados fisiológicos y afectivos	Moderado	Baja	Requiere sensores biométricos o autorreporte continuo	Excluida

La primera fuente integrada corresponde a las experiencias de éxito, considerada la más influyente sobre las creencias de autoeficacia (Bandura et al., 1999). Su inclusión resulta esencial, ya que un sistema capaz de modular la dificultad de los ejercicios puede favorecer la acumulación de logros reales en estudiantes con baja autoeficacia, evitando la frustración temprana (Bandura, 1995), y, al mismo tiempo, ofrecer retos suficientes a quienes presentan alta autoeficacia para sostener su interés y prevenir el aburrimiento (Bandura, 1986; Malone & Lepper, 1987). La segunda fuente integrada es la persuasión verbal, que se implementa mediante mensajes de apoyo y retroalimentación diferenciada según el perfil del usuario. Estos mensajes, que simulan provenir de una fuente creíble como un tutor o instructor, se entregan en momentos clave del recorrido para reforzar la confianza (Schunk, 1989), como al concluir un ejercicio, al enfrentar un reintento o al finalizar un tema.

Las experiencias vicarias y los estados fisiológicos y afectivos, aunque relevantes desde el punto de vista teórico (Bandura, 1977), se consideraron de difícil implementación en un sistema web de aprendizaje individual. Incorporar las experiencias vicarias requeriría módulos colaborativos o de modelado social que van más allá del alcance de este trabajo (Craig et al., 2004), mientras que la medición de los estados fisiológicos implicaría el uso

de sensores biométricos o instrumentos de autorreporte constante, lo cual resultaría intrusivo e interrumpiría negativamente la experiencia del usuario (McQuiggan et al., 2008). Por tanto, ambas fuentes fueron excluidas de la implementación. La operacionalización de las fuentes seleccionadas se especifica en las secciones siguientes.

4.2.2 Configuración de la dificultad

La primera dimensión, configuración de la dificultad, define el nivel inicial de dificultad de los ejercicios según el nivel de autoeficacia del perfil: los estudiantes con autoeficacia alta reciben ejercicios difíciles y los de autoeficacia baja reciben ejercicios fáciles. De este modo, quienes presentan baja autoeficacia tienen mayor oportunidad de acumular experiencias de éxito que fortalezcan su confianza, mientras que quienes tienen alta autoeficacia enfrentan retos que sostienen su interés.

Una vez asignado, el nivel de dificultad de los ejercicios permanece fijo durante el curso. No obstante, existen dos alternativas que pueden habilitarse en situaciones específicas y que el estudiante puede aceptar cuando se encuentren disponibles.

La primera es la opción de rescate, exclusiva para el perfil de alta autoeficacia con bajo rendimiento. Esta opción consiste en cambiar los ejercicios a nivel fácil si el estudiante la acepta tras acumular tres intentos no aprobados —entendidos como las ocasiones en que responde la sección de ejercicios y, al no alcanzar el porcentaje mínimo requerido, debe repetirla—. Esta alternativa cumple dos funciones: si el estudiante la acepta, se evita la frustración derivada de no aprobar los ejercicios de nivel difícil; si decide no aceptarla, se confirma que se considera capaz de enfrentar el reto.

La segunda alternativa es la opción de reto, dirigida a estudiantes con perfil de baja autoeficacia con alto rendimiento. Su propósito es ofrecer la oportunidad de resolver ejercicios de nivel difícil, aun cuando no estén obligados a hacerlo. En caso de que acepten y completen todos los ejercicios, el estudiante recibe un emoji de medalla como reconocimiento; si además logran aprobar, el reconocimiento es un emoji de trofeo. De esta

manera se registra el rendimiento frente al aumento de dificultad y, si los resultados son favorables, se favorece un incremento en la confianza del estudiante. La Tabla 4.8 presenta la relación de los perfiles con el nivel de dificultad asignado y las opciones adaptativas disponibles en cada caso.

Tabla 4.8 *Perfiles y condiciones de dificultad de los ejercicios*

Perfil	Nivel de dificultad asignado	Alternativa	Momento de activación	Efecto
AE_ALTA_A	Difícil	—	—	—
AE_ALTA_B	Difícil	Rescate	A partir del Tema 2, al no aprobar un tema en menos de tres intentos	Cambia los ejercicios a nivel fácil para ese tema; el estudiante debe aprobar los ejercicios fáciles para desbloquear el siguiente tema
AE_BAJA_A	Fácil	Reto	A partir del Tema 2, cuando aprueba un tema	Ofrece ejercicios de nivel difícil; si los completa recibe un emoji de medalla y si los aprueba recibe un emoji de trofeo
AE_BAJA_B	Fácil	—	—	—

4.2.3 Respuesta al desempeño

La segunda dimensión, respuesta al desempeño, agrupa las intervenciones que el sistema emite en reacción al rendimiento del estudiante durante la sesión. Se compone de dos mecanismos estructurales: la retroalimentación inmediata y la retroalimentación guiada.

La retroalimentación inmediata se entrega al concluir cada ejercicio y su contenido varía según el perfil y el resultado del reactivo. Los estudiantes con autoeficacia baja reciben una explicación del porqué de la respuesta —correcta o incorrecta—, ya que la atribución explícita del resultado al esfuerzo o al razonamiento es consistente con la función de la persuasión verbal para fortalecer la confianza en quienes tienden a subestimar sus capacidades (Schunk, 1989). Los estudiantes con autoeficacia alta reciben únicamente la indicación de acierto o fallo, sin explicación adicional, coherente con su mayor capacidad para sostener la motivación de forma autónoma; con la excepción del perfil AE_ALTA_A, que además visualiza un

contador acumulado de aciertos consecutivos como refuerzo de la experiencia de éxito. La Tabla 4.9 especifica la retroalimentación inmediata por perfil y resultado.

Tabla 4.9 *Retroalimentación inmediata por perfil y resultado*

Perfil	Respuesta correcta	Respuesta incorrecta
AE_ALTA_A	Símbolo "✓" acumulado por aciertos consecutivos (✓✓ · ✓✓✓ · ✓✓✓✓ ...)	Texto "Respuesta incorrecta"
AE_ALTA_B	Símbolo "✓" en cada acierto	Texto "Respuesta incorrecta"
AE_BAJA_A	Explicación de por qué la respuesta es correcta	Explicación del error cometido y mensaje de apoyo que refuerza la constancia
AE_BAJA_B	Explicación de por qué la respuesta es correcta	Explicación del error cometido y mensaje de apoyo que normaliza la dificultad

La retroalimentación guiada opera como un nivel adicional de apoyo que se activa cuando el número de intentos no aprobados en un tema supera el umbral definido para cada perfil. A diferencia del botón de ayuda estándar, que requiere acción del estudiante, esta intervención aparece de forma automática en los ejercicios que fueron respondidos de forma incorrecta en el intento anterior, sin que el estudiante deba solicitarla. Al finalizar la ronda y antes de comenzar la siguiente, el sistema ofrece además la opción de consultar ejemplos adicionales directamente relacionados con los ejercicios fallados. La graduación de los umbrales por perfil responde al principio de apoyo diferenciado: los perfiles con mayor vulnerabilidad al desánimo reciben la intervención antes, mientras que el perfil AE_ALTA_A, cuya autoeficacia y rendimiento se alinean positivamente, no la recibe. La Tabla 4.10 especifica los umbrales y recursos de la retroalimentación guiada por perfil.

Cuando varias condiciones de activación se cumplen de manera simultánea en un mismo momento del recorrido, el sistema aplica las intervenciones en el siguiente orden de prioridad. En primer lugar, la retroalimentación inmediata por resultado se emite al concluir cada

ejercicio y no puede ser postergada; constituye la respuesta base del sistema ante cualquier interacción con un reactivo.

En segundo lugar, la retroalimentación guiada, cuando el umbral del perfil ha sido superado, aparece de forma automática en los ejercicios fallados del intento anterior al iniciar la nueva ronda, sin que el estudiante deba solicitarla; esta intervención no interrumpe ni reemplaza la retroalimentación ya entregada.

En tercer lugar, los mensajes de apoyo entre intentos se despliegan al iniciar una nueva ronda o al concluir un tema, y ceden precedencia a las opciones de rescate o reto cuando estas también se encuentran disponibles para el perfil correspondiente. En cuarto y último lugar, las opciones de rescate y reto se presentan en el momento específico definido para cada perfil —tras tres intentos no aprobados para el perfil AE_ALTA_B y al aprobar un tema para el perfil AE_BAJA_A— y se activan una sola vez por tema sin interrumpir las intervenciones previamente entregadas.

Tabla 4.10 *Retroalimentación guiada (andamiaje pedagógico) por perfil*

Perfil	Momento de activación	Recurso 1: Pista contextual	Recurso 2: Ejemplo adicional
AE_ALTA_A	No se activa	—	—
AE_ALTA_B	A partir del intento 4	Texto de ayuda visible en pantalla en los ejercicios incorrectos del intento anterior, sin necesidad de dar clic en el botón de ayuda	Opción para ver ejemplos vinculados a los ejercicios no aprobados en el último intento
AE_BAJA_A	A partir del intento 3	Texto de ayuda visible en pantalla en los ejercicios incorrectos del intento anterior, sin necesidad de dar clic en el botón de ayuda	Opción para ver ejemplos vinculados a los ejercicios no aprobados en el último intento
AE_BAJA_B	A partir del intento 2	Texto de ayuda visible en pantalla en los ejercicios incorrectos del intento anterior, sin necesidad de dar clic en el botón de ayuda	Opción para ver ejemplos vinculados a los ejercicios no aprobados en el último intento

4.2.4 Intervención por perfil

Los cuatro perfiles difieren en el tipo de intervención que requieren según el grado de alineación entre autoeficacia y rendimiento. Los perfiles concordantes —AE_ALTA_A y AE_BAJA_B— se caracterizan porque la confianza declarada coincide con el rendimiento observado: alta autoeficacia con alto desempeño, y baja autoeficacia con bajo desempeño. Los perfiles de discrepancia —AE_ALTA_B y AE_BAJA_A— reflejan un desajuste entre confianza y rendimiento que, sin una intervención adaptativa, podría agravarse: en un caso por acumulación de errores no anticipados, en el otro por desinterés ante logros que el estudiante no reconoce como propios. La Tabla 4.11 presenta la clasificación de perfiles, el tipo de intervención que corresponde a cada uno y su fundamento en la teoría de Bandura.

Tabla 4.11 *Clasificación de perfiles y tipo de intervención*

Tipo de perfil	Perfil	Tipo de intervención	Fundamento (Bandura)
Concordante	Alta autoeficacia con alto rendimiento	Motivador: retos continuos y reconocimiento de logros	Refuerzo de experiencias de éxito para sostener el nivel de autoeficacia
Concordante	Baja autoeficacia con bajo rendimiento	Constructivo: construcción de confianza mediante logros accesibles y apoyo constante	Persuasión verbal normalizadora del error; reducción de la amenaza percibida ante la dificultad
De discrepancia	Alta autoeficacia con bajo rendimiento	Reflexivo: opción de rescate acompañada de mensajes reflexivos; si el estudiante acepta, los ejercicios se ajustan a nivel fácil para reducir la frustración; si no acepta, se confirma que se considera capaz de enfrentar el reto	Persuasión verbal orientada a la reflexión metacognitiva; prevención de la erosión de autoeficacia por acumulación de errores
De discrepancia	Baja autoeficacia con alto rendimiento	Alentador: ejercicios de nivel fácil para acumular éxitos; opción de reto como evidencia de capacidad para que el estudiante reconozca y valore su propia habilidad	Persuasión verbal para corregir calibración negativa; atribución del éxito al esfuerzo y la capacidad propia

Los mensajes que operacionalizan la persuasión verbal en cada perfil fueron diseñados siguiendo los criterios derivados del marco teórico: retroalimentación frecuente y específica que atribuya los logros al esfuerzo para perfiles de autoeficacia baja, y mensajes orientados a la reflexión y la autonomía para perfiles de autoeficacia alta (Schunk, 1989; Bandura, 1995). En el diseño de materiales instruccionales para Ambientes Inteligentes de Aprendizaje, el rigor del modelo no recae en la autoría externa de los contenidos, sino en la trazabilidad de las decisiones de diseño hacia un marco teórico documentado (Murray, 1999; Woolf, 2009). La diferenciación sistemática de mensajes por perfil —en contenido, tono y momento de activación— constituye la evidencia de que el diseño respondió a criterios pedagógicos explícitos.

Los mensajes de intervención se presentan al estudiante en dos modalidades según el momento de activación. Los mensajes generales aparecen ante respuestas incorrectas durante la sesión de ejercicios y aplican exclusivamente a los perfiles de autoeficacia baja, que son los que reciben retroalimentación explicativa según lo establecido en la Tabla 4.7.

Tabla 4.12 *Mensajes de apoyo generales por perfil ante respuesta incorrecta*

Aparición	Perfil AE_BAJA_B (Constructivo)	Perfil AE_BAJA_A (Alentador)
1.ª respuesta incorrecta	"Es común que estos conceptos resulten confusos al principio."	"Tu dedicación constante se refleja claramente en tu proceso de aprendizaje."
3.ª respuesta incorrecta	"Es completamente normal tener dudas o equivocarse durante el aprendizaje."	"Tu constancia es clave para llegar a dominar estos conceptos paso a paso."
5.ª respuesta incorrecta	"Este tipo de ejercicios son desafiantes."	"Cada intento que realizas demuestra tu gran compromiso por entender el tema."
7.ª respuesta incorrecta	"Los detalles lógicos son fáciles de pasar por alto."	"Mantienes una muy buena actitud frente a la dificultad de este tema."
9.ª respuesta incorrecta	"Es muy común equivocarse frente a un tema nuevo."	"Tu determinación te está llevando a familiarizarte cada vez mejor con este lenguaje."

Su contenido se ajusta al tipo de intervención del perfil: para el perfil AE_BAJA_B el tono es constructivo, orientado a normalizar el error y reducir la amenaza percibida; para el perfil AE_BAJA_A el tono es alentador,

orientado a reforzar la percepción de capacidad y atribuir el esfuerzo al desempeño. La Tabla 4.12 presenta los mensajes generales por perfil y el orden de aparición durante la sesión.

Los mensajes por condición específica se activan ante comportamientos concretos del estudiante durante la sesión —como el tiempo transcurrido entre la teoría y los ejercicios, el resultado porcentual de un intento no aprobado o la paridad del número de intento, criterio que permite alternar los mensajes entre intentos consecutivos y evitar que el estudiante reciba el mismo tipo de comunicación de forma reiterada— y se aplican a los perfiles AE_ALTA_B, AE_BAJA_A y AE_BAJA_B. En estos casos el sistema dispone de información conductual suficiente para ajustar el mensaje al momento preciso en que el estudiante lo necesita. La Tabla 4.13 presenta los mensajes por condición específica, con su tipo de intervención correspondiente.

Tabla 4.13 *Mensajes de apoyo por condición específica*

Perfil	Condición	Mensaje	Tipo
AE_ALTA_B	Pasa del inicio de la sección de teoría a los ejercicios en menos de 30 segundos	"Antes de continuar, te recomendamos repasar los conceptos clave del tema. Un repaso breve puede marcar una gran diferencia."	Reflexivo
AE_BAJA_A	Intento no aprobado con calificación mayor a 60%	"¡Tu desempeño es mejor de lo que crees! Confía en tu capacidad — estás avanzando muy bien."	Alentador
AE_BAJA_A	Intento no aprobado con calificación menor a 60%	"Nota que repasar la teoría y los ejemplos antes de volver a intentarlo puede ayudarte a mejorar tus resultados. ¡Tómate tu tiempo!"	Alentador
AE_BAJA_B	Intento impar no aprobado	"Antes de continuar, te recomendamos repasar los conceptos clave del tema. Un repaso breve puede marcar una gran diferencia."	Constructivo
AE_BAJA_B	Intento par no aprobado	"¡Tu desempeño es mejor de lo que crees! Confía en tu capacidad — estás avanzando muy bien."	Constructivo

El mensaje "Antes de continuar, te recomendamos repasar los conceptos clave del tema. Un repaso breve puede marcar una gran diferencia." aparece tanto en el perfil AE_ALTA_B como en el AE_BAJA_B para intentos impares no aprobados. Esta coincidencia es intencional y no representa una omisión de diferenciación por perfil: en ambos casos la conducta detectada —no aprobar los ejercicios tras revisar el contenido de forma insuficiente— es la misma, e independientemente del nivel de autoeficacia del estudiante, la intervención apropiada es idéntica: redirigir hacia el material teórico antes de reintentar. La intervención no busca modificar la autoeficacia en ese momento, sino corregir una conducta de estudio que, de mantenerse, podría erosionarla. La uniformidad del mensaje responde, por tanto, a la uniformidad de la conducta detectada.

