



Proyecto de Grado

Presentado ante la ilustre Universidad de Los Andes como requisito parcial para
obtener el Título de Ingeniero de Sistemas

Evaluación del Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés

Por

Br. José Castro

Tutor: Dr. Jesús Pérez

Cotutor: Dr. Jose Aguilar



**PROYECTO DE GRADO
CALIFICACIÓN FINAL**

Título del Proyecto de Grado: **Evaluación del Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés.**

Bachiller: José Alejandro, Castro Rosales	C.I	V- 26.589.702
1) Calificación del (de la) Profesor(a) Tutor(a):	20	(20%)
2) Calificación del manuscrito final:	20	(40%)
3) Calificación de la defensa oral:	20	(40%)
Calificación final:	20	(puntos)

Los suscritos miembros del Jurado asignan como calificación final del Proyecto de Grado la nota de:

Observación:

20 (puntos)
Números

Veinte (puntos)
Letras


Prof. Jesús Pérez Angulo
Tutor


Prof. Jose Aguilar Castro
Cotutor


Prof. Junior Altamiranda
Jurado


Prof. Yaneth Moreno
Jurado

Mérida, 19 de enero de 2026.



Evaluación del Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés

Br. José Alejandro Castro Rosales

Proyecto de Grado - Sistemas Computacionales

Escuela de Ingeniería de Sistemas, Universidad de Los Andes, 2026

Resumen: El Modelo de Interacción Humano-Robot (MIHR) es una propuesta teórica reciente que busca ser un modelo genérico de interacción para diferentes casos de estudio, pero el cual no ha sido implementado en la realidad. Por esta razón, en este Proyecto de Grado se implementa y se evalúa en dos casos de estudio a nivel universitario. El primer caso de estudio está orientado al aprendizaje de las matemáticas, la cual es una área que comúnmente se le dificulta a los estudiantes. El segundo caso de estudio abordó el manejo del estrés, dado que es un aspecto que frecuentemente afecta la salud de los estudiantes. Para la implementación, se propuso integrar al MIHR en una arquitectura que usa Grandes Modelos del Lenguaje (LLMs) y un Grafo de Conocimiento. Los LLMs son utilizados en tareas como la validación del funcionamiento de componentes del MIHR; en tareas específicas de componentes del MIHR durante una interacción; y en tareas de auto-evaluación para estimar la satisfacción del usuario. La experimentación se realizó con tres estudiantes en los dos casos de estudio, e incluyó un estudio de ablación para determinar el impacto de los componentes del MIHR. Así, se consideraron cuatro configuraciones: todos los componentes, sin el componente adaptativo, sin el componente normativo, o sin el componente afectivo. La medida evaluada fue el nivel de satisfacción a través del score SPUR, y los resultados generales del análisis ANOVA indican que la ausencia del componente afectivo genera diferencias significativas (reduce el nivel de satisfacción) con respecto a las otras configuraciones. Además, el análisis de uso del MIHR en los dos casos de estudio permite considerarlo como un modelo genérico porque es capaz de funcionar y adaptarse a contextos con objetivos y perfiles de usuario distintos, lo cual se evidencia en los resultados estadísticos obtenidos.

Palabras Clave: Interacción humano-robot, grandes modelos del lenguaje, grafo de conocimiento, aprendizaje de las matemáticas, manejo del estrés.

Índice

Agradecimientos.....	1
Glosario de Términos.....	2
Capítulo I. Introducción.....	5
1.1 Planteamiento del problema.....	5
1.2 Delimitación del problema.....	6
1.3 Justificación.....	8
1.4 Objetivos.....	9
1.4.1 Objetivo general.....	9
1.4.2 Objetivos específicos.....	9
1.5 Antecedentes.....	10
1.5.1 Estrategias basadas en robótica para el aprendizaje de las matemáticas.....	10
1.5.1.1 Descripción de las estrategias.....	10
1.5.1.2 Análisis de la interacción humano-robot.....	13
1.5.2 Estrategias basadas en robótica para el manejo del estrés.....	14
1.5.2.1 Descripción de las estrategias.....	14
1.5.2.2 Análisis de la interacción humano-robot.....	16
1.5.3 Estrategias de integración del LLM en la Interacción Humano-Robot.....	17
1.5.3.1 Descripción de las estrategias.....	17
1.5.3.2 Análisis de la integración del LLM en la interacción humano-robot.....	19
1.6 Organización de la tesis.....	20
Capítulo II. Marco teórico.....	21
2.1. Interacción humano-robot.....	21
2.1.1 Modelo de interacción humano-robot MIHR.....	21
2.2 Aprendizaje de las matemáticas.....	25
2.2.1 Técnicas de aprendizaje.....	25
2.2.1.1 Aprendizaje tradicional.....	25
2.2.1.2 Aprendizaje basado en problemas.....	25
2.2.1.3 Aprendizaje con el Modelo de Gamificación.....	26
2.2.1.4 Aprendizaje invertido (Flipped Classroom).....	26
2.3 Manejo del estrés.....	27
2.3.1 Técnicas del manejo del estrés.....	27
2.3.1.1 Técnicas de respiración.....	27
2.3.1.1.1 Respiración (4-7-8).....	27
2.3.1.1.2 Respiración cuadrada (4-4-4-4).....	28
2.3.1.1.3 Respiración abdominal o diafragmática.....	28
2.3.1.1.4 Respiración nasal alterna (Nadi Shodhana).....	28
2.3.1.2 Técnicas de meditación.....	29
2.3.1.2.1 Meditación básica.....	29
2.3.1.2.2 Imaginación guiada.....	29
2.3.1.2.3 Meditación con mantra.....	29
2.3.1.2.4 Meditación de atención plena (Mindfulness).....	30
2.3.1.3 Otras técnicas de relajación.....	30

2.3.1.3.1	Relajación muscular progresiva.....	30
2.3.1.3.2	Interacciones por tacto.....	30
2.3.1.3.3	Distracción.....	31
2.4	Grandes Modelos de Lenguaje.....	31
2.4.1	Ingeniería de Prompts.....	33
2.4.1.1	Elementos clave de un prompt.....	34
2.4.1.2	Proceso de un prompt.....	35
2.4.1.3	Técnicas de Ingeniería de Prompt.....	35
2.5	Grafo del Conocimiento.....	38
2.5.1	Neo4j y Cypher.....	39
2.5.2	Relación de los LLMs y Grafo del Conocimiento.....	40
2.6	Sistema Operativo Robótico (ROS).....	41
2.6.1	Especificaciones de ROS2.....	42
2.6.1.1	Principios de diseño.....	42
2.6.1.2	Patrones de comunicación.....	44
Capítulo III.	Diseño.....	45
3.1	Arquitectura de Integración.....	45
3.2	Descripción detallada de los componentes de la Arquitectura.....	47
3.2.1	Objetivo de Interacción.....	47
3.2.2	Grafo de Conocimiento.....	48
3.2.2.1	Construcción del Grafo de Conocimiento.....	48
3.2.2.2	Consulta del Grafo de Conocimiento.....	51
3.2.2.3	Actualización del Grafo de Conocimiento.....	53
3.2.3	Validación manual.....	54
3.2.3.1	Generación de una instancia.....	54
3.2.3.2	Extracción de Pruebas.....	57
3.2.3.3	Validación del funcionamiento.....	57
3.2.4	Auto-configuración.....	60
3.2.4.1	Modos de configuración.....	60
3.2.4.2	Generación de la configuración.....	61
3.2.4.3	Organización de elementos de la Arquitectura de Integración.....	62
3.2.5	Ejecución.....	62
3.2.5.1	Robot Social LRS2.....	63
3.2.5.2	Comunicación de los componentes del MIHR.....	63
3.2.6	Auto-Evaluación.....	66
3.2.6.1	Módulo de Estimación de la Satisfacción.....	66
Capítulo IV.	Resultados.....	71
4.1	Diseño del experimento.....	71
4.1.1	Participantes.....	71
4.1.2	Configuraciones del estudio.....	71
4.1.3	Casos de estudio.....	72
4.1.4	Métrica.....	72
4.1.5	Procedimiento.....	72
4.1.6	Modelo ANOVA con medidas repetidas.....	75

4.1.6.1 ANOVA de un factor con medidas repetidas.....	75
4.1.7 Ejemplos de sesiones.....	76
4.2 Análisis de los resultados.....	78
4.2.1 Análisis descriptivo.....	79
4.2.1.1 Análisis descriptivo para 4 grupos.....	79
4.2.1.2 Análisis descriptivo para 8 grupos.....	80
4.2.1.3 Análisis descriptivo para 12 grupos.....	82
4.2.2 Análisis ANOVA para medidas repetidas.....	83
4.2.2.1 Supuestos.....	83
4.2.2.2 Análisis ANOVA para 4 grupos.....	85
4.2.2.3 Análisis ANOVA para 8 grupos.....	86
4.2.2.4 Análisis ANOVA para 12 grupos.....	87
4.2.3 Discusión general de los resultados.....	89
Capítulo V. Conclusiones.....	91
5.1 Conclusiones.....	91
5.2 Aportes.....	93
5.3 Limitaciones.....	93
5.4 Recomendaciones.....	94
5.5 Trabajos futuros.....	95
Referencias.....	96
Anexos.....	106
Anexo 1: Prompts de componentes.....	106
Anexo 1.1 Componente normativo.....	106
Anexo 1.2 Componente afectivo.....	107
Anexo 1.3 Componente de reconocimiento (imagen).....	108
Anexo 1.4 Componente de verbal.....	109
Anexo 2: Ejemplos generados para las pruebas.....	110
Anexo 2.1 Ejemplo de prueba para el componente afectivo.....	110
Anexo 2.2 Ejemplo de prueba para el componente normativo.....	110
Anexo 2.3 Ejemplo de prueba para el componente deliberativo.....	110
Anexo 2.4 Ejemplo de prueba para el componente verbal.....	110
Anexo 2.5 Ejemplo de prueba para el componente reconocimiento de imagen.....	110
Anexo 3: Reglas para recuperar los datos del grafo de conocimiento.....	112
Anexo 4: Rúbricas generadas para la evaluación la satisfacción.....	114
Anexo 4.1 Rúbrica para el aprendizaje de matemática.....	114
Anexo 4.2 Rúbrica para el manejo del estrés.....	115
Anexo 5: Consentimiento informado.....	116
Anexo 6: Score de satisfacción de los estudiantes en las configuraciones y casos de estudio.....	117

Agradecimientos

Agradezco a Dios por la sabiduría y guía constante que me brinda en cada paso para alcanzar los objetivos planteados.

Quiero agradecerle a toda mi familia, cuyo apoyo incondicional ha sido fundamental, incluso en la distancia. Un agradecimiento especial a mi hermano Victor Rosales; a mis tías Iraida Rosales, Morelba Rosales, e Irazu Rosales; a mi tío Gerardo Rosales; a mis primos Luis Andrés, Yrazu Carmona, Dahisita Medina, Dariana Medina, y Paola Salazar. También a personas que considero parte de mi familia, como Rosa Mora y Osmar García, gracias por su valioso apoyo. Este logro es también un homenaje a la memoria de mis seres queridos que, aunque ya no están físicamente, fueron una gran motivación: mi mamá Elda Rosales, mi tío Luis Salazar, mi tía Dahisy Medina y mi abuela Edilia Contreras.

Estoy especialmente agradecido con mis dos tutores, Prof. Jesús Pérez quien ha sido una de las personas más importantes que he conocido en la universidad, gracias por guiarme en toda la carrera, formándome como preparador, ayudarme a conocer el mundo de la investigación, y darme consejos que me ayudaron en toda esta etapa; y Prof. Jose Aguilar le expreso mi profundo agradecimiento, quien con su experiencia me ayudó a través de cada una de las partes de este trabajo, me he beneficiado enormemente de su gran conocimiento y ha sido un placer haber trabajado con él.