4.3 Especificación de parámetros operativos

Las secciones anteriores definieron los componentes del modelo y sus reglas de operación, pero dejaron pendientes tres parámetros cuyos valores específicos solo pueden establecerse en función del comportamiento real de los estudiantes de la población objetivo: el umbral sobre el puntaje de la escala que distingue autoeficacia alta de baja, el umbral sobre el número de intentos en el Tema 1 que distingue rendimiento alto de bajo, y la asignación de cada ejercicio a uno de los dos niveles de dificultad —fácil o difícil—. Fijar estos parámetros con anterioridad al estudio habría implicado operar sobre supuestos no verificados, con el riesgo de introducir un sesgo en la asignación de perfiles y en las condiciones de la intervención.

Con este propósito se llevó a cabo una recopilación de datos preliminares con 61 estudiantes del plantel Cetis 12 que completaron el cuestionario de autoeficacia y participaron activamente en MateLog sin el Modelo de Autoeficacia activo. El análisis de estos datos permitió confirmar el valor específico que cada parámetro debía tomar en el contexto particular del estudio. La Tabla 4.14 muestra los parámetros que requerían especificación, el método de análisis empleado, el patrón observado en los datos y el valor finalmente adoptado.

Tabla 4.14 Datos preliminares utilizados para la configuración de las condiciones experimentales

Parámetro del MAE	Método de análisis	Resultado observado	Valor fijado
Umbral de clasificación de autoeficacia	Distribución de puntajes de la escala de autoeficacia general (n = 61)	47% de estudiantes obtuvo entre 0 y 15 puntos, y 53% obtuvo de 16 a 30 puntos (distribución equilibrada)	Autoeficacia Baja: 0–15; Autoeficacia Alta: 16–30
Umbral de reintentos en el Tema 1	Análisis de intentos con umbral variable	El umbral de 2 intentos es el punto donde la acumulación de aprobados cae de forma drástica y sostenida	Rendimiento Alto: 2 intentos o menos; Rendimiento Bajo: más de 2 intentos
Nivel de dificultad de los ejercicios	Análisis de tasa de acierto global por ejercicio	Los ejercicios con mayor cantidad de respuestas incorrectas corresponden a mayor dificultad que los de menor registro de respuestas incorrectas	Fácil: tasa de acierto alta; Difícil: tasa de acierto baja

La Figura 4.3 presenta la distribución de puntajes obtenidos por los estudiantes en la Escala de Autoeficacia General aplicada como cuestionario previo al inicio del curso. El histograma muestra que los puntajes se concentran principalmente en el rango de 8 a 25 puntos, con una acumulación notable alrededor del umbral de corte. El punto de mayor frecuencia se ubica en el puntaje 15 con 9 estudiantes, precisamente en el límite entre ambos grupos, lo que evidencia que el umbral 15/16 captura la zona de mayor densidad de la distribución. La gráfica circular confirma una distribución cercana al equilibrio: 29 estudiantes (47.5%) obtuvieron puntajes de 0 a 15, clasificados como autoeficacia baja, frente a 32 estudiantes (52.5%) con puntajes de 16 a 30, clasificados como autoeficacia alta.




Figura 4.3 Distribución de puntajes de la escala general de autoeficacia y clasificación por nivel de autoeficacia

La Figura 4.4 muestra la distribución de intentos realizados por los estudiantes en el Tema 1. Los intentos 1 y 2 concentran el mayor número de estudiantes que aprobaron el tema (13 y 12 respectivamente), seguidos de una caída abrupta al intento 3 (4 estudiantes). A partir del intento 4 la frecuencia se dispersa en un rango amplio que se extiende hasta 14 intentos, con valores que oscilan entre 1 y 10 estudiantes por intento (véase Figura 4.4). Este patrón confirma que el umbral de 2 intentos constituye el punto donde la acumulación de aprobados cae de forma drástica y sostenida, separando naturalmente a quienes resolvieron el tema con fluidez de quienes requirieron reintentos reiterados.




Figura 4.4 Distribución de intentos en el Tema 1

Adicionalmente, a las condiciones ya descritas, se optó por habilitar un botón de finalización anticipada a partir del Tema 3. Dado que la distribución de intentos en el Tema 1 mostró que un subconjunto de estudiantes requirió hasta 14 intentos para aprobar un solo tema (véase Figura 4.4), se anticipó que estos estudiantes podrían no completar el curso dentro del tiempo de sesión asignado. El botón ofreció una salida voluntaria y no frustrante para quienes, habiendo cubierto el contenido de los primeros dos temas, no lograran continuar al ritmo requerido.

Capítulo 5. MateLog

Este capítulo describe el proceso de construcción e integración del Modelo de Autoeficacia en MateLog. Se organiza en tres secciones: la arquitectura del sistema, que establece la ubicación de los componentes del modelo dentro de la plataforma; la actualización de MateLog, que describe las modificaciones realizadas sobre la versión previa de la plataforma (Mendoza, 2023) para cubrir los requerimientos del presente proyecto; y la integración del Modelo de Autoeficacia, que detalla cómo se incorporó el modelo a la plataforma y cómo opera en condiciones reales.

5.1 Arquitectura del Ambiente Inteligente de Aprendizaje

Para que el Modelo de Autoeficacia opere de manera coherente dentro de MateLog, cada uno de sus componentes debe vincularse al módulo cuya función complementa. Como se expuso en la Sección 2.1.2, los Ambientes Inteligentes de Aprendizaje se estructuran en cuatro módulos — dominio, modelo del estudiante, tutor e interfaz— cuya interacción determina la adaptabilidad del sistema. La Tabla 5.1 muestra la función de cada módulo y su relación con el Modelo de Autoeficacia.

Tabla 5.1 Módulos del Ambiente Inteligente de Aprendizaje y su relación con el Modelo de Autoeficacia

Módulo	Función en el AIA	Relación con el MA
Módulo interfaz	Gestiona la interacción y la experiencia de usuario	Medio de entrega de las intervenciones del MAR
Módulo del dominio	Contiene el conocimiento del área de estudio	Base de contenido y ejercicios que el MAR selecciona
Modelo del estudiante	Registra progreso, errores y aciertos; representa al aprendiz	Integra al submódulo MAE del MA
Módulo tutor	Define estrategias pedagógicas y adapta la instrucción	Integra al submódulo MAR del MA

La Figura 5.1 ilustra la integración del Modelo de Autoeficacia dentro de la arquitectura de MateLog. En ella se distinguen los cuatro módulos principales del sistema y se destaca el modelo, representado mediante líneas punteadas que indican su conexión con los módulos que extiende. El Modelo de Autoeficacia del Estudiante se integra como un submódulo vinculado al modelo del estudiante, ampliando dicho módulo con información relativa a la autoeficacia. El Modelo de Adaptación de Respuesta, por su parte, se incorpora como un submódulo conectado al módulo tutor, alineándose con la función pedagógica de ese componente al ampliar su capacidad de respuesta adaptativa.




Figura 5.1 Arquitectura de MateLog con la integración del Modelo de Autoeficacia

5.2 Actualización de MateLog

MateLog está orientado a la enseñanza de lógica matemática y se actualizó a partir de una versión previa de la plataforma, desarrollada y utilizada por Mendoza (2023), sobre la cual se realizaron modificaciones de infraestructura y ampliaciones de funcionalidad necesarias para soportar las exigencias del estudio.

La versión previa de la plataforma se construyó siguiendo el modelo de los Sistemas Tutores Inteligentes, utilizando el *framework* Django sobre Python y alojada en PythonAnywhere, con persistencia de datos en SQLite mediante catorce tablas. Organizaba el aprendizaje en cursos, lecciones y temas, integrando explicaciones teóricas con veintiocho ejemplos y treinta y seis ejercicios prácticos. La teoría se presentaba en una sola pantalla por tema, los ejemplos constituían una sección independiente posterior, y el botón de ayuda en ejercicios entregaba un texto orientador una única vez por reactivo. La navegación era libre entre temas, sin desbloqueo secuencial, y los ejercicios carecían de un umbral de aprobación; el sistema registraba el avance mediante una barra de porcentaje pero no contabilizaba reintentos por ejercicio. El uso de MateLog en ese trabajo se orientó a la minería de datos educativos bajo un diseño observacional, con instrumentos aplicados externamente mediante *Google Forms*.

Aunque esa configuración era adecuada para la finalidad de aquel estudio, presentaba dos limitaciones relevantes para el presente proyecto: la imposibilidad de realizar detección en tiempo real y adaptación dinámica del comportamiento del sistema, y un nivel de detalle limitado en el registro de interacciones, insuficiente para sostener el análisis de las variables requeridas por el modelo adaptativo. Estas limitaciones motivaron las actualizaciones descritas en las subsecciones siguientes, que comprenden la infraestructura, las funcionalidades, el contenido y la verificación operativa.

5.2.1 Actualización de la infraestructura

La ejecución del estudio experimental imponía exigencias técnicas que la infraestructura de la versión previa no podía satisfacer: operación estable durante sesiones simultáneas, control de acceso por condición de control o experimental, registro detallado de la interacción y disponibilidad como aplicación web. La arquitectura monolítica de la versión previa, junto con la base de datos SQLite y el alojamiento en PythonAnywhere, representaba una limitación técnica para todos estos requerimientos, lo que

motivó una transformación estructural de la plataforma. La Tabla 5.2 presenta los componentes técnicos modificados y la justificación de cada cambio.

Tabla 5.2 Comparación de la infraestructura entre MateLog previo (Mendoza, 2023) y MateLog actual

Componente	MateLog (Mendoza, 2023)	MateLog actual	Justificación del cambio
Arquitectura	Monolítica (Django)	Desacoplada: <i>backend</i> con Django REST <i>Framework</i> , <i>frontend</i> con React y Vite	Permite escalar de forma independiente cada componente y bifurcar el comportamiento según condición experimental sin reimplementar todo el sistema
Base de datos	SQLite	PostgreSQL	Soporta concurrencia real, mayor volumen de datos y consultas estructuradas en tiempo real
Alojamiento	PythonAnywhere	Render (<i>backend</i>) y Vercel (<i>frontend</i>)	Mejora la disponibilidad y permite despliegues independientes de <i>backend</i> y <i>frontend</i>

La transformación principal consistió en migrar de una arquitectura monolítica a una arquitectura desacoplada, en la que la lógica de negocio y la gestión de datos se separan de la interfaz de usuario.

5.2.2 Incorporación de funcionalidades

Las funcionalidades de MateLog actual se diseñaron como una evolución directa de las disponibles en la versión previa, conservando los elementos pedagógicos que ya formaban parte de la experiencia del estudiante y añadiendo nuevas funcionalidades necesarias para soportar el estudio experimental.

Respecto a la interfaz, la versión previa presentaba un diseño predominantemente textual, sin uso de color, formas ni efectos visuales. En MateLog actual se incorpora una interfaz visualmente diferenciada, con paletas cromáticas consistentes, formas que estructuran los bloques de contenido y transiciones que acompañan la navegación, con el propósito de

facilitar la lectura, distinguir visualmente los distintos tipos de elementos del curso y mantener la atención del estudiante.

Las funcionalidades pedagógicas heredadas se conservaron en su propósito original, pero se rediseñaron en su comportamiento. La presentación de la teoría, que en la versión previa consistía en una sola pantalla con todo el contenido del tema, se reorganizó como una secuencia de segmentos breves con ejemplos intercalados. Los ejemplos, que antes constituían una sección independiente posterior a la teoría, ahora aparecen integrados en el flujo de aprendizaje, con la posibilidad de solicitar un ejemplo adicional desde algunos de los presentados. El botón de ayuda durante los ejercicios, que en la versión previa permitía consultar un texto orientador una sola vez por reactivo, se rediseñó para mostrar un mensaje contextual superpuesto a la pantalla del ejercicio, invocable y cerrable cuantas veces lo requiera el estudiante.

A estas funcionalidades heredadas se sumaron nuevas que no existían en la versión previa. El botón "Volver" permite al estudiante regresar al contenido teórico desde la sección de ejercicios, registrando estos retornos como un indicador de comportamiento. El atajo "Ir a ejercicios" habilita el salto directo desde la teoría a la práctica para quienes ya han completado los ejercicios anteriormente sin aprobarlos. La continuidad entre sesiones permite que un estudiante retome la plataforma desde el último ejercicio no resuelto, sin necesidad de reiniciar el recorrido. Se incorporó además un esquema de aprobación por tema: cada tema requiere un porcentaje mínimo de respuestas correctas para considerarse aprobado, lo cual habilita un desbloqueo secuencial que impide el acceso a un tema posterior sin haber superado el anterior. Cuando un estudiante no alcanza el umbral de aprobación, el sistema le ofrece reintentar el tema completo, registrando cada intento de forma independiente. La Tabla 5.3 presenta la correspondencia entre las funcionalidades de ambas versiones.

Tabla 5.3 Comparación de funcionalidades entre MateLog previo (Mendoza, 2023) y MateLog actual

Funcionalidad	MateLog (Mendoza, 2023)	MateLog actual
Interfaz	Predominantemente textual, sin color, formas ni efectos	Interfaz con paleta cromática, formas estructurantes y transiciones
Presentación de teoría	Pantalla única con todo el contenido del tema	Segmentos breves con ejemplos intercalados
Ejemplos	Sección independiente posterior a la teoría	Integrados en el flujo de aprendizaje, con opción de ver ejemplo adicional
Botón de ayuda	Texto orientador disponible una sola vez por ejercicio	Mensaje contextual superpuesto, invocable y cerrable cuantas veces se requiera
Navegación entre temas	Libre, sin orden obligatorio	Desbloqueo secuencial al aprobar el tema actual
Aprobación de tema	No contemplada; barra de porcentaje al responder correctamente	Porcentaje mínimo de aprobación; reintento del tema en caso de no alcanzarlo
Registro de reintentos	No registrado	Cada intento se registra de forma independiente
Botón Volver al contenido	No disponible	Disponible desde la sección de ejercicios, con registro de cada retorno
Atajo Ir a ejercicios	No disponible	Salto directo desde la teoría a la práctica
Continuidad entre sesiones	No especificada	Retoma desde el último ejercicio no resuelto

El registro de interacciones del estudiante se reestructuró en paralelo a estos cambios, manteniendo las categorías que ya contemplaba la versión previa —tiempos por sección, intentos y resultados por ejercicio, solicitudes de ayuda, ejemplos consultados, ruta de navegación y porcentaje de avance— y ampliándolas para registrar los nuevos eventos: retornos al contenido teórico, uso del atajo "Ir a ejercicios", número de intentos por tema, mejora porcentual entre intentos, decisión de reintentar y solicitud de ejemplos adicionales.

5.2.3 Incorporación de contenido

El contenido educativo de MateLog actual se reemplazó por completo respecto a la versión previa, aunque manteniendo la misma referencia bibliográfica base. Esta decisión se fundamentó en la necesidad de contar con un conjunto de materiales más amplio, capaz de sustentar una verificación robusta del conocimiento adquirido por los estudiantes en condiciones de evaluación pre-test y post-test, además de soportar las exigencias adicionales que impone el modelo adaptativo en términos de selección diferenciada de ejercicios por perfil.

Respecto a la organización del contenido teórico, se adoptó un esquema de teoría y ejemplos intercalados, distribuidos a lo largo de pantallas consecutivas breves. Esta decisión se fundamenta en criterios de carga cognitiva: el desplazamiento entre pantallas con fragmentos acotados al contenido resulta menos demandante que la lectura sostenida de un texto extenso en una sola pantalla, particularmente para estudiantes que se enfrentan por primera vez al aprendizaje de lógica matemática. Asociado a este esquema, se incorporó la posibilidad de ver un ejemplo adicional a partir de determinados ejemplos presentados en la teoría, como vía voluntaria de profundización sin saturar la presentación inicial.

La estructura final del curso quedó conformada por una lección dividida en cinco temas secuenciales. Cada tema contiene entre 8 y 19 segmentos que incluyen teoría con entre 3 y 6 ejemplos intercalados, y un banco de 12 ejercicios. La variación en el número de segmentos teóricos responde al peso conceptual diferenciado de cada tema dentro de la simbolización de proposiciones, decisión de diseño que refleja la estructura conceptual del dominio. El número uniforme de ejercicios por tema, por su parte, es una decisión deliberada para garantizar una base equivalente que permita comparar el desempeño entre estudiantes y grupos. Para los ejercicios, el total es de 60 reactivos adaptados a partir del material de referencia. La mayoría son de opción múltiple; únicamente cuatro son de respuesta abierta, dos en el Tema 1 y dos en el Tema 2.

La categorización por nivel de dificultad merece una consideración aparte. Como se estableció en la Sección 4.2.1, la fuente de experiencias de éxito requiere modular la dificultad de los ejercicios para favorecer la acumulación de logros en estudiantes con baja autoeficacia y, simultáneamente, ofrecer retos suficientes a quienes presentan alta autoeficacia (Bandura, 1986). Esta operacionalización exige disponer de al menos dos bancos diferenciados de reactivos —fácil y difícil—. Sin embargo, el libro de referencia no establece un grado de dificultad para sus ejercicios y, en consecuencia, en una primera versión del banco los reactivos se incorporaron sin una asignación a priori de dificultad; la asignación definitiva se realizó a partir de datos empíricos, como se describe en la Sección 4.3 del Capítulo 4.

5.2.4 Verificación operativa

Una vez integradas las actualizaciones de infraestructura, las nuevas funcionalidades y el contenido, se procedió a verificar que MateLog operara correctamente en condiciones equivalentes a las del estudio experimental. Las pruebas realizadas se orientaron a confirmar que la infraestructura técnica pudiera soportar la operación simultánea de múltiples usuarios, que las distintas secciones y tipos de ejercicios respondieran de forma consistente y que los eventos de interacción se registraran de manera completa en la base de datos. La Tabla 5.4 resume los aspectos verificados y los criterios de aceptación correspondientes.

La verificación operativa confirmó el correcto funcionamiento de la plataforma y sentó las condiciones necesarias para la fase siguiente: al garantizar la integridad del registro de interacciones y la estabilidad del sistema bajo carga concurrente, quedó habilitado el entorno técnico que el Modelo de Autoeficacia requiere para operar.

Tabla 5.4 Aspectos operativos verificados

Aspecto verificado	Criterio de aceptación
Capacidad de usuarios simultáneos	Al menos 50 usuarios simultáneamente sin interrupciones de conexión
Sincronización del progreso	El sistema retoma el punto exacto donde se quedó
Gestión de reconexiones	Sin pérdida de datos al cerrar y reabrir sesión
Registro de interacción	Complejidad y consistencia de todos los eventos en base de datos
Funcionalidad de secciones de contenido	Teoría, ejemplos y ejercicios operativos
Funcionalidad de tipos de ejercicio	Respuesta abierta y opción múltiple evaluados correctamente

5.3 Integración del Modelo de Autoeficacia

La integración del Modelo de Autoeficacia en MateLog no se limita a la conexión técnica entre los componentes del modelo y los módulos del Ambiente Inteligente de Aprendizaje: requiere también incorporar el instrumento de evaluación inicial y adaptar las funcionalidades de MateLog para que se comporten de manera diferenciada según el perfil de cada estudiante. La Tabla 5.5 articula la correspondencia entre las fuentes de autoeficacia seleccionadas en la Sección 4.2.1, las intervenciones del Modelo de Adaptación de Respuesta y las funcionalidades de la plataforma que las hacen posibles, estableciendo el vínculo entre el diseño conceptual del modelo y su implementación técnica en MateLog.

Tabla 5.5 Correspondencia entre fuentes de autoeficacia, intervenciones del Modelo de Adaptación de Respuesta y funcionalidades de MateLog

Fuente de autoeficacia	Intervención del MAR	Funcionalidad de MateLog (Sección 4.2.3)
Experiencias de éxito	Configuración del nivel de dificultad de los ejercicios	Bancos diferenciados de reactivos (fácil y difícil)
Persuasión verbal	Retroalimentación inmediata	Campo de retroalimentación asociado a cada ejercicio
Persuasión verbal	Mensajes de apoyo	Mensajes contextuales en momentos clave del recorrido
Persuasión verbal	Retroalimentación guiada	Botón de ayuda contextual y opción de ver ejemplos adicionales

5.3.1 Integración del instrumento de evaluación

La incorporación de la Escala de Autoeficacia General a MateLog implicó tres tareas complementarias: definir su presentación al estudiante dentro de la plataforma, establecer los mecanismos de cálculo y almacenamiento del puntaje, y vincular el resultado al flujo general de acceso al curso. Las tres tareas se diseñaron de manera que la aplicación del instrumento resultara fluida para el estudiante y, simultáneamente, generara la información estructurada que el Modelo de Autoeficacia del Estudiante requiere para asignar perfiles adaptativos.

La escala se aplica como cuestionario inicial inmediatamente después del primer inicio de sesión del estudiante. La aplicación comienza con una pantalla de instrucciones que explica el propósito del cuestionario y la dinámica de respuesta. Los 10 ítems se presentan uno a uno, lo que evita que el estudiante anticipe el contenido del instrumento y permite registrar el tiempo de respuesta de cada reactivo de forma independiente. Al completar los 10 ítems, el flujo continúa de manera automática hacia el examen diagnóstico, que se presenta con su propia pantalla de instrucciones antes de iniciar.

Tanto el cálculo del puntaje como su clasificación se realizan en el *backend*, lo que evita exponer la lógica de evaluación al cliente y permite mantener la consistencia entre instancias del sistema. Para cada aplicación de la escala, el sistema almacena la respuesta individual de cada ítem y el puntaje total obtenido, y aplica el umbral configurado para asignar la etiqueta de autoeficacia alta o baja. El umbral se implementó como un parámetro configurable, facilitando ajustes posteriores sin necesidad de modificar el código fuente; el valor específico adoptado para el presente estudio —0 a 15 para baja, 16 a 30 para alta— se sustenta en la Sección 4.3 del Capítulo 4.

El registro de la respuesta por ítem, además del puntaje total, cumple dos funciones complementarias. En primer lugar, permite verificar posteriormente la integridad del cálculo y reproducir el proceso de

clasificación si fuera necesario. En segundo lugar, ofrece la posibilidad de análisis más finos en estudios futuros, como la identificación de ítems con comportamiento diferencial o la exploración de subdimensiones del constructo.

La clasificación en autoeficacia alta o baja se asigna de manera inmediata al concluir la escala. Esto permite que el modelo disponga de la primera variable del perfil adaptativo desde antes de que el estudiante comience a interactuar con los ejercicios del Tema 1, y que la segunda variable —el nivel de rendimiento— se determine posteriormente al aprobar dicho tema, completando así la asignación del perfil adaptativo que activa el Modelo de Adaptación de Respuesta.

La aplicación obligatoria de la escala pre-test se integra con el flujo general de acceso al curso mediante un control de estado secuencial gestionado en dos capas. En el *backend* se mantienen los indicadores de completitud de cada etapa del recorrido, que funcionan como fuente de verdad sobre el estado del estudiante. En el *frontend*, antes de cargar cualquier vista de contenido, el componente correspondiente consulta el *endpoint* de estado de evaluaciones y verifica si los prerrequisitos están completos; en caso contrario, interrumpe la carga y redirige al estudiante a la etapa pendiente. Este mecanismo establece un orden estricto e irreversible que garantiza la integridad del protocolo experimental y la disponibilidad de las mediciones requeridas para el análisis posterior. La Tabla 5.6 presenta la secuencia completa de etapas que opera el sistema, el momento en que se ejecutan, el componente técnico responsable y el resultado que producen. Las pantallas correspondientes a cada una de estas etapas se presentan en el Anexo A.

Tabla 5.6 *Secuencia de etapas del flujo de acceso al curso*

Etapas	Momento	Componente técnico responsable	Resultado
Registro del estudiante	Primer acceso a la plataforma	<i>Backend</i> (valida código y crea perfil)	Asignación de condición experimental (control o experimental)
Aplicación de la Escala General de Autoeficacia <i>pre-test</i>	Inmediatamente después del registro	<i>Frontend</i> con cálculo en <i>backend</i>	Puntaje total, etiqueta de nivel de autoeficacia (Alta/Baja) y desbloqueo del examen diagnóstico
Examen diagnóstico (<i>pre-test</i>)	Al concluir la Escala General de Autoeficacia <i>pre-test</i>	<i>Frontend</i> con registro en <i>backend</i>	Línea base de conocimiento y desbloqueo del contenido del curso
Recorrido del curso	Tras el examen diagnóstico (<i>pre-test</i>)	<i>Frontend</i> con bifurcación según condición	Eventos de interacción registrados y, en condición experimental, asignación de perfil al aprobar el Tema 1

5.3.2 Funcionamiento diferenciado por perfil

Antes de detallar las diferencias funcionales entre condiciones, conviene precisar el mecanismo por el cual MateLog opera simultáneamente como versión con y sin Modelo de Autoeficacia. La plataforma no se desplegó como dos sistemas independientes entre los que el estudiante deba elegir, sino como un único sistema cuyo comportamiento se bifurca dinámicamente según el perfil del usuario.

Esta bifurcación se gestiona mediante códigos de acceso configurables desde el panel de administración: cada código se vincula a un plantel, un grupo escolar y una condición experimental —condición control o condición experimental—. Al momento del registro, el estudiante introduce el código que se le proporcionó; el sistema valida que el código exista y esté activo, crea el usuario y, automáticamente, genera su perfil con la condición asignada. A partir de ese momento, todo el comportamiento del sistema —los cálculos que realiza el *backend* y las vistas que muestra el *frontend*— se decide en función de esa condición. Este diseño permite mantener el rigor experimental al garantizar que ambos grupos operan sobre la misma base técnica, sin necesidad de duplicar la plataforma.

En la condición control, la plataforma registra la interacción del estudiante y ofrece funcionalidades fijas de manera uniforme para todos los usuarios. En la condición experimental, esas mismas funcionalidades se mantienen, pero se añaden elementos adaptativos cuya disponibilidad, frecuencia y contenido varían según el perfil asignado. La Tabla 5.7 muestra las diferencias entre ambas condiciones para cada elemento funcional de la plataforma.

Tabla 5.7 *Diferencias entre la condición control y la condición experimental*

Elemento	MateLog sin MA (condición control)	MateLog con MA (condición experimental)
Dificultad de ejercicios	Fija para todos los estudiantes	Adaptada por perfil a partir del Tema 2
Botón de ayuda	Requiere acción del estudiante para activarse	Según perfil y número de intentos, se muestra automáticamente en los ejercicios incorrectos del último intento sin necesidad de dar clic
Ejemplos adicionales	Limitados a la sección de teoría	Según perfil y umbral de intentos, se habilita una sección específica de ejemplos relacionados con los ejercicios incorrectos del último intento
Retroalimentación por ejercicio	Uniforme para todos los estudiantes	Diferenciada por perfil y resultado del intento
Mensajes de apoyo	No disponibles	Activados por perfil en momentos clave del recorrido
Clasificación del estudiante	No disponible	Perfil asignado al aprobar el Tema 1

La Tabla 5.8 detalla, para cada componente del Modelo de Autoeficacia, el momento de activación, el dato que se registra durante la interacción y la acción que el sistema ejecuta en la plataforma. Esta especificación garantiza la trazabilidad de los datos y constituye la base para el análisis posterior del estudio experimental.

Tabla 5.8 Integración del Modelo de Autoeficacia en MateLog: datos registrados y acciones ejecutadas

Componente del MA	Momento de activación	Dato registrado	Acción ejecutada
Escala General de Autoeficacia (<i>pre-test</i>)	Primer inicio de sesión, antes del contenido	Puntaje por ítem y nivel de autoeficacia	Bloquea el acceso al curso hasta completar la escala
Tema 1 en modalidad difícil	Al acceder al Tema 1	Número de intentos y nivel de rendimiento	Entrega ejercicios en nivel difícil a todos los estudiantes
Asignación de perfil (MAE)	Al aprobar el Tema 1	Perfil adaptativo asignado	Activa el MAR para los temas siguientes
Configuración de dificultad (MAR)	Tras el Tema 1	Nivel de dificultad activo y aceptación de rescate o reto	Selecciona el conjunto de ejercicios según perfil
Retroalimentación pedagógica (MAR)	Al concluir cada ejercicio	Tipo de retroalimentación emitida	Muestra explicación o indicador simple según perfil y resultado
Mensajes de apoyo (MAR)	Al acumular aciertos, reintentar o concluir un tema	Mensajes emitidos por tipo	Despliega mensaje según perfil y número de intento
Retroalimentación guiada (MAR)	Al superar el umbral de intentos por perfil	Activación de pista y de ejemplo adicional	Habilita texto de ayuda visible en pantalla y opción de ejemplos adicionales relacionados con los ejercicios incorrectos del último intento
Escala General de Autoeficacia (<i>post-test</i>)	Al terminar el curso	Puntaje <i>post-test</i> y diferencia con el <i>pre-test</i>	Registra la medición final de autoeficacia

El algoritmo se ejecuta al término de cada intento y cumple dos funciones según el resultado. Ante cualquier intento, evalúa si corresponde activar una intervención tutorial del Modelo de Adaptación de Respuesta, como la retroalimentación guiada. Si el intento representa además la aprobación del tema, determina el perfil correspondiente conforme a las condiciones de la Tabla 4.6, según la cantidad de intentos que le tomó aprobar, y lo registra como el perfil obtenido en ese tema.

El Modelo de Autoeficacia se despliega en la plataforma mediante una secuencia que abarca desde la evaluación inicial hasta el cierre del curso. Cada componente cumple una función específica: diagnosticar el nivel de

autoeficacia, asignar un perfil adaptativo, configurar la dificultad de los ejercicios, ofrecer retroalimentación diferenciada y emitir mensajes de apoyo o guías adicionales. En conjunto, estas acciones conforman un sistema que integra el registro de datos con la activación de intervenciones pedagógicas, de tal manera que la experiencia formativa se ajusta a las características y necesidades de cada estudiante.

Capítulo 6. Evaluación del Modelo de Autoeficacia

Este capítulo presenta los resultados del experimento diseñado para evaluar el efecto del Modelo de Autoeficacia en MateLog. La exposición sigue la estrategia analítica descrita en la Sección 6.1: primero se describe la muestra y se verifican los supuestos que determinan la elección de las pruebas estadísticas; luego se comprueba la equivalencia inicial de los grupos y se reportan los resultados por cada variable dependiente; el capítulo cierra con una discusión de los hallazgos desde los principios de la teoría de autoeficacia.

6.1 Protocolo del estudio

La evaluación se planificó como un estudio experimental con diseño de dos grupos independientes —condición control y condición experimental— y mediciones antes y después (pre-test y post-test). El objetivo fue determinar si la versión adaptativa de MateLog produce diferencias en el aprendizaje de lógica matemática y en la percepción de autoeficacia de los estudiantes, en comparación con la versión sin adaptación.

El grupo control interactúa con MateLog sin el Modelo de Autoeficacia activo, por lo que recibe ejercicios uniformes y retroalimentación simple. El grupo experimental interactúa con MateLog con el modelo activo y recibe el flujo completo de adaptación descrito en la Sección 5.3.2. Más allá de la experiencia de aprendizaje durante el curso, ambos grupos siguen un procedimiento de acceso idéntico y responden los mismos instrumentos de medición. La Figura 6.1 resume la secuencia completa de actividades que realiza cada estudiante durante la sesión. El flujo es idéntico para ambos grupos en las etapas de registro, medición de autoeficacia, diagnóstico, escala post-test, examen final y valoración; la única diferencia entre condiciones reside en la experiencia dentro del curso.




Figura 6.1 *Secuencia de actividades del protocolo para ambos grupos*

La asignación a cada condición se realizó mediante un código de acceso ligado al plantel y grupo escolar, de modo que todos los estudiantes de un mismo salón quedaron en la misma condición. Este esquema por conglomerados evita la contaminación entre condiciones —al impedir que estudiantes del mismo salón compartan información sobre las diferencias entre versiones— aunque genera variación entre salones, la cual se controla mediante el análisis por código de acceso descrito en la Sección 6.1.3.

Además del cuestionario de autoeficacia, el protocolo contempla tres instrumentos de medición orientados a evaluar el conocimiento adquirido y la experiencia del usuario. La Tabla 6.1 resume sus características.

Tabla 6.1 Instrumentos de medición aplicados durante el protocolo

Instrumento	Momento de aplicación	Estructura	Propósito
Examen diagnóstico	Tras la Escala General de Autoeficacia (<i>pre-test</i>), antes del contenido del curso	10 reactivos de opción múltiple con cuatro alternativas, incluyendo la opción "No lo sé" para reducir el efecto de la adivinación	Establecer la línea base de conocimiento (<i>pre-test</i>)
Examen final	Tras la Escala General de Autoeficacia (<i>post-test</i>), al concluir el curso	10 reactivos equivalentes en estructura y dificultad al examen diagnóstico, con preguntas distintas	Medir la ganancia de conocimiento atribuible a la intervención (<i>post-test</i>)
Valoración de la plataforma	Al finalizar el examen final	Escala de 1 a 5 estrellas y campo de comentario abierto opcional	Información complementaria sobre la experiencia percibida por el usuario; no forma parte del análisis de efectividad del modelo

Tanto el examen diagnóstico como el examen final deben responderse de forma obligatoria, dado que su completitud condiciona el avance del estudiante dentro del protocolo.

6.1.2 Aplicación del estudio experimental

La convocatoria se dirigió a estudiantes de preparatoria de cuatro planteles: CETis 12, CETis 43, COBAEM 2 y COBAEM 6. En cada plantel participante se incluyeron grupos en ambas condiciones —condición control y condición experimental—, de modo que las diferencias entre planteles no pudieran confundirse con el efecto de la intervención. Se incluyeron al menos dos grupos por condición para reducir el efecto de las características propias de un salón en particular sobre los resultados. La participación fue voluntaria: los estudiantes recibieron información sobre el propósito general del proyecto y decidieron participar con la autorización de su profesor.

Para acceder a la plataforma se requirió un dispositivo con conexión a internet; quienes no contaban con uno recibieron apoyo del equipo investigador con dispositivo o conexión. En el análisis solo se consideraron

los estudiantes que participaron en una sesión presencial supervisada; los registros de quienes completaron el flujo fuera de estas sesiones se excluyeron, ya que no se garantizaba la integridad del procedimiento. Los estudiantes que no respondieron la escala post-test o no presentaron el examen final fueron excluidos del análisis de efectividad, aunque sus datos de interacción con la plataforma se conservaron para los análisis de comportamiento.