Me gustaría darle las gracias a todos los profesores que tuve durante la carrera por mantener la calidad de su enseñanza a pesar de las dificultades, en especial quiero darle las gracias al Prof. Rafael Rivas y Prof. Isabel Besembel por su forma magistral de dar cada clase, y al Prof. Alejandro Mujica por ser una persona que me ha brindado su apoyo más allá de su rol como profesor.

Le quiero dar las gracias a todas las personas con quienes compartí muchos momentos agradables en esta etapa de pregrado, personas dentro y fuera de la universidad que les tengo un gran aprecio. Quiero agradecer a Daniella Zambrano y Andrés Farias por todo su apoyo, especialmente en los momentos no tan buenos.

Por último, quiero agradecer a la Universidad de Los Andes por formarme como ingeniero y por todo el conocimiento adquirido en sus instalaciones, en especial al Laboratorio de Sistemas Discretos Automatización e Integración (LaSDAI).

Glosario de Términos

Ablación (Estudio de): Método experimental utilizado que consiste en desactivar o quitar componentes de una arquitectura (en este caso, del MIHR) para analizar su rendimiento e impacto en la interacción.

Alucinaciones: En los Grandes Modelos de Lenguaje (LLMs) es un fenómeno que ocurre cuando proporcionan información falsa, incorrecta o inventada. Pueden ser intrínsecas (contradicen la fuente) o extrínsecas (no verificables en la fuente).

Agente: Un agente de inteligencia artificial es un sistema computacional que realiza acciones autónomas flexibles en ese entorno para alcanzar sus objetivos.

ANOVA (Análisis de Varianza): Técnica estadística para comparar las medias de tres o más grupos y determinar si las diferencias observadas son estadísticamente significativas o se deben al azar.

Aprendizaje Invertido (Flipped Classroom): Método de aprendizaje que invierte el modelo tradicional, donde los estudiantes aprenden contenidos fuera de clase (por ejemplo, con videos) y aplican los conocimientos en clase a través de actividades prácticas.

API (Interfaz de Programación de Aplicaciones): Es un conjunto de reglas y protocolos que permite que dos programas de software diferentes se comuniquen e intercambien datos entre sí. Actúa como intermediario permitiendo que las aplicaciones compartan datos y funcionalidades sin necesidad de que los desarrolladores construyan todo desde cero.

Arquitectura de Integración: Diseño propuesto en el proyecto para evaluar el funcionamiento del MIHR. Se compone de cuatro capas: Validación manual, Auto-Configuración, Ejecución y Auto-evaluación.

Cypher: Lenguaje de consulta declarativo utilizado por la base de datos Neo4j para modificar, añadir y eliminar datos en grafos. Permite realizar consultas sobre nodos, etiquetas, atributos y relaciones.

Estudio longitudinal: Es un tipo de investigación que observa y recopila datos repetidamente sobre el mismo grupo de individuos o fenómenos a lo largo de un período prolongado. El objetivo es analizar cambios, patrones y relaciones de causa y efecto a lo largo del tiempo.

FineTuning (ajuste fino): En el aprendizaje automático es el acto de cambiar los parámetros de un modelo previamente entrenado para responder a una tarea o un conjunto de datos específico.

Framework: Es una estructura o plantilla reutilizable que proporciona herramientas, bibliotecas y convenciones para simplificar y acelerar el desarrollo de software y

aplicaciones, ofreciendo una base organizada para no empezar desde cero y enfocarse en la lógica específica del proyecto.

Gamificación: Estrategia de aprendizaje que incorpora elementos de juego (puntos, niveles, insignias, tablas de clasificación) para lograr objetivos educativos e involucrar a los estudiantes a nivel emocional y cognitivo.

Grafo del Conocimiento (Knowledge Graph - KG): Modelo de datos basado en un grafo dirigido compuesto por nodos (entidades) y aristas (relaciones semánticas). Ofrece una representación estructurada del conocimiento.

Ingeniería de Prompts: Proceso de diseñar y refinar las instrucciones (prompts) dadas a un modelo de lenguaje para guiarlo en la generación de resultados precisos y contextualmente apropiados.

In-Context Learning (Aprendizaje en Contexto): Enfoque utilizado para evaluar o validar componentes mediante LLMs, que consiste en proporcionar instrucciones con criterios y ejemplos dentro del prompt para guiar el razonamiento del modelo sin necesidad de reentrenamiento.

Interacción Humano-Robot (IHR): Estudio sobre cómo los humanos y los robots se comunican y colaboran.

LangChain: Es un framework de orquestación de código abierto para el desarrollo de aplicaciones utilizando los Grandes Modelos del Lenguaje (LLMs). Permite simplificar el proceso de creación de aplicaciones basadas en LLM, como chatbots y agentes de IA.

LLM (Large Language Model): Modelo de Inteligencia Artificial diseñado para comprender, generar y manipular lenguaje humano, entrenado con grandes cantidades de datos.

LRS2 (LaSDAI Robot Social 2): Robot social utilizado en el proyecto, diseñado con un enfoque minimalista para contextos educativos. Posee capacidad de expresar emociones faciales, rotar el cuello y comunicarse verbalmente.

Mago de Oz: Técnica de investigación en IHR donde una persona opera un robot de forma remota (controlando movimiento, habla, gestos) simulando que el robot actúa autónomamente.

MIHR (Modelo de Interacción Humano-Robot): Modelo teórico que describe la interacción. Integra tres elementos esenciales: modalidad de comunicación humana, adaptación de la interacción y expresión de emociones.

Neo4j: Base de datos orientada a grafos (NoSQL) que almacena datos en nodos y relaciones, permitiendo consultas ágiles y flexibles en comparación con bases de datos relacionales.

Prompt: Instrucción o entrada específica proporcionada a un LLM para lograr que realice una tarea deseada.

RAG (Retrieval Augmented Generation): Técnica que integra la recuperación de información de una base de conocimiento externa (como un grafo de conocimiento) en el proceso de prompting para generar respuestas más precisas y reducir alucinaciones.

ROS2 (Robot Operating System 2): Segunda generación del ecosistema de software de código abierto para robótica. Se centra en sistemas distribuidos, abstracción, asincronía y modularidad, utilizando un patrón de comunicación de publicación-suscripción.

SPUR (Supervised Prompting for User Satisfaction Rubrics): Método para estimar la satisfacción del usuario en sistemas conversacionales utilizando LLMs. Se compone de extracción supervisada de patrones, generación de rúbricas y estimación de la satisfacción.

OCDE (Organización para la Cooperación y el Desarrollo Económicos): Es un foro internacional donde países trabajan juntos para diseñar mejores políticas que promuevan la prosperidad, la igualdad y el bienestar, analizando datos, compartiendo mejores prácticas y estableciendo estándares globales en temas económicos, sociales y ambientales para mejorar la vida de sus ciudadanos.

Capítulo I. Introducción

1.1 Planteamiento del problema

La Interacción Humano-Robot (IHR), es una forma de interacción en la que el humano y el computador pueden colaborar, comunicar, y cooperar entre sí [1]. En la literatura existen varios modelos que permiten describir la IHR desde diferentes perspectivas. Por ejemplo, en [2] se revisan algunos modelos de comunicación e interacción que suelen ser aplicados para: (a) describir cómo los agentes pueden apoyar la comprensión mutua a través de acciones comunicativas; (b) ofrecer una perspectiva a largo plazo sobre el desarrollo y la calibración de la confianza en equipos humano-robot; y (c) ayudar en el diseño de interacciones para que los robots generen comportamiento social. Así mismo, en [2] distinguen dos paradigmas para describir la IHR: (1) *modelos de control*, cuyo enfoque es modelar la teleoperación que puede ser de control directo (donde el humano controla al robot), control supervisado (donde el humano formula y supervisa tareas que el robot debe ejecutar), y control autónomo completo (donde el humano establece metas de alto nivel y el robot las ejecuta autónomamente); y (2) *modelos de interacción social*, cuyo objetivo es apoyar el diseño de interacciones donde el robot pueda desempeñar múltiples funciones como agente social o como herramienta.

En el paradigma de control autónomo completo, al estudiar diferentes modelos de interacción social, se identificaron tres elementos esenciales en la IHR, tal como señala [1]: la modalidad de *comunicación humana*, que consiste en interacciones mediante entradas y salidas multimodales como gestos y la voz; la *adaptación de la interacción*, que se relaciona con la capacidad de ajustarse a los mensajes del usuario y al entorno; y la *expresión de emociones*, que se enfoca en cómo los robots reflejan las acciones que comunican. En ese sentido, el Modelo de Interacción Humano-Robot (MIHR) propuesto en [1], integra estos tres elementos con la finalidad de proponer un modelo genérico que pueda aplicarse a diferentes casos de estudio, algo que en la mayoría de los modelos es una limitación porque están orientados a cubrir un caso de estudio específico. Sin embargo, en la práctica los modelos como el MIHR, requieren que el robot muestre capacidades de conversación, razonamiento y adaptación, atributos que en los sistemas predefinidos son una limitación. Es por ello, que aparece una alternativa como los Grandes Modelos de Lenguaje (LLMs) cuya evolución ha superado esta limitación, debido a que pueden proporcionar comprensión y generación

coherente de texto y contenido multimedia, razonamiento contextual, simulación de roles, entre otras capacidades [3].

No obstante, como el MIHR es un modelo teórico propuesto recientemente, aún no ha sido probado en múltiples casos de estudio, por lo que no se ha evaluado completamente su capacidad de integrar de manera efectiva la modalidad de comunicación, adaptación y expresión de emociones en la interacción con robots sociales. Entonces, este Proyecto de Grado busca cubrir la necesidad de evaluar su versatilidad en distintos casos aplicativos. Para ello, se propone una implementación de MIHR que integra el uso de los LLMs de diferentes maneras. Los LLMs serán utilizados en tareas relacionadas a la validación del funcionamiento de componentes del MIHR; en tareas específicas de componentes del MIHR durante una interacción; y en tareas de auto-evaluación para estimar la satisfacción del usuario.

1.2 Delimitación del problema

Existen numerosos dominios donde la IHR ha sido aplicada, por ejemplo: en el hogar los robots pueden proporcionar ayuda para manejar la soledad de personas mayores sanas [4], asistir a personas mayores afectadas con deterioro cognitivo [5], y estimular el co-aprendizaje de familias [6]; en la medicina los robots pueden mejorar la precisión quirúrgica [7], apoyar en la toma de muestras para diagnóstico [8], y explicar pruebas y procedimientos médicos [9]; en el ámbito social y de entretenimiento los robots pueden asistir en hoteles [10], restaurantes [11], y participar en el arte y la cultura [12]; y en la educación los robots colaboran de diferentes formas en el aprendizaje de idiomas [13], resolución de problemas [14], aprendizaje de matemáticas [15], manejo del estrés [16], entre otras áreas.

Ahora bien, dado que la IHR se puede aplicar en diversos dominios, en este Proyecto de Grado sólo se abordarán dos casos de estudio en el dominio de la educación, específicamente a nivel universitario. El primer caso de estudio está orientado al aprendizaje de las matemáticas, por ser un problema común en los estudiantes. Como se menciona en [17], aprender matemáticas tiende a ser difícil no sólo para los estudiantes a los que no les gusta, sino que incluso para aquellos que disfrutan de las matemáticas. También los autores destacan otro problema común en el aprendizaje de las matemáticas, que es la comprensión de los conceptos básicos, cómo las fórmulas, ecuaciones, y técnicas de resolución complejas, que requieren un pensamiento lógico. Así mismo, los autores señalan que el ritmo de aprendizaje es otro problema presente, donde los profesores deben asegurarse de no avanzar

rápidamente en las lecciones y de que los estudiantes comprendan bien los conceptos anteriores, dado que un ritmo rápido de la enseñanza puede ser abrumador para aquellos que tienen dificultades. Además, en [18] se resalta que las matemáticas son fundamentales en la educación superior, debido a que la mayoría de los programas de pregrado incluyen algún contenido y nivel de matemática en sus planes de estudio.