6.1.3 Análisis estadístico

El análisis estadístico se organizó en dos etapas. En la primera se verificaron los supuestos que determinan la elección de las pruebas: normalidad de las distribuciones y homogeneidad de varianzas. En la segunda se realizaron las comparaciones de interés: el cambio dentro de cada grupo entre el pre-test y el post-test, y la diferencia en ese cambio entre el grupo control y el experimental.

6.1.3.1 Verificación de supuestos

Antes de seleccionar las pruebas estadísticas inferenciales, se verificaron dos supuestos fundamentales. El supuesto de normalidad se evaluó mediante la prueba de Shapiro-Wilk para cada variable y grupo, complementada con inspección visual de histogramas. El supuesto de homogeneidad de varianzas se verificó mediante la prueba de Levene. Dado que no se podía garantizar de antemano el cumplimiento del supuesto de normalidad —particularmente en las variables de rendimiento académico—, la estrategia principal de análisis fue no paramétrica. En caso de que alguna distribución cumpliera el supuesto de normalidad, se aplicaría adicionalmente la prueba *t* de *Student* pareada para la comparación intragrupo correspondiente, con fines de robustez.

6.1.3.2 Comparación intragrupo e intergrupo

El análisis estadístico tuvo como propósito comparar el desempeño de los dos grupos en las variables de resultado primarias, tanto dentro de

cada grupo (cambio de pre a post) como entre grupos (diferencia en la ganancia). La Tabla 6.2 especifica la prueba utilizada en cada tipo de comparación. Los tamaños del efecto se reportan como correlación de rango biserial (r) para las pruebas no paramétricas, con los siguientes umbrales de interpretación: trivial si es menor a .10, pequeño si es de .10 o más, mediano si es de .30 o más, y grande si es de .50 o más. Para las pruebas paramétricas se reporta la d de Cohen.

Tabla 6.2 *Análisis estadísticos principales*

Comparación	Variable	Prueba
Intragrupo (control)	Δ autoeficacia, Δ conocimiento	Wilcoxon de rangos con signo
Intragrupo (experimental)	Δ autoeficacia, Δ conocimiento	Wilcoxon de rangos con signo
Intergrupo	Δ autoeficacia, Δ conocimiento	Mann-Whitney U

6.2. Resultados

Esta sección reporta los resultados del experimento siguiendo el orden establecido por la estrategia analítica: primero se caracteriza la muestra de participantes, luego se verifican los supuestos estadísticos que determinan la elección de las pruebas inferenciales, y finalmente se presentan las comparaciones de interés, tanto dentro de cada grupo entre el inicio y el final del estudio como entre los grupos control y experimental.


6.2.1 Descripción de la muestra

El experimento incluyó a 180 estudiantes de preparatoria de cuatro planteles: CETis 12, CETis 43, COBAEM 2 y COBAEM 6. La muestra se distribuyó en dos grupos: condición control ($n = 99$) y condición experimental ($n = 81$). Los estudiantes que apoyaron en las pruebas del sistema no forman parte del experimento. La Tabla 6.3 muestra la distribución por plantel y condición experimental.

Tabla 6.3 Distribución de participantes por plantel y grupo

Plantel	Control	Experimental	Total
Cetis 12	21	22	43
Cetis 43	31	30	61
Cobaem 2	25	12	37
Cobaem 6	22	17	39
Total	99	81	180

No todos los participantes respondieron todos los instrumentos. La Figura 6.2 muestra los datos disponibles: 142 para la variable de autoeficacia (Escala de Autoeficacia General, post-test) y 138 para el examen final. Los análisis que combinan ambas medidas utilizan 138 participantes. A lo largo del capítulo se especifica el tamaño muestral empleado en cada análisis.

**Figura 6.2** Muestra y disponibilidad de datos por subconjunto

6.2.2 Verificación de supuestos

Previo a la selección de las pruebas estadísticas inferenciales, se verificaron los supuestos de normalidad y homogeneidad de varianzas, condiciones que determinan la elección entre pruebas paramétricas y no paramétricas. El análisis se realizó sobre las variables de autoeficacia (AE Pre, AE Post, Cambio AE) y de rendimiento académico (Examen Diagnóstico,

Examen Final, Cambio Examen), considerando por separado al grupo control y al grupo experimental.

6.2.2.1 Normalidad

La normalidad de las variables se evaluó mediante la prueba formal de Shapiro-Wilk (Tabla 6.4). Considerando el criterio $p > 0.05$ para no rechazar la hipótesis de normalidad, los resultados muestran que únicamente cuatro de las doce distribuciones evaluadas cumplieron este supuesto, correspondientes principalmente a las variables de autoeficacia (AE Pre en ambos grupos y AE Post en el grupo experimental) y a Δ Examen en el grupo experimental. Las ocho distribuciones restantes presentaron desviaciones significativas de la normalidad, destacando las variables de rendimiento académico (Examen Diagnóstico y Examen Final), donde la no normalidad resultó marcada en ambos grupos. El caso de AE Pre en el grupo control se ubicó en el límite del criterio establecido, por lo que se interpreta como un cumplimiento marginal.

Tabla 6.4 Prueba de Shapiro-Wilk aplicada a las variables de interés

Variable	Grupo	n	W	p	Normal
AE Pre	Control	99	0.975	.060	Sí
AE Pre	Experimental	81	0.973	.087	Sí
AE Post	Control	85	0.944	.001	No
AE Post	Experimental	58	0.967	.117	Sí
Examen Diagnóstico	Control	99	0.966	.011	No
Examen Diagnóstico	Experimental	81	0.945	.002	No
Examen Final	Control	82	0.927	.000	No
Examen Final	Experimental	56	0.905	.000	No
Δ AE	Control	85	0.916	.000	No
Δ AE	Experimental	58	0.952	.024	No
Δ Examen	Control	82	0.965	.026	No
Δ Examen	Experimental	56	0.962	.074	Sí

Dado que la mayoría de las variables no cumplió el supuesto de normalidad y que, con excepción de AE Pre, ninguna lo hizo simultáneamente en ambos grupos, se decidió emplear pruebas no

paramétricas de forma consistente. Esta elección privilegia la coherencia metodológica frente a la aplicación mixta de pruebas paramétricas y no paramétricas según la variable. Se utilizó la prueba U de Mann-Whitney para comparaciones entre grupos independientes y la prueba de Wilcoxon de rangos con signo para comparaciones intragrupo pre-post. Los tamaños de efecto se reportan mediante la correlación rango-biserial, apropiada para este tipo de pruebas.

6.2.2.2 Homogeneidad de varianzas

Adicionalmente al análisis de normalidad, se evaluó la homogeneidad de varianzas entre los grupos control y experimental mediante la prueba de Levene (Tabla 6.5). Este análisis aporta evidencia sobre la comparabilidad inicial de los grupos en términos de dispersión, lo que constituye un elemento de validez interna independiente de la prueba inferencial seleccionada.

Tabla 6.5 *Prueba de Levene aplicada a las variables de interés*

Variable	Estadístico de Levene	<i>p</i>	Homogéneo
AE Pre	0.366	.546	Sí
AE Post	2.160	.144	Sí
Examen Diagnóstico	0.240	.625	Sí
Examen Final	1.073	.302	Sí
Δ AE	0.406	.525	Sí
Δ Examen	0.890	.347	Sí

Las seis variables analizadas cumplen el supuesto de homogeneidad de varianzas, con valores *p* claramente por encima del umbral de 0.05 en todos los casos. Esto indica que las varianzas entre los grupos son comparables y refuerza la validez del diseño: los grupos control y experimental presentan dispersión similar en todas las variables, lo que sugiere que las diferencias encontradas en las comparaciones posteriores son atribuibles a tendencias centrales y no a diferencias en la variabilidad de los grupos.

6.2.3 Comparación intragrupo e intergrupo

Una vez verificados los supuestos estadísticos, se procedió a evaluar las diferencias en autoeficacia y rendimiento académico entre los grupos control y experimental, así como los cambios producidos entre las mediciones pre y post dentro de cada grupo. Este análisis responde a las dos preguntas de investigación planteadas: si existe mejora en el aprendizaje en MateLog con el Modelo de Autoeficacia, y si existe algún cambio en la autoeficacia en alguno de los grupos. Todas las comparaciones se realizaron mediante pruebas no paramétricas conforme a la decisión metodológica justificada en la sección anterior. Los tamaños de efecto se reportan mediante la correlación rango-biserial (r), interpretada según los umbrales convencionales: trivial ($|r| < 0.10$), pequeño ($|r| \geq 0.10$), mediano ($|r| \geq 0.30$) y grande ($|r| \geq 0.50$).

6.2.3.1 Equivalencia inicial entre grupos

En diseños experimentales sin asignación aleatoria es necesario verificar que los grupos no presenten diferencias significativas en las variables de resultado antes del inicio de la intervención. Esta verificación permite descartar que las diferencias observadas posteriormente sean atribuibles a condiciones iniciales desiguales. Se compararon los grupos control y experimental en las mediciones pre-test de autoeficacia y rendimiento académico mediante la prueba U de Mann-Whitney. Los resultados se presentan en la Tabla 6.6 y se visualizan en la Figura 6.3.

Los resultados muestran que los grupos parten de niveles equivalentes de autoeficacia, con medianas prácticamente idénticas entre condición control y condición experimental. En contraste, se observó una diferencia estadísticamente significativa en el rendimiento académico inicial, donde el grupo control presentó una mediana superior respecto al experimental (4.0 frente a 3.0 puntos). Esta diferencia inicial se consideró al interpretar los resultados de las comparaciones posteriores, tal como se explica en la Sección 6.2.3.3.

Tabla 6.6 Comparación pre-test entre grupos

Estadístico	AE Pre	Examen Diagnóstico
n control	99	99
Mdn control	15.0	4.0
IQR control	5.5	2.0
n experimental	81	81
Mdn experimental	16.0	3.0
IQR experimental	6.0	2.0
U	3763.5	4994.5
p	.479	.004*
r	0.061	-0.246
Interpretación	Equivalentes	Diferencia significativa




Figura 6.3 Comparación pre-test entre grupos control y experimental

6.2.3.2 Comparación intragrupo

Para evaluar si cada grupo experimentó cambios significativos entre las mediciones pre y post, se aplicó la prueba de Wilcoxon de rangos con signo a las variables de autoeficacia y rendimiento académico. Los resultados estadísticos se presentan en la Tabla 6.7, la distribución de cambios individuales en la Tabla 6.8, y las visualizaciones complementarias en las Figuras 6.4, 6.5 y 6.6.


Tabla 6.7 Comparaciones intragrupo pre-post

Variable	Grupo	n	Mdn pre	Mdn post	Mdn cambio	W	p	r
Autoeficacia	Control	85	15.0	15.0	0.0	985.5	.713	0.040
Autoeficacia	Experimental	58	16.0	17.0	1.0	433.5	.047*	0.261
Examen	Control	82	4.0	6.5	2.0	583.5	<.001*	0.657
Examen	Experimental	56	3.0	7.5	4.0	58.0	<.001*	0.738

Tabla 6.8 Distribución de cambios individuales pre-post

Variable	Grupo	n	Mejoran	Sin cambio	Empeoran
Autoeficacia	Control	85	29 (34.1%)	21 (24.7%)	35 (41.2%)
Autoeficacia	Experimental	58	31 (53.4%)	8 (13.8%)	19 (32.8%)
Examen	Control	82	53 (64.6%)	6 (7.3%)	23 (28.0%)
Examen	Experimental	56	44 (78.6%)	7 (12.5%)	5 (8.9%)

La Figura 6.4 presenta la trayectoria pre-post de ambas variables en cada grupo, lo que permite observar de manera panorámica las diferencias en la magnitud y dirección del cambio. En autoeficacia, la línea del grupo control se mantiene prácticamente horizontal, mientras que la del grupo experimental muestra una pendiente positiva. En rendimiento académico, ambos grupos presentan pendientes ascendentes, pero la del experimental es más pronunciada y parte de un nivel inicial menor.

**Figura 6.4** Trayectoria pre-post de autoeficacia y rendimiento académico por grupo

En la variable de autoeficacia, el grupo control no mostró cambios significativos entre el pre-test y el post-test, con una mediana de cambio igual a cero (Tabla 6.7). Por el contrario, el grupo experimental sí presentó un cambio significativo, con una mediana de cambio de +1.0 punto y un 53.4% de los estudiantes mostrando un incremento en su autoeficacia percibida (Tabla 6.8). La Figura 6.5 permite visualizar la distribución completa de los cambios individuales en autoeficacia para cada grupo: en el grupo control, la distribución se concentra alrededor del cero, con un 41.2% de estudiantes que disminuyeron su autoeficacia, lo que explica la ausencia de cambio neto significativo. En el grupo experimental, la distribución se desplaza hacia valores positivos, con la mediana ubicada en +1.0 y una mayor proporción de estudiantes que incrementaron su autoeficacia respecto a los que la disminuyeron.




Figura 6.5 Distribución de cambios individuales en autoeficacia

Este patrón sugiere que la versión adaptativa de MateLog generó un efecto perceptible sobre las creencias de eficacia de los estudiantes, mientras que la plataforma en condición control no produjo cambios sistemáticos en esta dimensión. Una posible explicación es que la adaptabilidad de la plataforma experimental llevó a que los estudiantes replantearan su confianza percibida en función de su perfil: la retroalimentación diferenciada y el ajuste de la dificultad pudieron operar como evidencia concreta de capacidad o de área de mejora, influyendo en la autoevaluación final.

En la variable de rendimiento académico, ambos grupos mostraron mejoras significativas entre el examen diagnóstico y el examen final, con tamaños de efecto grandes en ambos casos (Tabla 6.7). La Figura 6.6 muestra la distribución de los cambios individuales en rendimiento académico para cada grupo, donde se observa que el desplazamiento hacia valores positivos es marcado en ambos casos, pero notablemente más pronunciado en el grupo experimental, con el 78.6% de los estudiantes mostrando mejora frente al 64.6% del grupo control. Si bien ambos grupos mejoraron, la magnitud de la ganancia fue mayor en el grupo experimental, hallazgo que se analiza con mayor detalle en la siguiente sección.




Figura 6.6 Distribución de cambios individuales en rendimiento académico

6.2.3.3 Comparación intergrupo

La comparación entre grupos se realizó sobre las ganancias pre-post de la Escala General de Autoeficacia y del examen, que constituyen las variables dependientes principales del experimento. El uso de las ganancias como variable principal se justifica porque, como se vio en la Sección 6.2.3.1, los grupos partían de niveles distintos de rendimiento académico inicial: al analizar el cambio en lugar del resultado final, se controla el efecto del punto de partida de cada estudiante. Los resultados se presentan en la Tabla 6.9 y se visualizan en la Figura 6.7.

En la ganancia de autoeficacia, no se encontró una diferencia estadísticamente significativa entre grupos, aunque el resultado se ubica en el límite del criterio convencional de significancia y refleja una tendencia

favorable al grupo experimental (Tabla 6.9). Este resultado no es concluyente: puede que el efecto sea pequeño y la muestra no sea suficiente para captarlo con claridad, o que el efecto sea aún incipiente y requiera mayor tiempo de exposición para consolidarse.

Tabla 6.9 Comparación intergrupo de ganancias pre-post

Estadístico	Cambio AE	Cambio Examen
<i>n</i> control	85	82
Mdn control	0.0	2.0
IQR control	3.0	6.0
<i>n</i> experimental	58	56
Mdn experimental	1.0	4.0
IQR experimental	3.0	5.25
U	2021.0	1615.5
<i>p</i>	.066	.003*
<i>r</i>	0.180	0.296
Decisión	Tendencia marginal	Diferencia significativa




Figura 6.7 Ganancias pre-post por grupo

En la ganancia de rendimiento académico, se encontró una diferencia estadísticamente significativa entre los grupos, con un tamaño de efecto pequeño cercano al rango mediano. El grupo experimental duplicó la ganancia mediana del grupo control (4.0 frente a 2.0 puntos), y el 78.6% de sus estudiantes mostraron mejora frente al 64.6% del grupo control.

Este hallazgo constituye el resultado principal del experimento y respalda la efectividad del Modelo de Autoeficacia integrado en MateLog para favorecer el aprendizaje de lógica matemática, con mayor peso argumentativo dado que el grupo experimental partió de un nivel de conocimiento inicial inferior al del grupo control.

6.3 Discusión

Los resultados responden de manera diferenciada a las dos preguntas de investigación que orientaron el trabajo.

En cuanto a la primera pregunta —si existe mejora en el aprendizaje en MateLog con el Modelo de Autoeficacia—, la respuesta es afirmativa. Al comparar entre grupos las ganancias en el examen de lógica matemática, la diferencia fue estadísticamente significativa a favor del grupo experimental ($U = 1615.5$; $p = .003$; $r = 0.296$). La mediana de ganancia del grupo experimental duplica a la del control (4.0 frente a 2.0 puntos), y el 78.6% de sus estudiantes mejoró, frente al 64.6% del control.

Este hallazgo es más sólido si se tiene en cuenta el punto de partida. Los grupos no eran equivalentes al inicio: el control tenía una mediana de rendimiento más alta en el examen diagnóstico (4.0 frente a 3.0; $p = .004$), lo que en una comparación de puntajes finales lo habría favorecido. Al analizar las ganancias se controla esa diferencia inicial, y se aprecia que el grupo experimental, que comenzó desde un nivel inferior, no solo alcanzó al control sino que mejoró más. La mejora del experimental no se debe a una ventaja de partida, sino al efecto de la intervención.

Cabe señalar que ambos grupos mejoraron de manera significativa al compararse consigo mismos, con tamaños de efecto grandes ($r = 0.657$ en el control y $r = 0.738$ en el experimental). Esto indica que MateLog, incluso sin el modelo activo, produce aprendizaje: la plataforma en condición control es eficaz por sí misma, pues ya incluye retroalimentación por ejercicio, solo que de forma uniforme para todos los estudiantes (Tabla 5.7). La comparación entre condiciones no contrasta, por tanto, la presencia frente a la ausencia de retroalimentación, sino su diferenciación por perfil

frente a un esquema único. Lo que aporta el Modelo de Autoeficacia es una mejora adicional sobre esa base, gracias a la adaptación de la dificultad según el perfil, la activación gradual de pistas y ejemplos, y la retroalimentación personalizada. Esta lógica es consistente con Bandura (1986): las experiencias de éxito son la fuente principal de la autoeficacia, y esta a su vez influye en el esfuerzo, la persistencia y las estrategias que usa el estudiante. El Modelo de Adaptación de Respuesta fue diseñado precisamente para generar experiencias de éxito ajustadas a cada perfil, y los resultados sugieren que ese diseño logró un entorno más favorable que la versión lineal y uniforme.

En cuanto a la segunda pregunta —si existe algún cambio en la autoeficacia en alguno de los grupos—, la respuesta es también afirmativa, pero únicamente en el grupo experimental y al comparar al grupo consigo mismo entre el inicio y el final del estudio. La prueba de Wilcoxon mostró que la condición experimental aumentó significativamente su puntaje en la escala pre-post: la mediana pasó de 16.0 a 17.0 ($p = .047$; $r = 0.261$), y el 53.4% de sus estudiantes mejoró. En cambio, el grupo control no mostró un cambio significativo (mediana de 15.0 en ambos momentos; $p = .713$; $r = 0.040$), e incluso un 41.2% de sus estudiantes bajó su puntaje.

La comparación intergrupar de las ganancias no alcanzó significancia estadística ($U = 2021.0$; $p = .066$; $r = 0.180$), aunque el valor de p está justo en el límite del criterio habitual y el efecto, de tamaño pequeño, favorece al grupo experimental. Hay dos explicaciones posibles, que no se excluyen mutuamente: o el efecto sobre la autoeficacia es real pero pequeño, y se necesitaría una muestra más grande para detectarlo con claridad; o se trata de un efecto que apenas empieza a manifestarse y que requeriría mayor tiempo de exposición para consolidarse.

La diferencia entre lo que se observa al comparar cada grupo consigo mismo y al compararlos entre sí revela que la plataforma adaptativa logró un cambio detectable en las creencias de autoeficacia, mientras que la plataforma lineal no. Los mensajes de apoyo, la retroalimentación personalizada y el ajuste del nivel de dificultad pudieron ayudar al

estudiante a reflexionar sobre su propia competencia percibida, aunque no necesariamente de forma consciente. Lo que no puede afirmarse con certeza es que ese cambio sea mayor en el grupo experimental que en el control; lo que sí puede afirmarse es que la versión adaptativa produce un cambio detectable, la lineal no, y que la dirección del efecto favorece al grupo experimental tal como se esperaba desde la teoría.

Ambos resultados se complementan. La intervención tuvo un efecto claro en el rendimiento académico y un efecto aún incipiente en la autoeficacia. Esto es comprensible: la confianza se construye gradualmente con experiencias repetidas de éxito. Un período corto puede ser suficiente para aprender, pero no necesariamente para modificar creencias estables, especialmente cuando se miden con una escala general y no con un cuestionario específico para el dominio intervenido. Como se argumentó en la Sección 5.1.1, se seleccionó la Escala de Autoeficacia General porque los estudiantes tenían escasa familiaridad previa con el contenido de lógica matemática; una escala específica habría introducido sesgos. Esa decisión es metodológicamente correcta, pero tiene la limitación de que una medida general puede no ser suficientemente sensible para captar cambios directamente relacionados con la intervención en un dominio particular.

6.3.1 Observaciones sobre la ejecución del experimento

La aplicación del experimento en los planteles permitió observar patrones de comportamiento que complementan los hallazgos estadísticos. En la condición control, varios estudiantes mostraron señales de desinterés durante el uso de MateLog sin el modelo activo, mientras que quienes utilizaron la versión con el modelo manifestaron un mayor involucramiento. En cuanto a los mecanismos del Modelo de Adaptación de Respuesta, la opción de reto fue muy aceptada y la intentaron en más de una ocasión incluso sin necesidad de hacerlo. Por el contrario, la opción de rescate fue frecuentemente rechazada: los estudiantes expresaban confianza en su capacidad para resolver los ejercicios que ya tenían, lo que puede interpretarse como una manifestación conductual de alta

autoeficacia percibida. Estas observaciones son consistentes con las predicciones de la teoría de autoeficacia respecto al comportamiento de elección de tareas (Bandura, 1977).

Capítulo 7. Conclusiones y trabajo futuro

Este capítulo cierra el trabajo integrando los resultados del estudio experimental con los objetivos que orientaron su desarrollo. A partir del contraste entre lo propuesto y lo obtenido, se presentan las conclusiones del proyecto, las contribuciones de la investigación al campo de los Ambientes Inteligentes de Aprendizaje y las direcciones que quedan abiertas para extender, replicar o profundizar el trabajo realizado.

7.1 Cumplimiento de objetivos

Los tres objetivos específicos del proyecto se cumplieron. El primero consistía en construir el Modelo de Autoeficacia del Estudiante: el componente fue construido, integrado en MateLog y operó de forma autónoma durante todo el período experimental. Identifica el perfil de cada estudiante combinando el puntaje de la Escala de Autoeficacia General —que clasifica la autoeficacia como alta o baja— con el desempeño en el Tema 1 —que distingue rendimiento alto de bajo—, produciendo cuatro perfiles: AE_ALTA_A, AE_ALTA_B, AE_BAJA_A y AE_BAJA_B. El perfil se actualiza al término de cada tema a partir del Tema 2, lo que garantiza que la representación del estudiante sea sensible a la evolución de su desempeño a lo largo del curso. La evidencia de su funcionamiento es el registro de los 81 estudiantes de la condición experimental clasificados automáticamente por perfil al concluir el Tema 1, sin intervención del instructor.

El segundo objetivo consistía en construir el Modelo de Adaptación de Respuesta: el componente fue construido, integrado en MateLog y operó de forma autónoma durante todo el período experimental. Convierte el perfil asignado por el Modelo de Autoeficacia del Estudiante en intervenciones pedagógicas concretas a través de dos dimensiones. La primera, configuración de la dificultad, establece el nivel de ejercicios por perfil y habilita las opciones de rescate y reto bajo condiciones específicas de rendimiento. La segunda, respuesta al desempeño, comprende

retroalimentación inmediata diferenciada por perfil y resultado, mensajes de apoyo tipificados según el tipo de intervención requerida y retroalimentación guiada de activación escalonada. La evidencia de su funcionamiento es la emisión continua y diferenciada de intervenciones a lo largo del experimento, documentada en el registro de interacción.

El tercer objetivo consistía en integrar y evaluar el Modelo de Autoeficacia en MateLog, y se cumplió en sus dos vertientes. En cuanto a la integración, ambos componentes operaron de manera continua y sin intervención del instructor en cuatro planteles, con 180 estudiantes distribuidos en condición control ($n = 99$) y condición experimental ($n = 81$). En cuanto a la evaluación, los resultados mostraron un efecto significativo del modelo sobre el rendimiento académico, con una ganancia mayor en el grupo experimental que en el control, y un cambio detectable en la autoeficacia percibida del grupo experimental que no se observó en el grupo control.

En conjunto, el cumplimiento de los tres objetivos específicos implica el cumplimiento del objetivo general. Los resultados demuestran que MateLog con el Modelo de Autoeficacia activo produce una ganancia de aprendizaje significativamente mayor que la versión sin adaptación, y genera un cambio detectable en la autoeficacia percibida del grupo experimental que la versión en condición control no produce. Ambos hallazgos respaldan la viabilidad del modelo como mecanismo de personalización en contextos educativos del nivel medio superior.

7.2 Conclusiones

Este estudio tuvo como propósito diseñar, implementar y evaluar un Modelo de Autoeficacia integrado en un Ambiente Inteligente de Aprendizaje para la enseñanza de lógica matemática en el nivel medio superior. Los tres objetivos específicos del proyecto se cumplieron: se construyó el Modelo de Autoeficacia del Estudiante, se construyó el Modelo de Adaptación de Respuesta y ambos componentes fueron integrados en

MateLog y evaluados en condiciones experimentales reales con estudiantes de preparatoria, tal como se documenta en el Capítulo 6.

La hipótesis de investigación —que la integración de un modelo de autoeficacia en un Ambiente Inteligente de Aprendizaje producirá una diferencia estadísticamente significativa en el desempeño académico y en el nivel de autoeficacia de los estudiantes, en comparación con el uso del sistema sin dicho modelo— se cumplió de forma diferenciada: se confirmó para el rendimiento académico y se sostuvo parcialmente para la autoeficacia percibida.

La integración del Modelo de Autoeficacia del Estudiante y del Modelo de Adaptación de Respuesta en MateLog demostró que es posible clasificar automáticamente a los estudiantes por perfil y adaptar la enseñanza de forma continua en un entorno educativo real, con grupos numerosos y sin intervención del instructor. El uso de dos fuentes de información como entradas del modelo —el puntaje en la Escala de Autoeficacia General y el desempeño en el primer tema del curso— permite distinguir entre perfiles concordantes, en los que la confianza declarada y el rendimiento observado se alinean, y perfiles de discrepancia, en los que existe un desajuste entre ambas variables. Esta distinción es la que habilita estrategias adaptativas diferenciadas, especialmente útiles en los perfiles de discrepancia, que son los de mayor complejidad pedagógica.

En cuanto a los efectos de la intervención, se observó un efecto significativo en el rendimiento académico a favor del grupo experimental: la ganancia mediana del grupo con el modelo activo fue el doble que la del grupo control, y este resultado se sostiene incluso considerando que el grupo experimental partió de un nivel de conocimiento inicial más bajo. En cuanto a la autoeficacia percibida, el efecto fue significativo solo al comparar al grupo experimental consigo mismo entre el inicio y el final del estudio; la comparación entre grupos no alcanzó significancia estadística, aunque la dirección y el tamaño del efecto son los que la teoría de autoeficacia predice (Bandura, 1977).

En conjunto, los resultados respaldan el Modelo de Autoeficacia como un mecanismo viable para personalizar los Ambientes Inteligentes de Aprendizaje en el nivel medio superior.

7.3 Contribuciones de la investigación

Las contribuciones originales de esta investigación al campo de los Ambientes Inteligentes de Aprendizaje y de la autoeficacia computacional son las siguientes.

La primera contribución es el Modelo de Autoeficacia como propuesta de diseño computacional que combina la medición de autoeficacia general con el rendimiento académico observado para clasificar a los estudiantes en perfiles concordantes y de discrepancia. La revisión de la literatura no identificó sistemas que integren de manera práctica más de una fuente de autoeficacia ni que operen con esta combinación de dimensiones como base para la adaptación pedagógica. El modelo aporta, además, un mecanismo de umbral diferenciado por nivel de autoeficacia para la actualización del perfil a partir del segundo tema, lo que introduce una graduación en el apoyo que no depende únicamente del rendimiento absoluto del estudiante.

La segunda contribución es un conjunto de datos de interacción de 180 estudiantes de preparatoria con MateLog durante el estudio experimental. El conjunto incluye respuestas por reactivo, intentos por tema, solicitudes de ayuda, retornos al contenido teórico, decisiones ante las opciones de rescate y reto, tiempos por sección y resultados en los instrumentos de medición de autoeficacia y conocimiento. Estos datos constituyen un recurso para el análisis de comportamiento en entornos adaptativos con componente de autoeficacia, un tipo de conjunto de datos escaso en la literatura del área.

La tercera contribución es MateLog con el Modelo de Autoeficacia integrado como plataforma funcional de investigación. La arquitectura desacoplada, el sistema de bifurcación por condición experimental y el

registro detallado de interacciones permiten continuar realizando pruebas con distintos parámetros del modelo, incorporar nuevas funcionalidades adaptativas y extender el sistema a otros dominios de contenido sin necesidad de rediseñar la base tecnológica.

La cuarta contribución es la validación empírica del modelo en condiciones educativas reales. El estudio se realizó en cuatro planteles distintos de nivel medio superior, con grupos en ambas condiciones por plantel, lo que aporta evidencia de la viabilidad operativa del modelo más allá del laboratorio y en una población para la que los sistemas adaptativos con componente de autoeficacia tienen presencia muy limitada en la literatura.

7.4 Trabajo futuro

Los resultados obtenidos abren varias líneas de investigación y desarrollo, tanto en el diseño experimental como en la evolución del modelo y su alcance.

Una primera línea tiene que ver con la duración de la intervención. Aplicar el modelo durante todo un ciclo escolar, midiendo la autoeficacia en varios momentos intermedios, permitiría observar las trayectorias individuales de los estudiantes, evaluar si el efecto incipiente sobre la autoeficacia se consolida con mayor exposición y relacionar los cambios con eventos concretos del recorrido de aprendizaje.

La escala del estudio representa otra dirección relevante. Repetir el experimento con muestras más grandes permitiría determinar con mayor precisión si la tendencia marginal observada en la ganancia de autoeficacia entre grupos corresponde a un efecto real pero pequeño, o si se trata de una fluctuación que no persiste al aumentar el tamaño muestral.

El modelo del estudiante y su actualización ofrecen también un área de exploración. En su versión actual el perfil se fija al completar el Tema 1 y se recalcula por tema a partir del Tema 2, pero no incorpora señales de involucramiento continuo. MateLog ya registra eventos de interacción —

tiempo por sección, número de retornos al contenido teórico, solicitudes de ayuda, reintentos— que podrían utilizarse como indicadores del grado de compromiso del estudiante durante la sesión y alimentar actualizaciones más sensibles del perfil en intervenciones largas.

Los instrumentos de medición también ofrecen margen de mejora. En estudios donde los estudiantes ya cuentan con familiaridad previa en el dominio, sería conveniente complementar la Escala de Autoeficacia General con escalas específicas del área de conocimiento, ya que un instrumento más cercano al dominio intervenido sería más sensible para detectar los cambios asociados directamente a la intervención.

La generalización del modelo plantea otra línea de interés. La arquitectura del Modelo de Autoeficacia del Estudiante y del Modelo de Adaptación de Respuesta no depende del contenido específico: validarla en otras unidades de lógica matemática, en otras materias y en otros niveles educativos permitiría establecer hasta qué punto los mecanismos de clasificación y adaptación se sostienen más allá del dominio en que fueron diseñados. Una dirección complementaria sería comparar el modelo con otras estrategias de personalización —adaptación por nivel de conocimiento, por estilo de aprendizaje, por gamificación— para identificar qué aporta específicamente la dimensión de autoeficacia respecto a otras formas de adaptación.

Finalmente, quedan pendientes dos extensiones técnicas y metodológicas. La retroalimentación actual sigue plantillas fijas según el perfil y el resultado del ejercicio; integrar modelos de lenguaje permitiría generar retroalimentación adaptada al error concreto del estudiante, manteniendo la lógica adaptativa del modelo sin sacrificar la especificidad de la respuesta. Por otro lado, complementar el análisis cuantitativo con entrevistas y observación en el aula ayudaría a comprender cómo los estudiantes interpretan las intervenciones adaptativas y qué uso real dan a las herramientas de rescate, reto y botón de ayuda, información que los datos de interacción por sí solos no permiten obtener.