En ese sentido, los robots sociales se muestran como una alternativa de aprendizaje que puede generar un entorno interactivo y personalizado para facilitar la comprensión de conceptos matemáticos, estimular la motivación, mantener el interés en el aprendizaje para realizar las tareas, y ofrecer retroalimentación; todo esto, con el objetivo de mejorar el rendimiento y la actitud hacia las matemáticas. De hecho, según [19], la mayor probabilidad de un aumento en el rendimiento no se debe al contenido educativo del guía, sino más bien al apoyo social que se pueda ofrecer, y esto se ilustra mejor con la sensación que refleja un robot al ser capaz de generar emociones y personalizar la conversación cuando proporciona orientación a los estudiantes.

Por otro lado, el segundo caso de estudio a desarrollar en este Proyecto de Grado se enfoca en el manejo del estrés, porque es un aspecto que afecta a muchos estudiantes en el mundo. De acuerdo con [20], la Organización para la Cooperación y el Desarrollo Económico (OCDE) realizó una encuesta en la que participaron 72 países y 540.000 estudiantes de 15 a 16 años, cuyos resultados indicaron que en promedio el 66% informó sentir estrés por las malas calificaciones, y al 59% a menudo les preocupa que los exámenes fueran difíciles. También se descubrió que el 55% sentían ansiedad por los exámenes escolares, incluso cuando estaban bien preparados; y un 37% informó tener la sensación de tensión cuando estudiaban. Por su parte, en [21] identificaron las reacciones comúnmente manifestadas por los estudiantes: físicas (dolores de cabeza o migraña, 38.0%), psicológicas (inquietud, 38.4% y ansiedad, angustia o desesperación, 38.4%) y comportamentales (desgano para llevar a cabo las labores escolares, 36.9% y aumento o reducción del consumo de alimentos, 31.4%). Todos estos datos muestran que la educación y el rendimiento académico son una fuente importante de estrés, y su impacto influye en el bienestar de los estudiantes, afectando su capacidad de aprendizaje, productividad, y su salud física y mental.

En aras de reducir los niveles de estrés, los robots sociales son una buena opción mediante el uso interacciones multimodales que permiten ofrecer apoyo emocional, y técnicas de relajación y distracción, lo cual puede ser de beneficio en situaciones de alta presión como las que presentan los estudiantes. Por ejemplo, en [22] destacan que la estrategia conversacional humano-robot logra cambiar el estado de ánimo de enojo, y

sugieren que la incorporación de comportamientos táctiles en interacciones conversacionales puede proporcionar un mayor impacto en los estados de ánimo, e influir en tener mejores resultados del manejo del estrés.

El presente Proyecto de Grado, además de delimitarse en el ámbito de la educación universitaria con los dos casos de estudio seleccionados, se centrará en la integración de los LLMs como un recurso para estudiar la interacción humano-robot, aprovechando sus capacidades de razonamiento y respuestas. Para ello, se usan los LLMs en la validación y funcionamiento de los componentes del MIHR en las interacciones, así como, en la automatización del proceso de evaluación de dichas interacciones para verificar la utilidad del MIHR.

1.3 Justificación

La evaluación del MIHR en diferentes casos de estudio es importante porque permitirá demostrar su adaptabilidad, lo cual es una ventaja con respecto a otros modelos que sólo se aplican en casos de estudio particulares. Por ejemplo, los modelos que se enfocan en casos particulares incluyen: i) servicios de hotel, como en [23] que se propone un modelo de aceptación de robots de servicio específico para hoteles que cubre tres dimensiones: la parte funcional, que se refiere a la facilidad de uso y utilidad orientada a la recepción, servicio de habitaciones y manipulación de equipajes; la parte socioemocional, donde se refleja el componente conductual y habilidades sociales del robot durante las interacciones con los huéspedes; y la parte relacional, donde uno de los enfoques es el diálogo conversacional para tener una comunicación de confianza con los huéspedes de acuerdo a sus necesidades; ii) asistencia doméstica, en [24] se propone un modelo cognitivo para un robot personalizado que aprende y crea nuevas opciones de desayuno a través de varios módulos que permiten la percepción del entorno, la planificación de desayunos, entre otras cosas; iii) y asistencia de niños con autismo, donde se propone en [25] un modelo para implementar un teatro robótico mediante dos módulos principales: el primero para la gestión de los escenarios y sus componentes, donde el terapeuta planifica el objetivo y la estructura a seguir; y el segundo para la ejecución, donde internamente se hace verificación y configuración del primer módulo para la interpretación de las instrucciones y respuestas del robot, así como el monitoreo de su funcionamiento.

Ahora bien, es importante mencionar que para la evaluación de la adaptabilidad de un modelo de IHR es necesario probarlo en diferentes situaciones. Por esta razón, para el

desarrollo de este Proyecto de grado se evaluará el modelo teórico MIHR en el ámbito educativo para los dos casos de estudio previamente mencionados: el aprendizaje de matemáticas y el manejo del estrés. La elección de estos casos se basa en su relevancia y en la diversidad de desafíos que presentan. En el caso de las matemáticas, la relevancia se centra en que es una de las áreas más importantes de la educación, con tales problemas [17]. Por otra parte, en el caso del manejo del estrés, la relevancia tiene efecto en el bienestar emocional y físico que pueden experimentar los estudiantes, dado que influye en el desempeño de diferentes actividades académicas, especialmente aquellas donde hay un grado de presión significativo, y tiene tales manifestaciones [21].

Adicionalmente, se justifica el uso de los LLMs para la implementación de MIHR con el objetivo de generar una interacción capaz de adaptarse y captar las necesidades y preferencias de los usuarios y el contexto [26]; y a nivel de la evaluación, con el objetivo de usar los LLMs como juez, para ajustar los criterios al contexto específico, generar evaluaciones interpretativas, y ofrecer una alternativa escalable y reproducible a la evaluación humana [27].

En concreto, la justificación de este proyecto está relacionada con dos aportes principales del mismo: uso de los LLMs para implementar y evaluar al MIHR, y demostración del funcionamiento genérico de MIHR en dos casos de estudio.

1.4 Objetivos

1.4.1 Objetivo general

Evaluar el Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés.

1.4.2 Objetivos específicos

- Especificar los requisitos para el apoyo de estudiantes universitarios usando un robot social basado en MIHR en el aprendizaje de las matemáticas y en el manejo del estrés.
- Diseñar la arquitectura de integración de los LLMs con el proceso de interacción humano-robot definida en el modelo MIHR.
- Implementar la arquitectura de integración de los LLMs con el modelo MIHR en un robot social.

- Evaluar el comportamiento del robot social basado en la arquitectura de integración en los dos casos de estudio.

1.5 Antecedentes

El marco de antecedentes para este Proyecto de Grado se estructura en tres categorías: (1) investigaciones centradas en el uso de la robótica como estrategia para el aprendizaje de las matemáticas, (2) estudios sobre estrategias basadas en robótica para el manejo del estrés, (3) y trabajos enfocados en las estrategias de integración de los LLMs en la Interacción Humano-Robot (IHR). Para las dos primeras categorías, se detallan las estrategias empleadas y se realiza un análisis de la IHR tomando como referencia los elementos clave del MIHR (modalidad de comunicación humana, la capacidad de adaptación de la interacción y la expresión de emociones). Para la tercera categoría, se identifican los elementos esenciales para la incorporación efectiva de los LLMs, y luego, se realiza un análisis de las ventajas y desventajas encontradas.

1.5.1 Estrategias basadas en robótica para el aprendizaje de las matemáticas

1.5.1.1 Descripción de las estrategias

En la descripción de las estrategias se destaca: cómo se incorporan los robots sociales para apoyar la enseñanza y aprendizaje, y cómo es el diseño e implementación de las estrategias.

La interacción humano-robot ha sido estudiada en entornos educativos donde se han reportado sus impactos positivos en el aprendizaje. En [\[28\]](#) se llevó a cabo un estudio en el que utilizaron el robot social NAO para crear una interacción lúdica y agradable durante la enseñanza de matemáticas en niños. La estrategia comienza con un diseño pedagógico, donde el profesor crea un paquete de enseñanza relacionado al tema de “Longitud y distancia”, y proporciona instrucciones y preguntas personalizadas para sus estudiantes dentro de la plataforma “Choregraphe” que se comunica directamente con el robot NAO. Durante las actividades, el robot se coloca a la altura de los ojos de los niños, permitiendo suficiente espacio para los movimientos del robot, y se usa un computador portátil para mostrar las diapositivas. La estrategia incorpora una presentación del robot, tarjetas de preguntas hacia el robot, lección breve sobre el tema, y aplicación de un breve cuestionario. Respecto a la interacción humano-robot, se incluyen señales verbales a través de la voz y no verbales como

el contacto con las manos, y ejecución de algunos movimientos corporales. Los resultados obtenidos muestran cómo los niños identificaron al robot NAO como un compañero de aprendizaje amigable.

Otra estrategia fue integrar el uso del robot NAO en la enseñanza del “ordenamiento de los números decimales” en niños [29]. La estrategia con el robot fue aplicada mediante sesiones de familiarización, seguidas de sesiones de revisión sobre el tema. Las sesiones se desarrollaron siguiendo un guión predefinido, e integrando el uso de diapositivas para mostrar el contenido del tema. La interacción humano-robot fue asistida por un investigador usando la técnica Mago de Oz [30], la cual se refiere a que una persona opera un robot de forma remota, controlando diferentes acciones como su movimiento, navegación, habla, gestos, etc. En la interacción, el robot podía preguntar e interactuar con los estudiantes mediante la salida de voz, y realizar algunos movimientos corporales. Los resultados obtenidos indicaron una apreciación positiva de los estudiantes sobre la incorporación del robot como asistente de profesor.

La IHR se ha venido desarrollando también en secundaria. En [31] se utiliza el robot NAO con el objetivo de descubrir si las tecnologías educativas incorporadas, como los robots tutores, tienen efectos positivos en estudiantes de secundaria. La estrategia con el robot consiste en que un grupo de 3 o 4 estudiantes resuelvan ejercicios de matemáticas sobre “la conversión de unidades”, donde el robot facilita la actividad recitando las preguntas y brindando retroalimentación a los estudiantes mediante señales verbales. Además, a través de un computador, los estudiantes deben trabajar en equipo y elegir una de las opciones de respuesta proporcionadas mediante tarjetas con código QR, para luego avanzar tocando la cabeza del robot. Al finalizar la interacción, los estudiantes presentan un cuestionario sobre la aceptación y uso del robot. Algunos problemas identificados es que los estudiantes de secundaria no percibieron como algo beneficioso el rol de tutor que tenía el robot social, a diferencia de cómo los niños suelen verlo, por lo que se sugiere seguir trabajando en los diseños de IHR para estudiantes de secundaria o mayores.

Recientemente se ha logrado mejorar la interacción considerando algunas especificaciones necesarias en la IHR. En [19] presentan un estudio mostrando un diseño de cómo los niños pueden practicar matemáticas a través de una conversación con un robot social, y cómo el robot puede estructurar instrucciones. El experimento se enfoca en la resolución de “problemas de multiplicación” mediante el uso del robot NAO. La interacción involucra tres módulos claves: adaptación del nivel de dificultad de matemáticas; personalización del diálogo con información relacionada al niño, como su nombre e intereses;

y andamiaje para proporcionar ayuda adicional al niño. En este estudio, la interacción con el robot fue realizada en tres sesiones, la primera de introducción y familiarización entre el robot y el niño; la segunda de práctica de comunicación con el fin de resolver algunos problemas de multiplicación; y la tercera de conversación matemática enfocada en probar el efecto de los módulos mencionados. Luego de las sesiones realizadas, los participantes completaron un cuestionario digital y fueron entrevistados por un asistente de investigación. Los resultados obtenidos indicaron que el andamiaje tuvo un efecto significativo en la proporción de respuestas correctas donde los niños con apoyo adicional fueron más efectivos comparado con aquellos que no recibieron dicho apoyo. También se logró ver que la adaptación del nivel era adecuada para la mayoría de los niños, y la personalización en la interacción mejoraba el interés en el diálogo. Por este motivo, los resultados sugieren que la combinación de estrategias de personalización, adaptación de nivel y el andamiaje pueden mejorar la experiencia de aprendizaje y la eficacia en la enseñanza de matemáticas utilizando robots educativos.