Referencias

- Adjei, S. A., & Heffernan, N. T. (2015). Improving learning maps using an adaptive testing system: PLACEments. En *Lecture Notes in Computer Science* (pp. 517–520). Springer International Publishing.
- Afari, E., & Eksail, F. A. A. (2022). Relationship between learning environment and academic achievement: Mediating role of academic self-efficacy. En M. S. Khine & T. Nielsen (Eds.), *Academic self-efficacy in education* (pp. 179–190). Springer. https://doi.org/10.1007/978-981-16-8240-7_11
- AlAli, R., & Wardat, Y. (2024). Exploring students' mathematical literacy: The role of self-efficacy and learning environment. *Environment and Social Psychology*, 9(8). <https://doi.org/10.59429/esp.v9i8.2838>
- Al-Darei, I. S., & Elhag, A. (2022). The effect of feedback type in the e-learning environment on students' achievement and motivation. *Journal of Educational Technology and Online Learning*, 5(3), 694–705. <https://doi.org/10.31681/jetol.1111527>
- Alqurashi, E. (2016). Self-efficacy in online learning environments: A literature review. *Contemporary Issues in Education Research*, 9(1), 45–52. <https://doi.org/10.19030/cier.v9i1.9549>
- Baessler, J., & Schwarzer, R. (1996). Evaluación de la autoeficacia: Adaptación española de la escala de Autoeficacia General. *Ansiedad y Estrés*, 2(1), 1–8.
- Bandura, A. (1977). Self-efficacy: Toward a unifying theory of behavioral change. *Psychological Review*, 84(2), 191–215. <https://doi.org/10.1037/0033-295X.84.2.191>
- Bandura, A. (1986). *Social foundations of thought and action: A social cognitive theory*. Prentice-Hall.

- Bandura, A. (1995). Exercise of personal and collective efficacy in changing societies. En A. Bandura (Ed.), *Self-efficacy in changing societies* (pp. 1–45). Cambridge University Press.
- Bandura, A. (1997). *Self-efficacy: The exercise of control*. W. H. Freeman.
- Bandura, A., Caprara, G. V., Barbaranelli, C., Gerbino, M., & Pastorelli, C. (1999). Self-efficacy beliefs as shapers of children's aspirations and career trajectories. *Child Development*, 72(1), 187–206. <https://doi.org/10.1111/1467-8624.00273>
- Bandura, A. (2006). Guide for constructing self-efficacy scales. En F. Pajares & T. Urdan (Eds.), *Self-efficacy beliefs of adolescents* (pp. 307–337). Information Age Publishing.
- Bicknell, K., Brust, C., & Settles, B. (2023). How Duolingo's AI learns what you need to learn: The language-learning app tries to emulate a great human tutor. *IEEE Spectrum*, 60(3), 28–33. <https://doi.org/10.1109/MSPEC.2023.10061631>
- Bounhar, T., Yamak, Z., Havard, V., & Baudry, D. (2022). A dataset and methodology for self-efficacy feeling prediction during Industry 4.0 VR activity. En *2022 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)* (pp. 176–182). IEEE. <https://doi.org/10.1109/VRW55335.2022.00046>
- Bradáč, V., & Kostolányová, K. (2017). Intelligent tutoring systems. *Journal of Intelligent Systems*, 26(4), 717–727. <https://doi.org/10.1515/jisys-2015-0144>
- Bradáč, V., Smolka, P., Kotyrba, M., & Průdek, T. (2022). Design of an intelligent tutoring system to create a personalized study plan using expert systems. *Applied Sciences*, 12(12), 6236. <https://doi.org/10.3390/app12126236>
- Burns, H. L., & Capps, C. G. (1988). Foundations of intelligent tutoring systems: An introduction. En M. C. Polson & J. J. Richardson (Eds.), *Foundations*

of intelligent tutoring systems (pp. 1–19). Lawrence Erlbaum Associates.

- Capone, R. (2022). Blended learning and student-centered active learning environment: A case study with STEM undergraduate students. *Canadian Journal of Science, Mathematics and Technology Education*, 22(1), 210–236. <https://doi.org/10.1007/s42330-022-00195-5>
- Carbonell, J. R. (1970). AI in CAI: An Artificial-Intelligence Approach to Computer-Assisted Instruction. *IEEE Transactions on Man-Machine Systems*, 11(4), 190–202.
- Carbonell Bernal, N., & Hernández Prados, M. A. (2024). Impacto de los sistemas de tutoría inteligente: Una revisión sistemática. *Edutec: Revista Electrónica de Tecnología Educativa*, 89, 121–143.
- Castro-Schez, J. J., Glez-Morcillo, C., Albusac, J., & Vallejo, D. (2021). An intelligent tutoring system for supporting active learning: A case study on predictive parsing learning. *Information Sciences*, 544, 446–468. <https://doi.org/10.1016/j.ins.2020.08.079>
- Chahal, J. (2022). Effect of computer and internet self-efficacy on students' acceptance of e-learning: Analysis of TAM model using PLS SEM approach. En *2022 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)* (pp. 257–262). IEEE.
- Corona-González, C. E., Ramos-Flores, M., Alonso-Valerdi, L. M., Ibarra-Zarate, D. I., & Issa-Garcia, V. (2024). Psychophysiological evaluation of the Smartick method in children with reading and mathematical difficulties. *Frontiers in Human Neuroscience*, 18, 1287544.
- Craig, S. D., Driscoll, D. M., & Gholson, B. (2004). Constructing knowledge from dialog in an intelligent tutoring system: Interactive learning, vicarious learning, and pedagogical agents. *Journal of Educational Multimedia and Hypermedia*, 13(2), 163–183.

- Díaz Mujica, A. E., Sáez Delgado, F., Cobo-Rendón, R., & Pérez, M. V. (2022). Revisión sistemática sobre autoeficacia en universitarios: Conceptualización y medición. *Interdisciplinaria: Revista de Psicología y Ciencias Afines*, 39(2), 37–54. <https://doi.org/10.16888/interd.2022.39.2.3>
- Doignon, J.-P., & Falmagne, J.-C. (1985). Spaces for the assessment of knowledge. *International Journal of Man-Machine Studies*, 23(2), 175–196.
- Eryılmaz, M., & Adabashi, A. (2020). Development of an intelligent tutoring system using Bayesian networks and fuzzy logic for a higher student academic performance. *Applied Sciences*, 10(19), 6638. <https://doi.org/10.3390/app10196638>
- Espasa, A., Mayordomo, R. M., Guasch, T., & Martinez-Melo, M. (2022). Does the type of feedback channel used in online learning environments matter? Students' perceptions and impact on learning. *Active Learning in Higher Education*, 23(1), 49–63. <https://doi.org/10.1177/1469787419891307>
- Fernández-Herrero, J. (2024). Evaluating recent advances in affective intelligent tutoring systems: A scoping review of educational impacts and future prospects. *Education Sciences*, 14(8), 839. <https://doi.org/10.3390/educsci14080839>
- Flammer, A. (1995). Developmental analysis of control beliefs. En A. Bandura (Ed.), *Self-efficacy in changing societies* (pp. 69–113). Cambridge University Press.
- García-Fernández, J. M., Inglés-Saura, C. J., Vicent, M., González, C., Lagos-San Martín, N., & Pérez-Sánchez, A. M. (2016). Relación entre autoeficacia y autoatribuciones académicas en estudiantes chilenos. *Universitas Psychologica*, 15(1). <https://doi.org/10.11144/javeriana.upsy15-1.raaa>

- Graefen, B., & Fazal, N. (2024). Chat bots to virtual tutors: An overview of chat GPT's role in the future of education. *Archives of Pharmacy Practice*, 15(2), 43–52. <https://doi.org/10.51847/touppjedsx>
- Grawemeyer, B., Mavrikis, M., Holmes, W., & Gutiérrez-Santos, S. (2015). Adapting feedback types according to students' affective states. En C. Conati, N. Heffernan, A. Mitrovic & M. F. Verdejo (Eds.), *Artificial Intelligence in Education. AIED 2015* (Lecture Notes in Computer Science, Vol. 9112, pp. 586–590). Springer. https://doi.org/10.1007/978-3-319-19773-9_68
- Guzmán, E., & Conejo, R. (2015). Measuring misconceptions through item response theory. En *Lecture Notes in Computer Science* (pp. 608–611). Springer International Publishing.
- Heffernan, N. T., & Heffernan, C. L. (2014). The ASSISTments ecosystem: Building a platform that brings scientists and teachers together for minimally invasive research on human learning and teaching. *International Journal of Artificial Intelligence in Education*, 24(4), 470–497.
- Hill, S., & Suppes, P. (1968). *Introducción a la lógica matemática*. Reverte Ediciones.
- Hodges, C. B. (2008). Self-efficacy in the context of online learning environments: A review of the literature and directions for research. *Performance Improvement Quarterly*, 20(3–4), 7–25. <https://doi.org/10.1002/piq.20001>
- Holmes, W., Mavrikis, M., Hansen, A., & Grawemeyer, B. (2015). Purpose and level of feedback in an exploratory learning environment for fractions. En C. Conati, N. Heffernan, A. Mitrovic & M. F. Verdejo (Eds.), *Artificial Intelligence in Education. AIED 2015* (Lecture Notes in Computer Science, Vol. 9112, pp. 620–623). Springer. https://doi.org/10.1007/978-3-319-19773-9_76

- Hu, Y.-H. (2021). Effects and acceptance of precision education in an AI-supported smart learning environment. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-021-10664-3>
- Kooker, J. W., Zaini, R., & Arroyo, I. (2021). Simulating the dynamics of self-regulation, emotion, grit, and student performance in cyber-learning environments. *Metacognition and Learning*, 16(2), 367–405. <https://doi.org/10.1007/s11409-020-09252-6>
- Liang, J., Wang, L., Luo, J., Yan, Y., & Fan, C. (2023). The relationship between student interaction with generative artificial intelligence and learning achievement: Serial mediating roles of self-efficacy and cognitive engagement. *Frontiers in Psychology*, 14, 1285392. <https://doi.org/10.3389/fpsyg.2023.1285392>
- Lippert, A., Shubeck, K., Morgan, B., Hampton, A., & Graesser, A. (2020). Multiple agent designs in conversational intelligent tutoring systems. *Technology Knowledge and Learning*, 25(3), 443–463. <https://doi.org/10.1007/s10758-019-09431-8>
- Lumbantobing, P. A. (2020). The contribution of lecturer pedagogical competence, intellectual intelligence and self-efficacy of student learning motivation. *Budapest International Research and Critics in Linguistics and Education Journal*, 3(1), 564–573. <https://doi.org/10.33258/birle.v3i1.852>
- Maestro-Prieto, J. A., & Simon-Hurtado, A. (2018). The pedagogical model of SIAL: An adaptive and open-ended intelligent tutoring system for first order logic. *Proceedings of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education*.
- Malone, T. W., & Lepper, M. R. (1987). Making learning fun: A taxonomy of intrinsic motivations for learning. En R. E. Snow & M. J. Farr (Eds.), *Aptitude, learning, and instruction: Vol. 3. Cognitive and affective process analyses* (pp. 223–253). Lawrence Erlbaum Associates.

- Marouf, A., Al-Dahdooh, R., Abu Ghali, M. J., Mahdi, A. O., Abunasser, B. S., & Abu-Naser, S. S. (2024). Enhancing education with artificial intelligence: The role of intelligent tutoring systems. *International Journal of Engineering and Information Systems*, 8(8), 10–16.
- Masimba, F., & Maguraushe, K. (2022). Understanding e-learning adoption and acceptance during the COVID-19 pandemic: The influence of self-efficacy. En *2022 1st Zimbabwe Conference of Information and Communication Technologies (ZCICT)* (pp. 1–6). IEEE.
- Mavrikis, M., & Holmes, W. (2019). Intelligent learning environments: Design, usage and analytics for future schools. En S. Yu, H. Niemi & J. Mason (Eds.), *Shaping future schools with digital technology* (pp. 57–73). Springer. https://doi.org/10.1007/978-981-13-9439-3_4
- McQuiggan, S. W., & Lester, J. C. (2006). Diagnosing self-efficacy in intelligent tutoring systems: An empirical study. En M. Ikeda, K. D. Ashley & T. W. Chan (Eds.), *Intelligent Tutoring Systems. ITS 2006* (Lecture Notes in Computer Science, Vol. 4053, pp. 565–574). Springer. https://doi.org/10.1007/11774303_56
- McQuiggan, S. W., Mott, B. W., & Lester, J. C. (2008). Modeling self-efficacy in intelligent tutoring systems: An inductive approach. *User Modeling and User-Adapted Interaction*, 18(1–2), 81–123. <https://doi.org/10.1007/s11257-007-9040-y>
- Mencl, J., Wefald, A. J., & van Ittersum, K. W. (2012). General and specific self-efficacy in the context of a training intervention to enhance performance expectancy. *Performance Improvement Quarterly*, 25(3), 7–24.
- Mendoza Bahena, M. J. (2023). *Análisis y modelado de la autoeficacia en el aprendizaje a través de minería de datos educativos* [Tesis de maestría en preparación]. Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET).

- Meng, Q., & Zhang, Q. (2023). The influence of academic self-efficacy on university students' academic performance: The mediating effect of academic engagement. *Sustainability*, 15(7), 5767. <https://doi.org/10.3390/su15075767>
- Mills, C., Bosch, N., Krasich, K., & D'Mello, S. K. (2019). Reducing mind-wandering during vicarious learning from an intelligent tutoring system. En *Lecture Notes in Computer Science* (pp. 296–307). Springer International Publishing.
- Mitchell, K. M., McMillan, D. E., Lobchuk, M. M., Nickel, N. C., Rabbani, R., & Li, J. (2021). Development and validation of the situated academic writing self-efficacy scale (SAWSES). *Assessing Writing*, 48, 100524. <https://doi.org/10.1016/j.asw.2021.100524>
- Mitrovic, A., & Ohlsson, S. (1999). Evaluation of a constraint-based tutor for a database language. *International Journal of Artificial Intelligence in Education*, 10, 238–256.
- Murray, T. (1999). Authoring intelligent tutoring systems: An analysis of the state of the art. *International Journal of Artificial Intelligence in Education*, 10(1), 98–129.
- Oettingen, G. (1995). Cross-cultural perspectives on self-efficacy. En A. Bandura (Ed.), *Self-efficacy in changing societies* (pp. 149–176). Cambridge University Press.
- Pajares, F. (1997). Current directions in self-efficacy research. En M. Maehr & P. R. Pintrich (Eds.), *Advances in motivation and achievement* (Vol. 10, pp. 1–49). JAI Press.
- Papoušek, J., & Pelánek, R. (2015). Impact of adaptive educational system behaviour on student motivation. En *Lecture Notes in Computer Science* (pp. 348–357). Springer International Publishing.

- Pérez García, A. M., Bermúdez Moreno, J., & Sanjuán Suárez, P. (2000). Escala de autoeficacia general: Datos psicométricos de la adaptación para población española. *Psicothema*, 12(supl. 2), 509–513.
- Pérez Olguín, I. J. C., & Chávez Vega, N. B. (2021). *Sistema de tutores inteligentes: Una revisión de literatura*. Instituto de Ingeniería y Tecnología.
- Pourmirzaei, M., Montazer, G. A., & Mousavi, E. (2023). ATTENDEE: An affective tutoring system based on facial emotion recognition and head pose estimation to personalize e-learning environment. *Journal of Computers in Education*. <https://doi.org/10.1007/s40692-023-00303-w>
- Ritter, S., Anderson, J. R., Koedinger, K. R., & Corbett, A. (2007). Cognitive tutor: Applied research in mathematics education. *Psychonomic Bulletin & Review*, 14(2), 249–255.
- Rodríguez Chávez, M. H. (2021). Sistemas de tutoría inteligente y su aplicación en la educación superior. *RIDE: Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 11(22). <https://doi.org/10.23913/ride.v11i22.848>
- Rotter, J. B. (1966). Generalized expectancies for internal versus external control of reinforcement. *Psychological Monographs: General and Applied*, 80(1), 1–28. <https://doi.org/10.1037/h0092976>
- Schneewind, K. A. (1995). Impact of family processes on control beliefs. En A. Bandura (Ed.), *Self-efficacy in changing societies* (pp. 114–148). Cambridge University Press.
- Scholz, U., Doña, B. G., Sud, S., & Schwarzer, R. (2002). Is general self-efficacy a universal construct? Psychometric findings from 25 countries. *European Journal of Psychological Assessment*, 18(3), 242–251. <https://doi.org/10.1027//1015-5759.18.3.242>

- Schunk, D. H. (1983). Ability versus effort attributional feedback: Differential effects on self-efficacy and achievement. *Journal of Educational Psychology*, 75(6), 848–856.
- Schunk, D. H. (1989). Self-efficacy and achievement behaviors. *Educational Psychology Review*, 1(3), 173–208. <https://doi.org/10.1007/BF01320134>
- Schwarzer, R., & Jerusalem, M. (1995). Generalized Self-Efficacy scale. En J. Weinman, S. Wright & M. Johnston (Eds.), *Measures in health psychology: A user's portfolio. Causal and control beliefs* (pp. 35–37). NFER-NELSON.
- Schwarzer, R., Baessler, J., Kwiatek, P., Schröder, K., & Zhang, J. X. (2005). General self-efficacy in various domains of human functioning: Evidence from five countries. *International Journal of Psychology*, 40(2), 80–89.
- Seligman, M. E. P. (1991). *Learned optimism*. A. A. Knopf.
- Sergent, T., Daniel, M., Bouchet, F., & Carron, T. (2024). How can self-evaluation and self-efficacy skills of young learners be scaffolded in a web application? *IEEE Transactions on Learning Technologies*, 17, 1184–1197.
- Shahzad, M. F., Xu, S., & Zahid, H. (2024). Exploring the impact of generative AI-based technologies on learning performance through self-efficacy, fairness & ethics, creativity, and trust in higher education. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-024-12949-9>
- Shavelson, R. J., Hubner, J. J., & Stanton, G. C. (1976). Self-concept: Validation of construct interpretations. *Review of Educational Research*, 46(3), 407–441. <https://doi.org/10.3102/00346543046003407>
- Sherer, M., Maddux, J. E., Mercandante, B., Prentice-Dunn, S., Jacobs, B., & Rogers, R. W. (1982). The self-efficacy scale: Construction and