Adicionalmente, se destaca el trabajo realizado en [32], donde se propone un diseño de interacción humano-robot para el aprendizaje de las tablas de multiplicación para niños. Este trabajo es de especial importancia porque está basado en el MIHR, el cual se emplea en este Proyecto de Grado. En cuanto a la estrategia diseñada, el robot se debe relacionar con un niño a través de dos juegos de preguntas y respuestas. En el primer juego, el robot asume el rol de tutor y pregunta al niño sobre las tablas de multiplicar del 2 al 9. En el segundo juego, el robot adopta un papel de compañero de juego y compite con el niño en una serie de preguntas de verdadero o falso basadas en las tablas que le resultan más difíciles al niño. Para facilitar la comunicación, se usa un dispositivo táctil que el niño presiona cuando está listo para responder, activando así el reconocimiento de voz del robot. La interacción se divide en tres etapas: identificación, exploración y aprendizaje. En la etapa de identificación, el robot reconoce al niño y adapta su estrategia según las interacciones previas. En la fase de exploración, el robot realiza preguntas sobre las tablas de multiplicar, permitiendo al niño controlar el ritmo del juego mediante comandos de voz o toques en el dispositivo. En la fase de aprendizaje, el robot utiliza un juego de verdadero o falso para reforzar las tablas en las que el niño tuvo dificultades, manteniendo un equilibrio entre recompensas verbales y un comportamiento neutral para no distraerlo. Finalmente, el robot proporciona retroalimentación y estímulos verbales según el rendimiento del niño en cada etapa.

1.5.1.2 Análisis de la interacción humano-robot

En los antecedentes descritos se analizaron aspectos comunes e importantes en relación con los tres elementos esenciales del MIHR (ver Tabla 1.1). En cuanto a la modalidad de comunicación humana, la voz es el aspecto de comunicación principal [19, 28, 29, 31, 32], seguido del contacto con el robot [19, 28, 31, 32], y el uso de complementos visuales como un computador o una tablet [19, 29, 31]; sobre la adaptación de la interacción, se observa que dependiendo de la estrategia el modelo puede ser de control directo [29], control supervisado (el humano formula y supervisa tareas que el robot debe ejecutar) [31], o control autónomo completo (el humano establece metas de alto nivel y el robot las ejecuta autónomamente) [19, 28, 32], donde el enfoque suele ser en el nivel de dificultad del usuario; por último, en la expresión de emociones son relevantes los movimientos corporales con posturas que imitan el lenguaje corporal humano [28], o recompensas verbales del robot con expresiones de apoyo que proporcionan una retroalimentación positiva al usuario [29, 31, 32].

Antecedente	Características		
	Modalidad de comunicación humana	Adaptación de la interacción	Expresión de emociones
[28]	Por voz, contacto con las manos, y apoyo visual con un computador	Personaliza la interacción según la información que el profesor agrega del estudiante	Movimientos corporales
[29]	Por voz y apoyo visual con un computador	-	Recompensas verbales
[31]	Salida por voz, apoyo visual con un computador, y entradas con escaneo de QR y táctil del robot	-	Recompensas verbales
[19]	Apoyo visual con una tablet, contacto con las manos del robot, y entrada y salida por voz	Nivel de dificultad e intereses del niño	-
[32]	Por voz y dispositivo táctil	Nivel de dificultad	Recompensas verbales

Tabla 1.1: Elementos del MIHR presentes en las estrategias para las matemáticas.

También, existen múltiples carencias encontradas. Por ejemplo, en la modalidad de comunicación la ausencia de canales bidireccionales de señales verbales, como lo señalan en [31], donde las entradas solo se enfocan en el escaneo de códigos QR para recibir respuestas de los estudiantes, limita la naturalidad y la fluidez de la interacción. Esto puede resultar en una experiencia menos intuitiva, comparado con las interacciones humanas que normalmente son por voz. Otra limitación es solo enfocarse a la interacción verbal con un soporte visual

mínimo (por ejemplo, una pantalla), que puede no ser suficiente para los usuarios, por lo que se sugiere la exploración de configuraciones de aprendizaje social multimodal más completas [19]. En la adaptación de la interacción, se observa que el uso de un modelo de control directo como en [29], dificulta la capacidad de personalización dado que las instrucciones siguen un guión predefinido. Finalmente, en la expresión de emociones, una limitación es no mostrar gestos faciales, tales como felicidad o tristeza [28], donde profesores lo asocian como una falta en el sentido humano de la empatía [29], y es una carencia en las estrategias que usan al robot NAO [19, 28, 29, 31]. Otras carencias encontradas en [19] se relacionan con la necesidad de la incorporación de efectos de sonido, y la adaptación del volumen de la voz según la percepción visual o auditiva del usuario, lo cual puede ser muy importante durante la interacción.

1.5.2 Estrategias basadas en robótica para el manejo del estrés

1.5.2.1 Descripción de las estrategias

La descripción de estas estrategias tiene como finalidad observar la efectividad de los robots sociales para facilitar intervenciones y conocer métodos usados para gestionar el estrés.

En el manejo del estrés, la IHR ha servido para apoyar con técnicas de relajación. En las interacciones se pueden usar sensores para detectar signos de estrés, como el aumento de la frecuencia cardíaca o la sudoración, y responder con ejercicios de respiración guiada. En [33] se investigó la efectividad de los robots sociales con intervenciones de estudiantes universitarios mediante la evaluación de sus respuestas fisiológicas. La estrategia se desarrolló bajo dos condiciones: una con el uso de un computador, y la otra con el robot. Respecto al uso del robot social, se usó a Pepper, y consistió en dos actividades: una para realizar una tarea de inducción al estrés enfocada en problemas aritméticos bajo presión de tiempo con el fin de llevar a los participantes a un nivel comparable de estrés; y otra para hacer una técnica de manejo del estrés, en la que los participantes realizaron un ejercicio de respiración profunda con la ayuda del robot. Para medir los niveles de estrés se utilizó en la cabeza el dispositivo “Unicorn Hybrid Black” registrando las señales cerebrales, y se utilizó un sensor en la muñeca y los dedos de la mano para registrar las respuestas galvánicas de la piel. Finalmente, se aplicaron cuestionarios sobre la aceptación del robot. Los resultados no mostraron diferencias significativas con la inclusión del robot para el manejo del estrés, sin

embargo, sí se notaron diferencias en cómo surgieron las respuestas emocionales interpretadas con el Modelo Circumplejo de las Emociones, para cada grupo del experimento.

Existen diversos casos donde se pueden presentar niveles de estrés alto, un ejemplo es la sala de urgencias en un hospital, donde tanto el personal médico como los pacientes y sus familiares experimentan una alta presión debido a la naturaleza crítica y urgente de la situación. En [34] evaluaron el impacto de un robot social en el manejo del estrés de niños que esperan un procedimiento en una sala de emergencias, a través de la evaluación de los niveles de cortisol salival. Se evaluaron tres grupos: uno donde las enfermeras participaron como distractoras de los niños, otro donde se usó el robot, y un grupo de control. En la intervención con el robot NAO se aplicaron estrategias de distracción cognitivo-conductual apropiadas para la edad (canciones, historias, chistes, juegos, acertijos); se realizaron pruebas fisiológicas para registrar niveles de cortisol salival antes y después de la intervención, así como pruebas psicológicas con el uso de cuestionarios. Los resultados fueron positivos, reflejando que los niveles de cortisol salival disminuyeron significativamente luego de la interacción con el robot y las pruebas psicológicas resaltaron que los niños con personalidades más extrovertidas presentaron menor estrés inicial, lo que respalda la idea de que la capacidad de regular emociones contribuye a una menor ansiedad en situaciones difíciles.

La interacción humano-robot también ha sido testigo de un creciente interés de los investigadores en la interacción táctil. En el contexto del manejo del estrés, esto puede verse relacionado en los efectos amortiguadores que pueden proporcionar las interacciones. Por ejemplo, en [35] se utilizó un robot abrazable con una aplicación de realidad virtual para verificar los posibles efectos amortiguadores del estrés asociados con el abrazo de un robot. El estudio fue realizado a jóvenes mayores de edad, y su desarrollo consideró dos condiciones: agente virtual del mismo género, y con género opuesto. A partir de una introducción y demostración de la actividad, los participantes avanzaron en la interacción correspondiente donde la persona debía tener un dispositivo de visualización montado en la cabeza, el cual mostraba un agente con apariencia de género masculina o femenina para generar los estímulos audiovisuales; y cerca se tenía al robot físico Moffuly, el cual estaba coordinado en simultáneo con los movimientos del agente. Durante una interacción, el robot acariciaba suavemente la espalda del usuario teniendo un abrazo de 1 minuto. Después de la interacción, los participantes presentaron un cuestionario, y luego hicieron una tarea de operaciones de resta para inducir el estrés, un método comúnmente empleado en la literatura de ciencias humanas para inducir estrés de manera confiable. En los resultados se resalta que

en la interacción del abrazo con un agente del sexo opuesto brinda mayores beneficios que aquellos con un agente del mismo sexo, así como también los abrazos son un factor que puede amortiguar los efectos del estrés. Por otro lado, la tarea realizada luego de la intervención refleja que efectivamente incrementa los niveles de estrés, pero no hay cambios significativos luego de la interacción sobre todo en la relación del género del humano y el agente.

Uno de los puntos importantes donde el estrés influye es en el estado emocional de las personas, por lo que es relevante desarrollar estrategias que permitan ayudar en esto. En [22] se realizó un estudio con el fin de hacer que el estado de ánimo de las personas sea más positivo a través de conversaciones sobre sus problemas. La estrategia fue aplicada a adultos incorporando al robot Sota. La intervención con el robot fue de forma conversacional, centrándose en el uso del método de la columna que es una técnica típica de afrontamiento del estrés en Japón. La conversación fluyó considerando dos escenarios, uno de preguntas básicas, donde el robot preguntó a los usuarios sobre sus preocupaciones, y otro donde el robot realizaba preguntas más detalladas sobre las preocupaciones de los usuarios incluyendo reflexiones sobre sus respuestas. Dentro de la evaluación, se registró la cantidad de información revelada del usuario sobre sí mismo (autorrevelación), en la interacción con el robot; y se registró con cuestionarios de perfil el estado de ánimo. Los resultados mostraron que el sistema con estrategias conversacionales adicionales aumentó significativamente la cantidad de autorrevelaciones de los participantes y redujo su enojo.

1.5.2.2 Análisis de la interacción humano-robot

En los antecedentes para manejo del estrés también se analizaron los aspectos comunes en relación con los tres elementos esenciales del MIHR (ver Tabla 1.2). En cuanto a la modalidad de comunicación humana, se reafirma que la voz es el aspecto principal [22, 33, 34, 35], puede haber uso de elementos visuales [33, 35], y haber contacto con el robot [35]. En la adaptación de la interacción, se ven casos de control supervisado [33, 35], y control autónomo completo [22, 34], cuyo enfoque está en las características del usuario, palabras clave usadas, o resultados de estimación. Finalmente, en la expresión de emociones, se resalta el uso de sonidos y cambio de colores de las luces LED integradas para enfatizar el mensaje verbal [34], recompensas verbales con palabras de aliento y elogios al usuario fomentando la confianza [22, 33], y contacto visual para transmitir interés y atención [35].

Antecedente	Características		
	Modalidad de comunicación humana	Adaptación de la interacción	Expresión de emociones
[33]	Salida visual (pantalla incorporada) y por voz	-	Recompensas verbales
[34]	Comunicación por voz	Según las características del niño	Reproducir sonidos, y cambiar el uso de luces LED
[35]	Audiovisual por el agente virtual, contacto físico con el robot abrazable	-	Contacto visual del agente según los movimientos de la cabeza del usuario
[22]	Comunicación por voz	Según las palabras clave recibidas y resultados de la estimación	Recompensas verbales

Tabla 1.2: Elementos del MIHR presentes en las estrategias para manejo del estrés.

Ahora bien, existen diferentes limitaciones: en la modalidad de comunicación humana, cuando solo es por voz como en [22, 34], puede provocar que los usuarios pierdan el foco de la actividad, y según [22], es necesario incorporar comportamientos táctiles durante comunicación verbal para las interacciones, porque es una ventaja que poseen los agentes físicos sobre los agentes no físicos. En la adaptación de la interacción, para los ejercicios de respiración o relajación puede que las instrucciones sean predefinidas como en [33, 35], lo cual no toma en cuenta las señales de estrés que se presentan, y se podría mejorar con el reconocimiento emocional de los participantes durante el ejercicio. Finalmente, en la expresión de emociones, como se observa en [22, 33, 34, 35], no se suele ofrecer un componente de empatía como los gestos faciales, el cual puede mejorar la conexión emocional entre el robot y el usuario.

1.5.3 Estrategias de integración del LLM en la Interacción Humano-Robot.

1.5.3.1 Descripción de las estrategias

En la descripción de las estrategias se resalta cómo se integran los LLMs en el desarrollo de interacciones humano-robot. En [36] desarrollaron un sistema de IHR con el objetivo de integrar los LLMs en robots sociales para facilitar conversaciones fluidas, personalizadas y conscientes del contexto, dirigidas específicamente a combatir el aislamiento en adultos mayores. Para ello, se usó el robot Pepper, integrado el modelo *GPT 3.5* mediante la API de Microsoft Azure para la transcripción de voz en tiempo real y el

motor neuronal de ElevenLabs para una síntesis de voz expresiva y con acentos regionales adaptados. El diseño se basó en una “arquitectura modular”, en la que se detecta la entrada del usuario, se procesa a texto, y se usa el LLM para generar una respuesta que luego el robot ejecuta. Para las respuestas se considera la memoria de características relevantes de sesiones previas del usuario y el historial de la conversación actual. La evaluación fue realizada con adultos jóvenes y una prueba piloto exploratoria en los hogares de adultos mayores, analizando la usabilidad y la conexión social a través de interacciones. Los resultados demostraron que la continuidad en la memoria y la adaptación cultural de la voz mejoraron significativamente la percepción de confianza y naturalidad, aunque se identificaron limitaciones técnicas persistentes relacionadas con la latencia de respuesta y las alucinaciones del modelo. Como trabajos a futuro, los autores sugieren la implementación de modelos de toma de turnos basados en prosodia para reducir interrupciones, y la realización de estudios longitudinales (estudios que recopilan datos repetidamente de la misma muestra durante un período prolongado) para validar la interacción sostenida.

Por su parte, En [37] propusieron la integración los LLMs dentro de una “arquitectura cognitiva para robots autónomos”, con el objetivo de sustituir los sistemas deliberativos clásicos por un sistema de planificación en lenguaje natural que mejore la interacción humano-robot. Este trabajo se centró en un entorno doméstico con el fin de que el robot hable con personas. Para la implementación se utilizó *ROS2* (framework para sistemas robóticos), junto con el *LangChain* (framework para crear agentes y aplicaciones impulsadas con LLM), el modelo LLM *Marcoroni*, una base de datos vectorial y un grafo de conocimiento para guiar la planificación según el objetivo. La integración del LLM es realizada en el módulo de planificación donde se incluye el grafo de conocimiento para obtener el contexto de forma relevante; a su vez, mediante *prompting* (técnica de formular instrucciones) el sistema genera planes de acción en formato *JSON* que son ejecutados, y posteriormente verificados, por el propio LLM. El experimento se realizó de forma simulada, y los resultados experimentales mostraron que el enfoque clásico sigue siendo significativamente más eficiente, pero se valida la capacidad de razonamiento del LLM, y sugiere como trabajos futuros la optimización mediante algoritmos de grafos para obtener el contexto, y la inclusión de modelos visuales que pueden utilizarse para extraer características de las imágenes capturadas por el robot para mejorar la interacción.

En el contexto educativo también se han integrado los LLMs con interacciones humano-robot. Por ejemplo en [38] investigaron el impacto de la interacción con robots sociales en la creatividad verbal infantil mediante una tarea de narración de historias. Este

estudio integró LLM mediante el uso de GPT-3, y aplicó el *fine-tuning* (técnica de adaptar un modelo a casos específicos) para entrenar un conjunto de datos de historias infantiles previamente puntuadas y generar dos modelos distintos de comportamiento robótico: uno creativo y otro no creativo. El procedimiento experimental incluyó dos fases: un primer estudio con un robot teleoperado que generaba ideas aleatorias, y un segundo donde el robot operaba de forma autónoma utilizando el LLM para ofrecer continuaciones de historias contextualmente coherentes. Mientras que el primer estudio no mostró efectos significativos, los resultados del segundo estudio revelaron que los niños que interactuaron con el robot autónomo en la condición creativa demostraron niveles significativamente mayores de fluidez, flexibilidad y elaboración en sus narrativas en comparación con el grupo de control no creativo. Estos hallazgos sugieren que un agente robótico impulsado por LLM, capaz de generar contenido creativo y contextual, puede estimular efectivamente ciertas dimensiones de la creatividad infantil.

Así como el LLM se puede integrar para que el robot actúe de forma natural en las interacciones, también puede integrarse para analizarlas y evaluarlas de manera automática. Aunque de forma explícita no existe el análisis o evaluación de interacciones humano-robot a través de los LLM, si se ha utilizado para el análisis de diálogos con agentes IA. En [39], los autores proponen un marco de evaluación automática diseñado para medir las capacidades de diagnóstico médico de los LLMs, con el objetivo de establecer un criterio unificado y reducir la dependencia de evaluaciones humanas costosas en tiempo y esfuerzo. La integración de los LLMs es usada para actuar según dos roles: primero, emplean un modelo *BLOOM* ajustado como simulador de pacientes para generar diálogos médicos de forma autónoma al interactuar con el modelo a evaluar; y segundo, utilizan *ChatGPT* como juez para calificar dichas interacciones basándose en una adaptación de la escala clínica. Los resultados mostraron que la evaluación automática es altamente efectiva y reproducible para valorar aspectos como el cuidado humanístico y las habilidades de entrevista (pudiendo reemplazar a expertos humanos en estos rubros), aunque presenta limitaciones al evaluar la precisión del diagnóstico y los planes de tratamiento complejos debido a la falta de conocimiento médico especializado en el LLM evaluador general.

1.5.3.2 Análisis de la integración del LLM en la interacción humano-robot

Se identificaron algunas ventajas en la integración de los LLMs: primero, pueden generar diálogos naturales, fluidos y coherentes gracias a la gestión de memoria e historial; segundo, pueden generar planes de acción estructurados en algún formato específico (ej.,

JSON) y razonar mejor según el objetivo y contexto usando fuentes externas como grafo de conocimiento; y tercero, pueden actuar como "jueces" automáticos para evaluar interacciones (e.j., diálogos médicos), reduciendo costos y trabajo manual. Por otro lado, algunas desventajas encontradas en la integración de los LLMs son: la lentitud de respuesta que puede afectar la fluidez y naturalidad de la interacción en tiempo real, y el riesgo de generar información falsa debido a las “alucinaciones” si no existe un contexto del dominio, lo cual puede afectar su uso en la interacción o evaluación de la misma.

1.6 Organización de la tesis

En las siguientes secciones de este Proyecto de Grado se aborda con detalles cada uno de los objetivos planteados.

- Capítulo II Marco teórico: se describen los fundamentos teóricos que sustentan el Modelo de Interacción Humano-Robot (MIHR). Se realiza una revisión de la literatura sobre las técnicas de aprendizaje de las matemáticas y las técnicas para el manejo del estrés. Se especifican los conceptos clave para la implementación: Grandes Modelos del Lenguaje (LLMs), Grafo de Conocimiento (KG) y Sistema Operativo Robótico (ROS). Este marco teórico proporciona una base para contextualizar los casos de estudio seleccionados y la propuesta de implementación.
- Capítulo III Diseño: se presentan las características del diseño e implementación donde se propone una arquitectura de integración. Se detalla cada una de sus partes, que incluye una validación de componentes del MIHR, la auto-configuración del MIHR, la ejecución de la interacción, y la auto-evaluación según la estimación de satisfacción del usuario.
- Capítulo IV Resultados: se detalla la experimentación, destacando criterios como: selección de los participantes, el diseño de las pruebas y la configuración del entorno. Luego se analizan los resultados obtenidos en los dos casos de estudio. La presentación de los datos recopilados se realiza utilizando las métricas previamente definidas para la generalización adecuada de los hallazgos.
- Capítulo V Conclusiones: se presentan los principales aportes tras la evaluación del Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de los dos casos de estudio propuestos. Se señalan los resultados más relevantes, las limitaciones encontradas, las recomendaciones, y los trabajos a futuro bajo esta línea de investigación.

Capítulo II. Marco teórico

2.1. Interacción humano-robot

La interacción humano-robot (IHR) es un estudio sobre los humanos y robots, y las formas en que pueden interactuar e intercambiar información. En [40], mencionan que la manera de comunicación puede ser clasificada como un medio social pasivo/interactivo: un medio pasivo, indica que un robot ofrece información unidireccional donde los humanos solo observan el comportamiento de un robot; un medio interactivo, es que existe un intercambio bidireccional donde un robot cambia sus comportamientos verbales y no verbales dependiendo de los comportamientos del humano como su locomoción e interrupción hacia el robot; un medio pasivo-social, significa que dos (o más) robots ofrecen información interactuando entre sí a través de comportamientos verbales/no verbales y similar a un medio pasivo, los robots no interactúan con los usuarios; y un medio interactivo-social, señala que dos (o más) robots ofrecen información como medio, al igual que en un medio pasivo-social, aunque los robots interactúan tanto con los usuarios como con otros robots. En ese sentido, para este Proyecto de Grado la interacción humano-robot es relevante dentro de esta clasificación debido a que las estrategias para el aprendizaje de las matemáticas y manejo del estrés, están orientadas a la implementación de un medio interactivo entre un estudiante universitario y un robot social.

2.1.1 Modelo de interacción humano-robot MIHR

La interacción humano-robot aplicada en diferentes casos de estudio debe permitir la capacidad de reconocer características de las personas y el contexto para que los robots puedan adaptarse en función de ello. Por esta razón, las estrategias desarrolladas deben estar destinadas a que la interacción sea de la manera más natural posible, y para ello es necesario el uso de modelos y técnicas inspiradas en la comunicación entre personas. Es por ello que en esta sección se explica el modelo de interacción humano-robot MIHR propuesto en [1], cuyo fin es ser evaluado mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés.

El modelo de interacción humano-robot (MIHR) es un modelo que describe la interacción entre un humano y un robot, con el fin de lograr una interacción parecida a la que existe entre las personas. El MIHR está constituido por dos niveles: un nivel interno, que

describe el proceso de cada participante en la interacción desde que percibe la información hasta que genera las respuestas; y un nivel externo, que describe cómo puede ser alterada la información desde que es emitida por un participante hasta que es recibida por otro. A continuación, se describen cada uno de los módulos que interactúan en el MIHR, tal como se muestra en la figura 2.1.




Figura 2.1: Modelo de interacción humano-robot MIHR [1]

Nivel interno del humano: está compuesto por cuatro módulos: físico, afectivo, cognitivo y conductual. Este nivel procesa la información proveniente del entorno externo, y la modifica a través de los sentidos de la persona, generando una respuesta emocional según la interpretación inicial. Luego, se realiza una nueva interpretación a través de los filtros cognitivos para determinar la intención de comunicación de la otra persona, lo que provoca una nueva activación de los estados afectivos. A partir de esta dinámica, se establecen los objetivos y el estilo de comunicación, basados en la interacción entre los procesos conscientes e inconscientes y los estados emocionales. Finalmente, la respuesta se ajusta a través de los componentes conductuales, influenciada por los objetivos, el estilo de comunicación y las condiciones fisiológicas de la persona.