- validation. *Psychological Reports*, 51(2), 663–671.
<https://doi.org/10.2466/pr0.1982.51.2.663>
- Shi, G., Wang, L., Zhang, L., Shubeck, K., Peng, S., Hu, X., & Graesser, A. C. (2021). The adaptive features of an intelligent tutoring system for adult literacy. En *Adaptive Instructional Systems. Design and Evaluation* (pp. 592–603). Springer International Publishing.
- Shimizu, Y. (2022). Relation between mathematical proof problem solving, math anxiety, self-efficacy, learning engagement, and backward reasoning. *Journal of Education and Learning*, 11(6), 62.
- Susanti, V. D., & Wulandari, R. (2021). Student difficulties in solving mathematics questions based on mathematical logic intelligence during the COVID-19 pandemic. *AKSIOMA Jurnal Program Studi Pendidikan Matematika*, 10(3), 1848.
<https://doi.org/10.24127/ajpm.v10i3.4034>
- Tang, K.-Y., Chang, C.-Y., & Hwang, G.-J. (2021). Trends in artificial intelligence-supported e-learning: A systematic review and co-citation network analysis (1998–2019). *Interactive Learning Environments*.
<https://doi.org/10.1080/10494820.2021.1875001>
- Tsai, C.-L., Chaichanasakul, A., Zhao, R., Flores, L. Y., & Lopez, S. J. (2014). Development and validation of the Strengths Self-Efficacy Scale (SSES). *Journal of Career Assessment*, 22(2), 221–232.
<https://doi.org/10.1177/1069072713493761>
- Valencia Vallejo, N. (2021). *Desarrollo de la autoeficacia y la metacognición en ambientes e-learning: Andamiajes computacionales para favorecer el logro de aprendizaje*. Universidad Pedagógica Nacional.
- Van der Kleij, F. M., Feskens, R. C. W., & Eggen, T. J. H. M. (2015). Effects of feedback in a computer-based learning environment on students' learning outcomes: A meta-analysis. *Review of Educational Research*, 85(4), 475–511. <https://doi.org/10.3102/0034654314564881>

- van Zyl, L. E., Klibert, J., Shankland, R., See-To, E. W. K., & Rothmann, S. (2022). The General Academic Self-Efficacy Scale: Psychometric properties, longitudinal invariance, and criterion validity. *Journal of Psychoeducational Assessment*, 40(6), 777–789. <https://doi.org/10.1177/07342829221097174>
- Vandewaetere, M., Desmet, P., & Clarebout, G. (2011). The contribution of learner characteristics in the development of computer-based adaptive learning environments. *Computers in Human Behavior*, 27(1), 118–130. <https://doi.org/10.1016/j.chb.2010.07.038>
- VanLehn, K., Lynch, C., Schulze, K., Shapiro, J. A., Shelby, R., Taylor, L., Treacy, D., Weinstein, A., & Wintersgill, M. (2005). The Andes Physics Tutoring System: Lessons learned. *International Journal of Artificial Intelligence in Education*, 15(3), 147–204.
- Weiner, B. (1985). An attributional theory of achievement motivation and emotion. *Psychological Review*, 92(4), 548–573. <https://doi.org/10.1037/0033-295X.92.4.548>
- Woolf, B. P. (2009). *Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning*. Morgan Kaufmann.
- Zarrin, F., & Montazer, G. (2019). Personalizing the e-learning environment based on learner self-efficacy. *Journal of Technology and Education*, 13(4), 141–154. <https://doi.org/10.22061/JTE.2018.3137.1911>
- Zhang, T., & Li, F. (2021). The influence of online learning self-efficacy on learning engagement among middle school students: The mediating role of learning motivation. En *2021 16th International Conference on Computer Science & Education (ICCSE)* (pp. 61–65). IEEE.
- Zimmerman, B. J. (1995). Self-efficacy and educational development. En A. Bandura (Ed.), *Self-efficacy in changing societies* (pp. 202–231). Cambridge University Press.


Zimmerman, B. J. (2000). Self-efficacy: An essential motive to learn. *Contemporary Educational Psychology*, 25(1), 82–91.
<https://doi.org/10.1006/ceps.1999.1016>

Anexo A. Interfaz de MateLog

Las capturas de pantalla presentadas en este anexo ilustran el flujo completo de MateLog tal como lo experimentó el estudiante durante el protocolo experimental, organizado en el orden de acceso descrito en la Sección 5.3.1. Las imágenes se agrupan por etapa o funcionalidad y cubren tanto la experiencia compartida por ambas condiciones como las pantallas exclusivas de la condición experimental, donde el Modelo de Autoeficacia se encontraba activo.

A.1 Registro e inicio de sesión

El acceso a MateLog requiere el ingreso de un código de acceso que vincula al estudiante con su plantel, grupo y condición experimental.



The image displays two side-by-side screenshots of the MateLog web application interface, which has a purple and white color scheme. Both screens feature the 'MateLog' logo and the subtitle 'Aprendizaje de Lógica Matemática' at the top.

The left screenshot shows the 'Registrarse' (Register) page. It includes tabs for 'Iniciar Sesión' and 'Registrarse', with the latter being active. The registration form contains the following fields: 'Usuario' (with 'MateLog' entered), 'Contraseña' (with the placeholder 'Mínimo 8 caracteres'), 'Confirmar Contraseña' (with the placeholder 'Repite tu contraseña'), 'Código de Participación' (with the placeholder 'Código proporcionado por tu instructor'), 'Género' (a dropdown menu showing 'Selecciona...'), and 'Edad' (a dropdown menu showing 'Selecciona...'). A blue 'Registrarse' button is at the bottom.

The right screenshot shows the 'Iniciar Sesión' (Login) page. It has the same header and tabs, but the 'Iniciar Sesión' tab is active. The login form includes the 'Usuario' field (with 'MateLog' entered) and the 'Contraseña' field (with masked characters '*****'). A blue 'Iniciar Sesión' button is positioned below the password field.

Figura A.1 Pantalla de bienvenida e ingreso del código de acceso.

A.2 Escala de Autoeficacia General — pre-test

Inmediatamente después del registro, el estudiante responde la Escala de Autoeficacia General antes de acceder al contenido del curso.

Cuestionario Inicial Antes de comenzar el curso, nos gustaría conocerte mejor. Instrucciones: • Lee cuidadosamente cada una de las siguientes 10 oraciones y selecciona la opción que mejor describa tu nivel de acuerdo. • No hay respuestas correctas o incorrectas • No te llevará más de 3 minutos Iniciar Cuestionario	Cuestionario inicial Pregunta 1 Puedo encontrar la manera de obtener lo que quiero, aunque alguien se me oponga. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 2 Puedo resolver problemas difíciles si me esfuerzo lo suficiente. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 3 Me es fácil persistir en lo que me he propuesto hasta llegar a alcanzar mis metas. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente
Cuestionario inicial Pregunta 4 Tengo confianza en que podría manejar eficazmente eventos inesperados. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 5 Gracias a mis cualidades y recursos puedo superar situaciones imprevistas. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 6 Cuando me encuentro en dificultades puedo permanecer tranquilo/a porque cuento con las habilidades necesarias para manejar situaciones difíciles. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 7 Venga lo que venga, por lo general soy capaz de manejarlo. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente
Cuestionario inicial Pregunta 8 Puedo resolver la mayoría de los problemas si me esfuerzo lo necesario. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 9 Si me encuentro en una situación difícil, generalmente se me ocurre qué debo hacer. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario inicial Pregunta 10 Al enfrentarme a un problema, generalmente se me ocurren varias alternativas de cómo resolverlo. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Finalizar Cuestionario	

Figura A.2 Pantalla de instrucciones de la Escala de Autoeficacia General, e interfaz de respuesta de los 10 ítem de la escala con sus cuatro opciones.

A.3 Examen diagnóstico

Al concluir la escala, el estudiante realiza el examen diagnóstico, cuyos resultados establecen la línea base de conocimiento.

Examen Diagnóstico

Esta prueba evaluará tus conocimientos previos en Lógica Matemática.

Instrucciones:

- Lee cada una de las 10 preguntas cuidadosamente y selecciona la respuesta que consideres correcta
- Es normal no estar seguro de la respuesta correcta antes de iniciar el curso. Si te ocurre, no te preocupes: siempre puedes elegir la opción "No lo sé"
- No te llevará más de 5 minutos

Iniciar Prueba

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 1

¿Cómo se define a una proposición que no contiene términos de enlace?

☐ A) Moleculares

☐ B) Atómicas

☐ C) Condicional

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 2

¿Qué tipo de proposición se forma al unir dos ideas mediante un término de enlace?

☐ A) Atómica

☐ B) Molecular

☐ C) Simple

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 3

¿De qué depende únicamente la forma de una proposición molecular?

☐ A) Contenido

☐ B) Término de enlace

☐ C) Verdad de las partes

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 4

Si en una proposición molecular sustituimos las atómicas por otras cualesquiera, ¿qué ocurre con la forma?

☐ A) Cambia

☐ B) Desaparece

☐ C) Se conserva

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 5

¿Cuál es el símbolo lógico que representa a la disyunción («o»)?

☐ A) &

☐ B) v

☐ C) →

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 6

¿Cómo debe definirse una proposición en el diccionario antes de aplicarle una negación?

☐ A) Negativa

☐ B) Afirmativa

☐ C) Ambas

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 7

¿Para qué se utilizan primordialmente los paréntesis en una proposición molecular?

☐ A) Mostrar la forma y señalar el dominante

☐ B) Sustituir letras

☐ C) Hacer la frase larga

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 8

¿Cuál es la forma lógica representativa para la disyunción?

☐ A) «si» (_) «, entonces» (_)

☐ B) (_) «y» (_)

☒ C) (_) «o» (_)

☐ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 9

¿Qué sucede cuando una fórmula presenta los signos & y v sin paréntesis?

☐ A) Ambigüedad

☐ B) Claridad absoluta

☐ C) Veracidad

☒ D) No lo sé

Siguiente

Examen diagnóstico

En esta sección evaluaremos tus conocimientos previos en Lógica Matemática. No te preocupes si no estás seguro de la respuesta correcta, siempre puedes elegir la opción "No lo sé".

Pregunta 10

De acuerdo con las reglas de potencia, ¿cuál es el término de enlace más fuerte?

☐ A) Negación

☐ B) Conjunción

☒ C) Condicional

☐ D) No lo sé

Finalizar Examen

¡Examen diagnóstico Completado!

No te preocupes por la calificación de este examen. Su propósito es servir como punto de partida y, al finalizar el curso, nos permitirá valorar el conocimiento que habrás adquirido.

Ir al curso

Figura A.3 Pantalla de instrucciones del examen diagnóstico, los 10 reactivos de opción múltiple que incluyen la opción "No lo sé" y pantalla de conclusión del examen diagnóstico.

A.4 Inicio del curso y vista de lecciones y temas

Una vez completado el examen diagnóstico, el estudiante accede al contenido del curso con un esquema de desbloqueo secuencial.




Figura A.4 Pantalla con descripción e instrucciones del curso, vista principal del curso mostrando los cinco temas y el estado de desbloqueo.

A.5 Teoría y ejemplos

La presentación del contenido teórico se organiza en segmentos breves con ejemplos intercalados a lo largo del tema.

The figure displays a sequence of 16 screenshots from a digital learning interface, organized into a 4x4 grid. Each screenshot represents a segment of the 'Tema 1: Proposiciones' (Topic 1: Propositions) course. The segments are as follows:

- Row 1:**
 - Segment 1: Introduction to logic and propositional logic. Text: 'Con el estudio de la Lógica se persigue llegar a un razonamiento preciso y cuidadoso. La Lógica tiene un lenguaje exacto, por lo que es necesario redactar un conjunto de reglas que sean perfectamente claras y definidas, libres de ambigüedades. Al final de este curso podrás ser capaz de entender y expresar enunciados como el siguiente: P & (Q V R)'. Navigation: 'Continuar'.
 - Segment 2: Definition of propositions. Text: 'Las proposiciones son el punto de partida para el estudio de la lógica. Para comenzar este estudio, se consideran las proposiciones en lengua castellana. Cada proposición posee una forma lógica a la que se le asignará un nombre. En Lógica, se simbolizan y se distinguen dos clases de proposiciones: 1. Proposiciones atómicas. 2. Proposiciones moleculares.' Navigation: 'Regresar', 'Continuar'.
 - Segment 3: Atomic propositions. Text: 'Proposiciones atómicas: Las proposiciones atómicas son la base fundamental en la Lógica. Son aquellas de **forma más simple o más básicas**. Se define como una **proposición completa que se presenta sin términos de enlace**.' Navigation: 'Regresar', 'Continuar'.
 - Segment 4: Examples of atomic propositions. Text: 'Ejemplo: Las siguientes son **proposiciones atómicas**: • "Hoy es sábado". • "No hay clases".' Navigation: 'Regresar', 'Continuar', 'Ver otro ejemplo'.
- Row 2:**
 - Segment 5: Extra example of atomic propositions. Text: 'Ejemplo Extra: Las siguientes también son **proposiciones atómicas**: • "La comida será hoy a las tres en punto". • "Se puede encontrar a Juana en casa de Susana".' Navigation: 'Regresar', 'Continuar'.
 - Segment 6: Molecular propositions. Text: 'Proposiciones moleculares: Las proposiciones moleculares se forman al juntar una o varias proposiciones atómicas utilizando un término de enlace. Términos de enlace de proposiciones: Se utilizan para formar proposiciones moleculares a partir de proposiciones atómicas. Los más comunes son las palabras: "y", "o", "si...", "entonces", y "no".' Navigation: 'Regresar', 'Continuar'.
 - Segment 7: Example of molecular propositions. Text: 'Ejemplo: Si se consideran las proposiciones atómicas "Hoy es sábado" y "No hay clases", al unirlos mediante el término de enlace «y», se obtiene la proposición molecular "**Hoy es sábado y no hay clases**".' Navigation: 'Regresar', 'Continuar', 'Ver otro ejemplo'.
 - Segment 8: Extra example of molecular propositions. Text: 'Ejemplo Extra: Las siguientes también son proposiciones moleculares: • El viento arrastrará las nubes o lloverá hoy con seguridad. • A las focas **no** les crece el pelo. • Si estamos en diciembre **entonces** pronto llegará la navidad.' Navigation: 'Regresar', 'Continuar', 'Ver otro ejemplo'.
- Row 3:**
 - Segment 9: Logical connectives. Text: 'Los tres términos de enlace considerados, «y», «o», «si...», **entonces**, se usan para enlazar dos proposiciones atómicas, pero el término de enlace «no» se agrega a una sola proposición atómica para formar una molecular. Se puede decir que el término de enlace «no» cada vez **actúa sobre una sola proposición atómica** y que **los otros términos de enlace actúan sobre dos proposiciones atómicas a la vez**.' Navigation: 'Regresar', 'Continuar'.
 - Segment 10: Example of a molecular proposition. Text: 'Ejemplo: La proposición "**La luna no está hecha de queso verde**" es una proposición molecular que utiliza el término de enlace «no».' Navigation: 'Regresar', 'Continuar', 'Ver otro ejemplo'.
 - Segment 11: Extra example of a molecular proposition. Text: 'Ejemplo Extra: La proposición "**No todos los líquidos hierven a la misma temperatura**" es una proposición que utiliza el término de enlace «no».' Navigation: 'Regresar', 'Continuar', 'Ver otro ejemplo'.
 - Segment 12: Summary of atomic propositions. Text: 'Ver otro ejemplo: En resumen, las **proposiciones atómicas** son enunciados simples e indivisibles, es decir, no contienen conectores lógicos. Los **términos de enlace** son precisamente esos conectores lógicos (como «y», «o», «no», «si... entonces...») que se aplican sobre las proposiciones atómicas. Y, las **proposiciones moleculares** son enunciados más complejos que se forman al unir una o más proposiciones atómicas mediante dichos conectores.' Navigation: 'Regresar', 'Ir a Ejercicios'.

Figura A.5 Segmento de teoría con texto y ejemplos integrado en el flujo de aprendizaje.

A.6 Sección de ejercicios

Los ejercicios de cada tema se presentan en un formato de reactivos individuales con controles de navegación disponibles durante la sesión.

The figure displays three sequential screens for 'Tema 1: Proposiciones'. Each screen features a purple header with the topic name, a yellow 'Ver Ayuda' button, and a question prompt. Below the prompt are three radio button options labeled A, B, and C. At the bottom of each screen is a purple 'Enviar Respuesta' button and a light blue '← Volver al Tema' button.