Nivel externo: describe la interacción entre un humano y un robot, donde ambos envían y reciben información a través de un canal de comunicación. Durante este proceso, la información puede ser alterada tanto en el trayecto hacia el canal como durante su transmisión y recepción. Este nivel funciona de manera similar para ambos, ya que pueden actuar como emisor o receptor. El nivel externo consta de tres módulos: el módulo individual del humano, el módulo individual del robot y el módulo compartido. En primer lugar, la información se ve influenciada por las condiciones ambientales entre el emisor y el canal (módulo individual del emisor). Luego, se incorpora al canal de comunicación, donde puede ser modificada por el ruido (módulo compartido). Finalmente, la información es extraída del

canal por el receptor y se ajusta según las condiciones ambientales entre el canal y el receptor (módulo individual del receptor), generando así la salida de este nivel.

Nivel interno del robot: recibe la información desde el nivel externo a través de sus sensores. Luego, se aplican algoritmos de reconocimiento para interpretar los datos y determinar la intención de la comunicación. Este nivel gestiona dos tipos de respuestas: automáticas y deliberadas. Las respuestas automáticas se ejecutan de manera inmediata una vez que se identifica su necesidad. Por otro lado, las respuestas deliberadas se generan con base en un objetivo de comunicación, el cual se determina según la intención, las normas de interacción y el estado afectivo. Posteriormente, esta respuesta se adapta según la persona involucrada, generando señales verbales, paraverbales y no verbales que son traducidas en comandos para los actuadores, permitiendo así su ejecución. A continuación se describe con detalle cada módulo presente en el nivel interno del robot:

- **Módulo físico:** está formado por tres componentes (percepción, actuación, y condiciones físicas). Cuando la información proviene del módulo individual del robot en el nivel externo, el componente de percepción captura las señales de manera multimodal, siguiendo los parámetros establecidos por el componente de condiciones físicas (como repetibilidad y sensibilidad) en relación con los sensores, con el objetivo de detectar los datos de interés y enviarlos al componente de reconocimiento del módulo cognitivo. Por otro lado, si la información proviene del módulo conductual, el componente de actuación traduce las órdenes en señales que los actuadores puedan comprender, y luego las envía para su ejecución, de acuerdo con los parámetros del componente de condiciones físicas (como precisión y velocidad) en relación con los actuadores.
- **Módulo cognitivo:** está compuesto por cinco componentes (reconocimiento, automático, deliberativo, normativo, y adaptación). El componente de reconocimiento utiliza los datos obtenidos del módulo físico para aplicar algoritmos que identifican personas, voces, temas de conversación, lugares, estados afectivos, eventos, entre otros. El componente automático, detecta los eventos que requieren una respuesta inmediata, enviando dichas respuestas directamente al módulo conductual para su ejecución rápida. El componente deliberativo interpreta la información reconocida a través de diferentes canales o modos, con el fin de identificar la intención de comunicación y generar un objetivo de acuerdo con las normas de interacción y el estado afectivo. El componente normativo proporciona las reglas sociales que guían la interacción. Finalmente, el componente de adaptación ajusta la respuesta de acuerdo

al objetivo de comunicación y las características de la persona. Además, el módulo cognitivo envía los resultados de la intención de comunicación identificada al módulo afectivo.

- **Módulo afectivo:** tiene el objetivo de gestionar los estados afectivos del robot en términos de emociones y sentimientos. La entrada de este módulo proviene del módulo cognitivo, el cual le envía la intención de comunicación que ha identificado para que sean actualizados los estados afectivos del robot en función de esa intención, de la persona, y de las normas sociales de interacción. Luego, los estados afectivos son enviados a los módulos conductual y cognitivo.
- **Módulo conductual:** tiene la finalidad de distribuir las respuestas y los estados afectivos del robot mediante diferentes canales o modos de expresión, y está compuesto por tres componentes (verbal, paraverbal y no verbal). Cada uno de estos componentes se encarga de generar las órdenes correspondientes para la comunicación. El componente verbal se ocupa de las palabras; el paraverbal regula los aspectos como el volumen, tono y timbre de la voz; mientras que el componente no verbal gestiona las expresiones faciales, movimientos y posturas del robot.

Igualmente, el MIHR tiene tres capacidades principales: la modalidad de comunicación humana, la adaptación de la interacción y la expresión de emociones.

- **Modalidad de comunicación humana:** es la forma de cómo las personas interactúan de la manera más natural y social con robots, utilizando un conjunto de señales y comportamientos similares a los que empleamos en nuestras relaciones interpersonales. Esta interacción se basa en *normas sociales* en las que se emplean diversas modalidades de comunicación como la voz, la mirada, los gestos, y el contacto físico.
- **Adaptación de la interacción:** es la manera en que los robots sociales son capaces de percibir y responder a las diferencias individuales de cada usuario para ajustar su comportamiento con interacciones adecuadas. Esta adaptación se manifiesta en los cambios de diversos aspectos como las respuestas del usuario, el tono de voz, los gestos, y los movimientos corporales.
- **Expresión de emociones:** es la capacidad de que los robots sociales puedan transmitir estados afectivos de diversos canales, como faciales, vocales y gestuales, con el fin de establecer conexiones emocionales con los humanos. La combinación de diferentes canales de expresión, conocida como multimodalidad, enriquece aún más la experiencia del usuario.

2.2 Aprendizaje de las matemáticas

2.2.1 Técnicas de aprendizaje

Existen numerosas técnicas y enfoques en el aprendizaje, partiendo del aprendizaje tradicional donde se incluye clases presenciales, tutorías, exámenes, hasta un aprendizaje moderno: basado en problemas, gamificación, aprendizaje inverso, o el uso de herramientas tecnológicas. A continuación se describen algunas técnicas muy utilizadas en la actualidad.

2.2.1.1 Aprendizaje tradicional

Es la técnica de aprendizaje más común que se suele implementar en la educación. El enfoque está orientado a que el profesor imparta el contenido de forma presencial y se complementa con diferentes materiales de apoyo, y luego se evalúa el conocimiento mediante exámenes escritos u orales. De acuerdo con [\[41\]](#) los componentes del aprendizaje tradicional son:

1. Clases presenciales: llevadas a cabo por profesores o personas invitadas y pueden complementarse con libros de texto y material de apoyo.
2. Tutorías: sesiones en grupos reducidos dirigidas por un profesor o asistente de cátedra en las que los estudiantes pueden debatir y hacer preguntas sobre el material del curso.
3. Laboratorios: sesiones prácticas realizadas en ciencias, ingeniería u otros campos técnicos para proporcionar experiencia práctica y reforzar conceptos teóricos.
4. Exámenes: los exámenes tradicionales, como las pruebas escritas o los exámenes orales, se utilizan a menudo para evaluar el conocimiento y la comprensión de los estudiantes.

2.2.1.2 Aprendizaje basado en problemas

La técnica basada en resolución de problemas ayuda a los estudiantes a recordar mucho mejor el conocimiento matemático y también a vincularlo con situaciones de la vida real, lo que les permite conectar diferentes áreas temáticas. El Método heurístico de George Pólya es muy conocido en este tipo de aprendizaje porque enseña a desglosar problemas complejos en partes manejables y fomenta el desarrollo del razonamiento lógico, esencial en el contexto de las habilidades del siglo XXI [\[42\]](#). Un ejemplo a nivel universitario es el fortalecimiento de

las habilidades de resolución de problemas en ecuaciones diferenciales [43]. Los pasos esenciales son:

1. Entender el problema, identificando las partes principales, los datos conocidos, y la incógnita del problema.
2. Planificar una estrategia, diseñando un plan basándose en los datos y en posibles soluciones.
3. Ejecutar el plan, llevando a cabo la solución, paso a paso.
4. Revisar o retroalimentar, evaluando el proceso y los resultados para comprender bien y mejorar futuras resoluciones.

2.2.1.3 Aprendizaje con el Modelo de Gamificación

Es una estrategia innovadora cuyo enfoque constructivista incorpora los elementos de un juego para lograr objetivos de aprendizaje específicos e involucrar a los estudiantes a nivel emocional, social y cognitivo, permitiendo disfrutar del proceso de aprendizaje [44]. Un ejemplo a nivel universitario es convertir el aula de clase en un contexto de juego, como en [45] que transforman las lecciones de Estadística y Probabilidad para que cada estudiante sea recompensado con diferentes insignias por completar cada tarea en clase, y cada insignia sea representada por una cantidad de puntos obtenidos según el nivel de la tarea; los puntos acumulados son mostrados en una tabla de clasificación durante el semestre, para que los estudiantes puedan verificar su rendimiento y motivarse en mejorar su posición en la tabla. Entonces, los elementos clave son:

1. Puntos: se asignan valores cuantitativos a determinadas acciones, y pueden ser acumulados.
2. Niveles: se definen una serie de niveles que el usuario debe superar.
3. Insignias: se entregan diferentes insignias coleccionables por completar los objetivos.
4. Tabla de clasificación: se tiene una lista con los participantes ordenados según los puntos u objetivos acumulados.
5. Objetivos o misiones: se plantean los diferentes retos a conseguir y resolver.

2.2.1.4 Aprendizaje invertido (Flipped Classroom)

Es un método de aprendizaje que invierte el modelo de aprendizaje tradicional. Cuyo objetivo es motivar a los estudiantes mediante el uso de métodos de enseñanza mejorados con tecnología que vayan más allá de las clases tradicionales, algunas herramientas y tecnologías

usadas incluyen la creación de videos, sistemas de gestión del aprendizaje, repositorios de contenido, colaboración, podcasts y evaluación en línea [46]. Un ejemplo a nivel universitario se muestra en [47] donde aplican esta estrategia para repasar conceptos de trigonometría y los vectores, donde los estudiantes tienen acceso a videos explicativos fuera de clase y durante la clase conversan en grupos que trabajan en base al contenido visto. Las partes del aprendizaje invertido son:

1. Fuera de clase: los estudiantes aprenden contenidos, a menudo a través de clases grabadas en línea, lecturas, o investigaciones.
2. En clase: Los estudiantes aplican sus conocimientos a través de actividades prácticas, resolución de problemas y colaboración.

2.3 Manejo del estrés

2.3.1 Técnicas del manejo del estrés

Según se señala en [48], la literatura actual destaca la disponibilidad de numerosas técnicas no farmacológicas basadas en evidencia para el manejo del estrés en niños y adolescentes. Estas técnicas pueden implementarse en diversos entornos, como hospitales, instituciones educativas o el hogar. Su aplicación abarca una amplia gama de problemas de salud, desde molestias y dolores relacionados con el estrés hasta condiciones graves como el asma o trastornos psiquiátricos, incluyendo, entre otros, el trastorno por déficit de atención con hiperactividad (TDAH). A continuación, se describen diferentes técnicas basadas en el trabajo [49], las cuales permiten promover la relajación y el bienestar mental y físico, ayudando a un buen manejo del estrés.

2.3.1.1 Técnicas de respiración

Existen diferentes variaciones de las técnicas de respiración. Por eso es importante conocer y experimentar con cada una de ellas y elegir la que se adapte mejor según la situación y necesidad específica, con la intención de practicarla regularmente para obtener buenos resultados.

2.3.1.1.1 Respiración (4-7-8)

De acuerdo con [50], consiste en la respiración seguida de una pausa que permite que los canales colaterales se abran y se expandan. Activa el sistema nervioso parasimpático, lo

que reduce la frecuencia cardíaca y hace que el cuerpo se relaje y ralentiza la respiración, mejorando los niveles del cortisol.

Pasos:

1. Inhalar por la nariz durante cuatro segundos.
2. Mantener la respiración durante siete segundos.
3. Exhalar por la boca mientras hace un sonido de zumbido durante ocho segundos.
4. Repetir el ciclo hasta cuatro veces.

2.3.1.1.2 Respiración cuadrada (4-4-4-4)

Como menciona [51], esta técnica promueve la relajación, y ayuda a mantener los niveles de pH equilibrados en la sangre, lo que la hace beneficiosa para la reducción del estrés. Su simplicidad y eficacia son adecuadas para personas de todas las edades.

Pasos:

1. Inhalar por la nariz durante cuatro segundos.
2. Mantener la respiración durante cuatro segundos.
3. Exhalar lentamente durante cuatro segundos.
4. Mantener la respiración durante cuatro segundos.
5. Repetir el proceso.

2.3.1.1.3 Respiración abdominal o diafragmática

Según [52], en la respiración diafragmática, intervienen los músculos abdominales, ya que se respira con los lóbulos inferiores del pulmón, incrementando la cantidad de aire que llega al cuerpo, reduciendo el ritmo cardíaco lo que permite la estimulación del sistema nervioso parasimpático para incrementar los niveles de relajación y concentración.

Pasos:

1. Inhalar lentamente y a medida que esto sucede se debe empujar con la mano el abdomen.
2. Exhalar por la boca lentamente, mientras se siente la contracción del diafragma.
3. Repetir estos pasos de cinco a diez minutos.

2.3.1.1.4 Respiración nasal alterna (Nadi Shodhana)

Como expresa [53], la respiración nasal alterna suele ser utilizada en el yoga como medio de relajación del cuerpo y la mente, y la práctica puede traer beneficios en la

modulación del equilibrio simpático-vagal, la mejora de la función cardíaca, el refinamiento del metabolismo, el alivio del estrés, y el aumento de la agudeza cognitiva.

Pasos:

1. Tapar el orificio izquierdo de la nariz.
2. Exhalar completamente.
3. Destapar orificio izquierdo y tapar el orificio derecho.
4. Inhalar lentamente.
5. Repetir el proceso.

2.3.1.2 Técnicas de meditación

Es una práctica para promover la relajación y reducir el estrés y la ansiedad. La meditación permite despejar la carga de información acumulada día tras día, enfocar la atención en algo que pueda calmar a la persona que lo practica, así como dar paz y equilibrio. Algunos de los elementos esenciales que están presentes durante la meditación son: concentrar la atención, respiración relajada, lugar tranquilo, posición cómoda, y actitud abierta.

2.3.1.2.1 Meditación básica

Consiste en realizar algunos pasos básicos de la meditación. Se debe estar en un espacio tranquilo, estar cómodo, cerrar los ojos, y mantener la respiración evitando cualquier tipo de pensamiento.

2.3.1.2.2 Imaginación guiada

Según [54], la imaginación guiada permite la generación interna de imágenes, que invocan experiencias visuales, auditivas, hápticas y de gusto-olfato, además de desencadenar respuestas conductuales y fisiológicas. Consiste en utilizar la imaginación para crear imágenes que produzcan efectos emocionales y físicos beneficiosos. La imaginación guiada puede ser dirigida por otra persona, un vídeo o una grabación de audio. Una sesión comienza con una relajación profunda en la que el participante libera la tensión en su mente y cuerpo. La práctica de esta técnica puede influir en el manejo del estrés, ansiedad, y depresión.

2.3.1.2.3 Meditación con mantra

Como se menciona en [55], la meditación con mantra implica la repetición interna o vocal de una palabra o frase que resuena con nosotros a nivel personal. Este sonido, o mantra,

actúa como un ancla que nos devuelve al presente cada vez que la mente divaga. Al centrarnos en la repetición del mantra, creamos un espacio mental donde los pensamientos intrusivos tienen menos oportunidad de arraigarse, promoviendo así una mayor calma y claridad mental.

2.3.1.2.4 Meditación de atención plena (Mindfulness)

Conforme con [56], consiste en prestar atención al momento presente, sin juzgar, se trata de cultivar la conciencia de nuestros pensamientos, emociones y sensaciones corporales, aceptando como son. Al practicar la atención plena, desarrollamos la capacidad de observar nuestros pensamientos sin dejarnos arrastrar por ellos, reduciendo el estrés y la ansiedad. Esta práctica nos ayuda a conectarnos con nosotros mismos y con el mundo que nos rodea de una manera más profunda y consciente, mejorando nuestra calidad de vida en general. Podemos aplicar Mindfulness simplemente prestando atención a lo que estamos haciendo en cada instante, ya sea al caminar, comer o conversar.

2.3.1.3 Otras técnicas de relajación

2.3.1.3.1 Relajación muscular progresiva

En [57], afirman que es un ejercicio útil donde se contraen activamente los músculos para crear tensión y se liberan progresivamente hasta alcanzar un buen punto de relajación. Los efectos pueden aliviar la ansiedad, y momentos de alto estrés o nerviosismo.

Pasos:

1. Elegir una posición cómoda.
2. Inhalar y tensar un grupo muscular durante algunos segundos.
3. Echar rápidamente para relajar el grupo muscular.
4. Pausar unos segundos y notar cómo sientes los músculos.
5. Repetir el proceso.

2.3.1.3.2 Interacciones por tacto

Según [58], el tacto produce un efecto calmante y/o de alivio del estrés en la mayoría de las interacciones y puede reflejarse en las respuestas emocionales y fisiológicas. Existen diferentes interacciones como por ejemplo: en los animales, muchas personas encuentran consuelo y alivio del estrés acariciando sus mascotas; y en las personas, al sentir la presencia de alguien por su calor o al sentir su respiración lenta y los latidos del corazón trae beneficios

tranquilizantes, así como recibir un masaje también ayuda en a mejorar los niveles de estrés y ansiedad.

2.3.1.3.3 Distracción

En [59], se menciona que la distracción es un técnica de relajación de manejo cognitivo-conductual que desvía la atención del individuo de un estímulo estresante hacia un estímulo más placentero, y se considera una intervención psico-cognitiva que incluye componentes pasivos y activos. Usualmente se aplica a niños mientras reciben o esperan por procedimientos médicos dolorosos para que olviden el dolor y el miedo. La aplicación de esta técnica puede incluir el uso de música, videos, juegos, entre otros.

2.4 Grandes Modelos de Lenguaje

Un Gran modelo del lenguaje (*Large Language Model, LLM*) es un modelo de Inteligencia Artificial, diseñado para comprender, generar y manipular el lenguaje humano de forma que imita las habilidades del lenguaje natural, su proceso de entrenamiento implica el aprendizaje no supervisado a partir de un corpus diverso, que incluye libros, repositorios de código, sitios web y más, lo que permite que el modelo desarrolle una comprensión integral del lenguaje, el contexto y el conocimiento del mundo [60]. La evolución de los LLMs, abarca desde enfoques basados en reglas (1950-1960) y modelos estadísticos (1980-1990) hasta redes neuronales recurrentes (2010); sin embargo, la revolución llega con la arquitectura *Transformer* (2017), que permitió a modelos como BERT y GPT, ser capaces de procesar texto en paralelo y capturar contextos complejos; luego modelos posteriores, como GPT-3 (2020) y GPT-4 (2023), escalaron a miles de millones de parámetros, es decir la cantidad de variables que el modelo puede ajustar durante el entrenamiento para aprender patrones en los datos, ofreciendo capacidades avanzadas de generación de texto y multimodalidad [61].

Los avances tecnológicos han permitido el desarrollo de modelos del lenguaje especializados que buscan optimizar el desempeño en tareas específicas, complementando así a los LLMs de propósito general. Estos modelos pueden estar enfocados en áreas como el razonamiento, la resolución de problemas matemáticos o la generación de código. Algunos de los modelos destacados en 2024 e inicios de 2025 se mencionan en [62]: *GPT-4* (desarrollado por OpenAI GPT) es un modelo multimodal que se destaca en tareas como descripción de imágenes y la resolución de problemas; *Claude 3.5*, (desarrollado por Anthropic) es un

modelo enfocado en áreas especializadas como la codificación y el razonamiento científico; *LLaMA 3.1* (desarrollado por Meta AI) es un modelo que se especializa en codificación, resolución de problemas lógicos y tareas de lenguaje de bajo consumo de recursos; *Qwen 2.5* (desarrollado por Alibaba Cloud) es un modelo especializado en tareas como razonamiento matemático, generación de código y comprensión de lenguajes; *DeepSeek R1* (desarrollado por DeepSeek) es un modelo diseñado para aplicaciones de búsqueda y recuperación de información, optimizando la capacidad de encontrar y presentar datos relevantes de manera eficiente y precisa; y *Gemini 2.0 flash* (desarrollado por Google) es un modelo multimodal que permite integrar funciones externas (Búsqueda de Google y Maps) e integrar datos de streaming para aplicaciones en tiempo real ampliadas. Cabe resaltar, que cada una de las empresas mencionadas tienen actualmente modelos con versiones mejoradas que cubren áreas más específicas y con mayor precisión en las respuestas generadas (ej., Gemini en su versión 3.0 ahora tiene funciones mejoradas de respuestas rápidas, razonamiento y multimodalidad).

El uso de los LLMs se presenta en diversas modalidades. Inicialmente, se puede acceder a estos modelos a través de plataformas web interactivas proporcionadas por los desarrolladores. Por ejemplo, la plataforma de *OpenAI* permite a los usuarios experimentar directamente con las capacidades del modelo ChatGPT mediante una interfaz intuitiva para la generación y manipulación de texto [63]. En segundo lugar, los LLMs pueden integrarse en proyectos de software a través de Interfaces de Programación de Aplicaciones (APIs). Un caso ilustrativo es el uso de la API que proporciona la plataforma de *Google AI for Developers*, para incorporar funcionalidades de los modelos de Gemini en aplicaciones personalizadas [60]. Finalmente, los LLMs pueden ejecutarse localmente en infraestructuras computacionales propias, mediante herramientas como *OLLAMA*, que permite trabajar con diferentes modelos en entornos con requisitos específicos de privacidad o acceso sin conexión [64]. Estas distintas modalidades de uso demuestran la flexibilidad y adaptabilidad de los LLMs para una amplia gama de aplicaciones o requerimientos.

No obstante, el uso de los LLMs debe considerar los riesgos significativos que se pueden presentar ante el sesgo y desinformación al replicar patrones en sus datos de entrenamiento y propagar la desinformación de manera convincente. Su potencial uso para automatizar tareas lingüísticas genera interrogantes sobre la falta de transparencia en su funcionamiento que puede dificultar un buen rendimiento. Por lo que se requiere una atención cuidadosa a sus implicaciones para garantizar su desarrollo y uso responsable. Algunos desafíos de los LLMs son expuestos por [65]: (1) pueden generar contenido tóxico,

incluyendo insultos, discurso de odio y amenazas, por lo que evaluar completamente esta toxicidad puede ser un desafío; y (2) pueden tener alucinaciones, esto sucede cuando proporcionan información falsa o incorrecta, que puede ser intrínseca (contradice la fuente) o extrínseca (no se puede verificar con la fuente), además las razones incluyen la mala comprensión del texto fuente, conflictos con el conocimiento pre-entrenado y un sesgo hacia este conocimiento.

Los LLMs por lo general ofrecen un modo de configuración para el diseño y prueba de sus entradas. Es decir, se pueden configurar algunos parámetros para obtener diferentes resultados. Este ajuste es importante para la conveniencia de las respuestas. En [66] se describen dos parámetros comunes de los diferentes proveedores de LLM: el parámetro de *temperatura*, que controla la aleatoriedad de la salida en general, donde una temperatura más baja produce salidas más deterministas y aumentar la temperatura podría generar mayor aleatoriedad, lo que fomenta resultados más diversos o creativos; y el parámetro *top-p* ajusta el grado de determinismo del modelo, controlando la diversidad al limitar el conjunto de tokens considerados a aquellos con mayor probabilidad. Por lo tanto, para obtener respuestas exactas y objetivas, es recomendable mantener este valor bajo.