Ejercicio 2: Seleccione la opción correcta. Una proposición atómica se define como:

- ☐ A. Cualquier proposición que es negada por el término "no"
- ☐ B. Una proposición molecular que no contiene más de dos términos de enlace.
- ☐ C. Una proposición completa que se presenta sin términos de enlace

Ejercicio 3: Seleccione la opción correcta. El término de enlace se utiliza para:

- ☐ A. Definir la forma lógica de una proposición atómica
- ☐ B. Formar proposiciones moleculares a partir de proposiciones atómicas
- ☐ C. Determinar si una proposición es verdadera o falsa.

Ejercicio 4: Elige a qué tipo de proposición pertenece la siguiente oración: La comida será hoy a las tres en punto.

- ☐ A. Proposición Atómica
- ☐ B. Proposición Molecular

Figura A.6 Pantallas con ejercicios con las alternativas de respuesta.

A.7 Botón de ayuda contextual

El botón de ayuda muestra un mensaje orientador superpuesto sobre la pantalla del ejercicio activo, invocable y cerrable en cualquier momento.




Figura A.7 Ejercicio en estado estándar, con el botón de ayuda disponible activado, y su variante que aparece después del tercer intento para los perfiles de AE_ALTA_B y AE_BAJA_B únicamente en los ejercicios que tuvieron respuesta incorrecta en el intento anterior.

A.8 Retroalimentación inmediata por perfil

Al concluir cada ejercicio, el sistema entrega retroalimentación cuyo contenido varía según el perfil del estudiante y el resultado del reactivo, conforme a la Tabla 4.14.




Figura A.8 Ejemplos de retroalimentación obtenida en respuestas incorrectas y correctas.

A.9 Ejemplos adicionales

Cuando el número de intentos no aprobados supera el umbral del perfil, el sistema activa automáticamente la opción de ver ejemplos adicionales, conforme a la Tabla 4.15.




Figura A.9 Opción de ver ejemplos adicionales relacionados con los ejercicios incorrectos del último intento.

A.10 Opción de rescate

Tras tres intentos no aprobados, el sistema presenta al perfil AE_ALTA_B la opción de cambiar el nivel de dificultad de los ejercicios.



Figura A.10 *Pantalla de oferta de rescate presentada al perfil AE_ALTA_B tras tres intentos no aprobados.*

A.11 Opción de reto

Al aprobar un tema en máximo 2 intentos, el sistema presenta al perfil AE_BAJA_A la opción voluntaria de intentar ejercicios de nivel difícil.




Figura A.11 Pantalla de oferta de reto presentada al perfil AE_BAJA_A al aprobar un tema, interfaz de ejercicios de nivel difícil tras aceptar el reto y reconocimiento entregado al aprobar los ejercicios del reto.

A.12 Opción para terminar curso

A partir de haber aprobado el tercer tema se activa el botón para terminar curso ubicado en la pantalla de Lecciones.




Figura A.12 Pantalla de resultado de intento aprobado con opción de avanzar al tema siguiente.

A.13 Escala de Autoeficacia General — post-test

Al aceptar terminar el curso, el estudiante responde nuevamente la Escala de Autoeficacia General

Cuestionario Final Ahora que has completado las lecciones, nos gustaría conocer nuevamente tu opinión. Instrucciones: • Lee cuidadosamente cada una de las siguientes 10 oraciones y selecciona la opción que mejor describa tu nivel de acuerdo. • No hay respuestas correctas o incorrectas • No te llevará más de 3 minutos Iniciar Cuestionario	Cuestionario final Pregunta 1 Puedo encontrar la manera de obtener lo que quiero, aunque alguien se me oponga. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 2 Puedo resolver problemas difíciles si me esfuerzo lo suficiente. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 3 Me es fácil persistir en lo que me he propuesto hasta llegar a alcanzar mis metas. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente
Cuestionario final Pregunta 4 Tengo confianza en que podría manejar eficazmente eventos inesperados. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 5 Gracias a mis cualidades y recursos puedo superar situaciones imprevistas. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 6 Cuando me encuentro en dificultades puedo permanecer tranquilo/a porque cuento con las habilidades necesarias para manejar situaciones difíciles. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 7 Venga lo que venga, por lo general soy capaz de manejarlo. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente
Cuestionario final Pregunta 8 Puedo resolver la mayoría de los problemas si me esfuerzo lo necesario. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 9 Si me encuentro en una situación difícil, generalmente se me ocurre qué debo hacer. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Siguiente	Cuestionario final Pregunta 10 Al enfrentarme a un problema, generalmente se me ocurren varias alternativas de cómo resolverlo. Selecciona tu nivel de acuerdo: ☐ Nunca ☐ Algunas veces ☐ Muchas veces ☐ Siempre Finalizar Cuestionario	

Figura A.13 Pantalla de instrucciones de la Escala de Autoeficacia General en su aplicación post-test e interfaz de respuesta de los ítems del cuestionario post-test.

A.14 Examen final

Después de la escala post-test, el estudiante realiza el examen final para medir la ganancia de conocimiento.

Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Instrucciones: - Lee cada una de las 10 preguntas cuidadosamente y selecciona la respuesta que consideres correcta - No te llevará más de 5 minutos Iniciar Examen	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 1 Si a una proposición atómica le añadimos un término de enlace y otra idea, ¿en qué se convierte? ☐ A) Molecular ☐ B) Atómica ☐ C) Compuesta ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 2 ¿Qué nombre recibe una proposición con forma simple? ☐ A) Molecular ☐ B) Atómica ☐ C) Particular ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 3 Si en una fórmula lógica cambiamos los enunciados pero mantenemos los mismos enlaces, ¿qué ocurre con la forma lógica? ☐ A) Desaparece ☐ B) Se altera ☐ C) Se mantiene igual ☐ D) No lo sé Siguiente
Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 4 ¿Qué elemento determina exclusivamente la estructura de una proposición molecular? ☐ A) El tema ☐ B) El término de enlace ☐ C) Las palabras descriptivas ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 5 ¿Cuál de los siguientes símbolos es el operador lógico de la conjunción?? ☐ A) & ☐ B) v ☐ C) → ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 6 ¿Cuál es la función principal de los paréntesis para agrupar proposiciones complejas? ☐ A) Definir jerarquía y el enlace dominante ☐ B) Separar letras de números ☐ C) Adornar la fórmula ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 7 Al construir un diccionario de variables, ¿cómo se deben listar las proposiciones antes de ser negadas? ☐ A) Como falsas ☐ B) En sentido afirmativo ☐ C) Con el signo puesto ☐ D) No lo sé Siguiente
Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 8 Según la jerarquía de los conectores (reglas de potencia), ¿cuál tiene mayor peso que la conjunción y la disyunción? ☐ A) Negación ☐ B) Interrogación ☐ C) Condicional ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 9 ¿Qué esquema representa correctamente la estructura de una disyunción en lenguaje natural? ☐ A) Si () entonces () ☐ B) () y () ☐ C) () o () ☐ D) No lo sé Siguiente	Examen Final Este examen evaluará lo que has aprendido durante las lecciones. Selecciona la respuesta que consideres correcta para cada pregunta. No te preocupes si no estás seguro, siempre puedes elegir la opción "No lo sé". Pregunta 10 ¿Cómo se le llama a una fórmula lógica que contiene varios conectores pero carece de signos de agrupación? ☐ A) Ambigua ☐ B) Verdadera ☐ C) Molecular simple ☐ D) No lo sé Finalizar Examen	

Figura A.14 Pantalla de instrucciones del examen final y reactivos del examen final con su formato de opción múltiple.

A.15 Valoración de la plataforma

Al concluir el examen final, el estudiante puede calificar su experiencia con MateLog de forma voluntaria.

The figure displays three sequential screens from the MateLog platform evaluation process. The first screen, titled 'Valora tu experiencia', prompts the user to provide feedback and features a five-star rating system and a text area for comments. The second screen, also titled 'Valora tu experiencia', shows the same form but with the first three stars selected and a pink 'Enviar' button. The third screen, titled 'Gracias por tu valiosa participación', confirms the user's successful completion of the course and includes a 'Cerrar sesión' button.

Valora tu experiencia

Tu opinión nos ayuda a mejorar. Valora tu experiencia y comparte tus comentarios más sinceros, por favor.

★ ★ ★ ★ ★

Escribe tus comentarios y sugerencias aquí sobre lo que más te haya gustado y lo que no (colores, organización, etc.)

Enviar

Valora tu experiencia

Tu opinión nos ayuda a mejorara. Valora tu experiencia y comparte tus comentarios más sinceros, por favor.

★ ★ ★ ★ ★

Comentarios y sugerencias

Enviar

Gracias por tu valiosa participación

Has concluido exitosamente el curso de Lógica Matemática. Tu participación es muy importante para esta investigación.

Cerrar sesión

Figura A.15 Pantalla de valoración de la plataforma con la escala de estrellas y el campo de comentario abierto, seguido de la pantalla de agradecimiento por haber participado

Anexo B. Publicaciones

Durante el desarrollo de este trabajo de tesis se generaron las siguientes publicaciones académicas.

Artículo en congreso. Domínguez-Lara, V., Sánchez-Jiménez, E., Hernández, Y., Ortiz-Hernandez, J., & García-García, S. M. (2025). Towards adaptive tutoring: A proposed self-efficacy behavior model for intelligent learning environments. *Workshop on Intelligent Learning Environments (WILE), MICAI 2025*.

Towards Adaptive Tutoring: A Proposed Self-Efficacy Behavior Model for Intelligent Learning Environments

Victor Domínguez-Lara^[0009-0002-3698-8607], Eduardo Sánchez-Jiménez^[0009-0009-1853-9526], Yasmín Hernández [★][0000-0002-8842-0899], Javier Ortiz-Hernandez^[0000-0002-6481-1537], Sandra Magali García-García^[0000-0001-5633-7241]

Computer Science Department, TecNM/Cenidet, Cuernavaca, Mexico
{m24ce051, d22ce005, yasmin.hp, javier.oh, d23ce168}@cenidet.tecnm.mx

Abstract. Self-efficacy is defined as the belief of individuals in their own capabilities. Academic self-efficacy has been shown to play a crucial role in student success, it can be fostered through educational practices that enable learners to acquire skills while receiving appropriate feedback. A self-efficacy model for an intelligent learning environment is proposed to strengthen the self-efficacy of students and thus improve learning outcomes. The model predicts the self-efficacy of learners and provides pedagogical actions designed to promote it based on pedagogical models. The student's self-efficacy model is grounded in their interaction with the learning environment, while the tutor's self-efficacy model relies on presenting vicarious experiences, mastery experiences, and positive feedback. We hope to achieve empirical evidence on the impact of self-efficacy in adaptive learning systems, and insights about fostering beliefs of students in their own abilities in order to improve motivation, persistence, and academic achievement.

Keywords: Bandura theory, intelligent learning environments · intelligent tutoring system · self-efficacy · student model · vicarious learning.

Figura B.1 Encabezado y Abstract del artículo publicado en el *Workshop on Intelligent Learning Environments (WILE), MICAI 2025*.

Artículo en congreso. Romero-Negrete, R., Urbano, L., Domínguez-Lara, V., Hernández, Y., Ortiz-Hernández, J. (2026). HECTutor: Conversational Tutor based on Generative Artificial Intelligence for Teaching Mathematical Logic. *Congreso Internacional de Tecnología y Ciencia Aplicada (CITCA)*, 2026.

HECTutor: Conversational Tutor based on Generative Artificial Intelligence for Teaching Mathematical Logic

Rafael, Romero-Negrete*, Lizeth, Urbano*, Víctor, Domínguez-Lara, Yasmín, Hernández**, Javier, Ortiz-Hernández****

** Instituto Tecnológico de Cuautla, Yecapixtla, México
{20680176, 20680190}@cuautla.tecnm.mx*

*** Centro Nacional de Investigación y Desarrollo Tecnológico, Cuernavaca, México
{m24ce051, yasmin.hp, javier.oh}@cenidet.tecnm.mx*

Abstract: This article presents HECTutor, an Educational Web Application based on generative artificial intelligence designed to support the teaching of mathematical logic to students at upper-middle and higher education levels. The main objective of the work was to develop an intelligent tutor capable of offering personalized, adaptive, and interactive, learning experiences, addressing the absence of immediate and contextualized feedback, which represents a challenge in the teaching of abstract disciplines. The methodology combined a documentary review of generative AI models such as GPT, Gemini, and Llama, along with Python web frameworks like Django and Flask, as well as functional testing in Google Colab. Gemini 1.5 Pro was selected as the underlying large language model due to its quality and availability in its free version, and multimodal reasoning capabilities, while Django was chosen as the development framework for its scalability, security, and database management features. The HECTutor tool was implemented following a Scrum methodology and a specific generative AI project lifecycle, incorporating prompt engineering techniques to configure the model as an expert tutor in mathematical logic. The resulting application includes user authentication, and interactive chat module, three learning levels: basic, intermediate, and advanced, personalized explanations adapted to each student's academic level, and a feedback module for solving specific doubts. Initial functional tests confirmed that HECTutor correctly generates adapted content, rejects off-topic requests, and stores interaction history in a relational database. The results demonstrate that generative AI represents a viable strategy for building personalized learning environments in formal disciplines.

Keywords: *Generative Artificial Intelligence, Gemini Model, Intelligent Tutoring System, Large Language Model, Learning environments, Mathematical Logic.*

Figura B.2 Encabezado y Abstract del artículo de congreso “HECTutor: Conversational Tutor based on Generative Artificial Intelligence for Teaching Mathematical Logic”

Capítulo de libro. Pérez-España, N., Ortiz-Hernández, J., Hernández, Y., Domínguez-Lara, V., & Vargas-Solar, G. (en prensa). Multi-criteria characterization and decision-making for the selection of data governance maturity models. En *Studies in Big Data*. Springer Nature.

Multi-criteria characterization and decision-making for the selection of data governance maturity models

Nohema Pérez-España¹, Javier Ortiz-Hernández¹, Yasmín Hernández¹,
Genoveva Vargas-Solar², Víctor Manuel Domínguez-Lara¹

¹TECNM Cenidet, Computer Science Department, Cuernavaca, México

²CNRS, LIRIS, Villeurbanne, France

Abstract As the generation, use, and openness of data have demonstrated value for businesses, governments, and society, data management has evolved toward a data governance perspective, which is defined as the exercise of authority, planning, monitoring, and execution over the management of data assets. Data governance is not a project with a defined beginning and end; rather, it is a continuous process that must be evaluated to determine its maturity level. Several data governance maturity assessment models have been proposed nevertheless; they are not tailored to any specific kind of organization. An important challenge is to select the appropriate model for the organization previously to the data governance maturity assessment. We proposed a method based on characterization and multicriteria decision-making. The former allowed the identification of the main characteristics of each model, while the latter enabled the comparison of models through weights assigned to each criterion. This method was applied in a public higher education institution, and the selected model was the Data Warehousing Institute.

Keywords: Data governance, maturity models, multi-criteria decision-making, characterization.

N. Pérez-España, J. Ortiz-Hernández, Y. Hernández*, V. Domínguez-Lara.
TECNM Cenidet, Computer Science Department, Cuernavaca, México
e-mail: d23ce174@cenidet.tecnm.mx; javier.oh@cenidet.tecnm.mx;
yasmin.hp@cenidet.tecnm.mx*; m24ce051@cenidet.tecnm.mx

G. Vargas-Solar
CNRS, LIRIS, Villeurbanne, France
e-mail: genoveva.vargas@gmail.com

* Corresponding author

Figura B.3 Encabezado y Abstract del capítulo de libro en prensa en *Studies in Big Data*, Springer Nature.

Anexo C. Retribuciones

Las siguientes actividades de difusión y servicio se realizaron en el marco del programa de maestría.

Presentación de póster. Domínguez-Lara, V. (2025). Integrando autoeficacia en MateLog, un ambiente inteligente para enseñar lógica matemática. Póster presentado en el International Conference on Artificial Immune Systems (ICARIS 2025).



Figura C.1 Constancia de participación como presentador de póster en ICARIS 2025.

Impartición de taller. Del caos a la lógica: organización conceptual y modelado de proyectos. Taller impartido en el Congreso Tecnologías del Futuro, Instituto Tecnológico de Gustavo A. Madero 3.



Figura C.2 Constancia de participación como ponente en el Congreso Tecnologías del Futuro.

Participación en concurso de divulgación. 3 Minutos de mi Tesis. Evento institucional, Centro Nacional de Investigación y Desarrollo Tecnológico (Cenidet).



Figura C.3 Constancia de participación en el concurso 3 Minutos de mi Tesis, Cenidet.

Voluntariado en organización de eventos académicos.

Participación como staff voluntario en el Congreso Internacional de Tecnologías y Ciencias Aplicadas (CITCA 2024) y en el Congreso Mexicano de Inteligencia Artificial (COMIA 2026).



Figura C.4 Constancias de participación como staff voluntario en CITCA 2024 y COMIA 2026.



**TECNOLÓGICO
NACIONAL DE MÉXICO**