2.4.1 Ingeniería de Prompts

Ahora bien, la forma en que se aprovechan las capacidades de los LLMs para cada una de las aplicaciones o requerimientos es a través de la formulación de una instrucción o entrada específica, conocida como *prompt*. El objetivo principal es proporcionar al LLM instrucciones para lograr una tarea deseada. Por ejemplo “*Describe un amanecer*”, dado este prompt el LLM procesa y genera una salida como “*Es un momento de magia y misterio, donde el tiempo parece detenerse por un instante*” o “*Un manto de dorado se extiende sobre las colinas, iluminando las sombras de la noche que se desvanecen*”, entre otras posibilidades. Las respuestas son dadas de forma probabilística, basadas en los patrones que el modelo ha aprendido durante su entrenamiento con grandes cantidades de datos. En ese sentido, se ha originado la Ingeniería de Prompts, que como señala [67], es el proceso de diseñar y refinar los prompts, para guiar al modelo en la generación de resultados, considerando un conjunto de habilidades, métodos y técnicas para obtener las respuestas más precisas, pertinentes y contextualmente apropiadas.

2.4.1.1 Elementos clave de un prompt

El diseño de un prompt debe considerar algunos elementos clave para guiar al modelo a una respuesta deseada. En [68] se mencionan varios elementos básicos e importantes para redactar un prompt:

- Contexto: Describe quién formula la pregunta e incluye información relevante sobre la solicitud para guiar al modelo.
- Instrucción: Define lo que se espera del modelo, usa verbos de acción sobre la tarea.
- Rol: Asigna una perspectiva de cómo debe actuar el modelo (profesión, estilo).
- Formato de salida: Especifica cómo debe presentarse la respuesta, es decir se define el tipo de formato (lista, tabla, etc.).

En la tabla 2.3, se muestran dos ejemplos relacionados a los casos de estudio de este Proyecto de Grado, con respuestas generadas por el modelo *Gemini 2.5*.

Contexto	Instrucción	Rol	Formato de salida	Respuesta
"Soy un estudiante universitario repasando álgebra básica. Necesito ayuda para simplificar expresiones."	"Explica cómo simplificar: $3a+2b-4a+9b$. Detalla cada paso y las reglas usadas."	"Sé un profesor de álgebra claro y preciso. Usa lenguaje sencillo."	"Muestra la solución en lista numerada, con cada paso explicado. Resume las reglas al final."	https://g.co/gemini/share/c83926cd5736
"Soy un estudiante universitario que experimenta altos niveles de estrés debido a la carga académica, los exámenes y la presión social."	"Proporciona estrategias prácticas para manejar el estrés en un entorno universitario. Incluye técnicas de relajación, consejos de organización."	"Actúa como un consejero estudiantil experto en el manejo del estrés y el bienestar emocional. Utiliza un tono comprensivo y alentador."	"Presenta la información en una lista con viñetas, dividida en secciones claras: Técnicas de relajación, Organización y Gestión del tiempo. Incluye ejemplos concretos y consejos prácticos para cada sección."	https://g.co/gemini/share/a0a749c1cf80

Tabla 2.3: Ejemplos de prompts utilizando los elementos clave.

La estructuración de un prompt no se limita a la inclusión de los elementos clave. Para ello existen *frameworks* que ofrecen métodos y plantillas para organizar estos elementos de manera que maximicen la efectividad y la coherencia de la respuesta del LLM. Por ejemplo *CLEAR* es un método diseñado para optimizar las interacciones con modelos de lenguaje que abarca cinco principios centrales: *Concise*, prioriza la brevedad y claridad eliminando información innecesaria para obtener respuestas precisas; *Logical*, asegura un flujo ordenado de ideas para mejorar la comprensión del contexto; *Explicit*, establece especificaciones claras sobre el formato y alcance de la salida para evitar respuestas irrelevantes; *Adaptive*, fomenta la flexibilidad y el ajuste de los prompts para equilibrar la creatividad y el enfoque; y

Reflective, enfatiza la evaluación continua y la mejora de los prompts basándose en la retroalimentación y los resultados obtenidos [69].

Por su parte, *ROSES* es una plantilla que tiene un enfoque flexible y está estructurado en torno a cinco elementos: *Role*, proporciona el rol en el que debe enfocarse el modelo LLM; *Objective*, establece los objetivos específicos a cubrir; *Scenario*, presenta escenarios o contextos para ampliar la información; *Expected Solution*, especifica las soluciones esperadas y un formato de salida; y *Steps*, describe los pasos necesarios para guiar al modelo [70].

Así mismo, diversos autores resaltan la importancia del formato en la organización de la información. Al escribir prompts, se sugiere el uso de etiquetas XML para facilitar que el modelo comprenda mejor los límites lógicos de los datos y el contexto [71]. Esta recomendación se basa en la observación de que los LLMs tienden a enfocarse con mayor atención en el contenido que se encuentra delimitado por estas etiquetas [72].

2.4.1.2 Proceso de un prompt

Como menciona [73] en el diseño de un prompt efectivo se considera necesario realizar un proceso que debe incluir los siguientes pasos:

1. Definir el objetivo: Identifica los resultados específicos que se desea que el modelo genere. (ej., objetivos de aprendizaje).
2. Determinar el tipo y el formato del contenido: Decide el tipo de contenido (ej., preguntas de cuestionario, caso práctico) y el formato (ej., opción múltiple, respuesta larga) que mejor se adapte a los objetivos y al contexto.
3. Elaborar el prompt inicial: Crear un prompt claro y conciso que comunique eficazmente el contenido y el formato deseados al modelo. Asegúrese de incluir los elementos clave como el contexto, las instrucciones y los parámetros necesarios para guiar al modelo hacia el resultado deseado.
4. Probar el prompt inicial: Introducir el prompt al modelo para generar un resultado inicial.
5. Reflexionar sobre el resultado: Evaluar el contenido generado por el modelo para comprobar si se alinea con el objetivo previsto.
6. Iterar el proceso: Si el contenido no cumple con las expectativas, perfeccionar el prompt ajustando los elementos clave, y repetir el proceso hasta lograr el resultado deseado.

2.4.1.3 Técnicas de Ingeniería de Prompt

Existen diversas técnicas para aprovechar las respuestas de los LLMs mediante los prompts. En [74] se describe una lista detallada de técnicas tal como se observa en la tabla 2.4.

Técnica de Prompting	Descripción	Área de aplicación
Zero-shot Prompting	Utiliza prompts cuidadosamente elaborados para guiar al modelo hacia nuevas tareas sin necesidad de datos de entrenamiento específicos.	Nuevas Tareas sin entrenamiento extenso
Few-shot Prompting	Proporciona al modelo algunos ejemplos de entrada-salida para inducir la comprensión de una tarea dada, mejorando el rendimiento en comparación con el zero-shot.	Nuevas Tareas sin entrenamiento extenso
Chain-of-Thought (CoT) Prompting	Solicita al modelo que genere una cadena de razonamiento paso a paso para problemas complejos, imitando el proceso de pensamiento humano.	Razonamiento y Lógica
Automatic Chain-of-Thought (Auto-CoT)	Genera automáticamente cadenas de razonamiento utilizando un prompt inicial como "Pensemos paso a paso", mejorando la robustez mediante el muestreo diverso.	Razonamiento y Lógica
Self-Consistency	Emplea una estrategia de decodificación que muestrea diversas cadenas de razonamiento y selecciona la respuesta final más consistente para tareas complejas.	Razonamiento y Lógica
Logical CoT (LogiCoT) Prompting	Marco neurosimbólico que aplica principios de la lógica simbólica para verificar cada paso del razonamiento, reduciendo errores lógicos y alucinaciones.	Razonamiento y Lógica
Chain-of-Symbol (CoS) Prompting	Utiliza símbolos condensados en lugar de lenguaje natural para prompts, mejorando el razonamiento espacial y la interpretabilidad humana.	Razonamiento y Lógica
Tree-of-Thoughts (ToT) Prompting	Gestiona una estructura de árbol de pasos de razonamiento intermedios "pensamientos", permitiendo la exploración y la búsqueda anticipada de soluciones. Es útil para mantener un razonamiento consistente a lo largo de varias preguntas relacionadas a un contenido extenso.	Razonamiento y Lógica
Graph-of-Thoughts (GoT) Prompting	Modela el proceso de razonamiento como un grafo dirigido, permitiendo una interacción dinámica, retroceso y evaluación de ideas, capturando la naturaleza no lineal del pensamiento humano.	Razonamiento y Lógica
System 2 Attention (S2A) Prompting	Utiliza las capacidades de razonamiento del modelo para regenerar el contexto de entrada, permitiendo una atención selectiva a las partes relevantes y mejorando la calidad de la respuesta.	Razonamiento y Lógica
Thread of Thought (ThoT) Prompting	Examina sistemáticamente contextos extensos en segmentos manejables para un análisis incremental, mejorando el razonamiento en contextos caóticos.	Razonamiento y Lógica
Chain of Table Prompting	Emplea un razonamiento tabular paso a paso, generando y ejecutando dinámicamente operaciones SQL/DataFrame en tablas para mejorar los resultados intermedios.	Razonamiento y Lógica
Retrieval Augmented Generation (RAG)	Integra la recuperación de información de una base de conocimiento externa en el proceso de prompting para enriquecer el prompt original y generar respuestas más precisas	Reducción de Alucinaciones

	y actualizadas.	
ReAct Prompting	Permite al modelo generar trazas de razonamiento y acciones específicas de la tarea de forma concurrente, mejorando la sinergia entre el razonamiento y la acción.	Reducción de Alucinaciones
Chain-of-Verification (CoVe) Prompting	Involucra un proceso sistemático de cuatro pasos donde el modelo genera una respuesta, planifica preguntas de verificación, responde las preguntas y revisa la respuesta inicial.	Reducción de Alucinaciones
Chain-of-Note (CoN) Prompting	Evalúa sistemáticamente la relevancia de los documentos recuperados para modelos de lenguaje aumentados con recuperación (RALMs), filtrando contenido irrelevante y mejorando la precisión.	Reducción de Alucinaciones
Chain-of-Knowledge (CoK) Prompting	Descompone tareas complejas en pasos coordinados, iniciando con una preparación exhaustiva del razonamiento y adaptando dinámicamente el conocimiento de diversas fuentes.	Reducción de Alucinaciones
Active-Prompting	Selecciona las preguntas más impactantes para la anotación con ejemplos de cadena de pensamiento, mejorando el rendimiento del modelo en tareas complejas de preguntas y respuestas.	Interacción con el Usuario
Automatic Prompt Engineer (APE)	Genera y selecciona dinámicamente los prompts más efectivos para tareas específicas, utilizando aprendizaje por refuerzo para adaptar los prompts a diferentes contextos.	Ajuste Fino y Optimización
Automatic Reasoning and Tool-use (ART)	Permite a los modelos razonar a través de procesos de múltiples pasos e integrar herramientas externas para conocimientos y cálculos especializados.	Razonamiento y Generación Basado en Conocimiento
Contrastive Chain-of-Thought (CCoT) Prompting	Proporciona demostraciones de razonamiento tanto válidas como inválidas junto con los prompts originales para enseñar al modelo a aprender de los errores.	Mejora de la Consistencia y Coherencia
Emotion Prompting	Añade oraciones de estímulo emocional a los prompts para mejorar la inteligencia emocional del modelo y su capacidad para comprender señales psicológicas.	Gestión de Emociones y Tono
Scratchpad Prompting	Permite al modelo generar una secuencia arbitraria de tokens intermedios (un "bloc de notas") antes de proporcionar la respuesta final, útil para tareas complejas que requieren razonamiento preciso.	Generación y Ejecución de Código
Program of Thoughts (PoT) Prompting	Aboga por el uso de intérpretes de lenguaje externos para los pasos de cálculo en problemas matemáticos, permitiendo que el modelo exprese el razonamiento a través de programas ejecutables.	Generación y Ejecución de Código
Structured Chain-of-Thought (SCOT) Prompting	Incorpora estructuras de programación (secuencia, bifurcación y bucle) en los pasos de razonamiento para mejorar el rendimiento de los modelos en la generación de código estructurado.	Generación y Ejecución de Código
Chain-of-Code (CoC) Prompting	Extiende el razonamiento del modelo aprovechando la escritura de código para tareas tanto lógicas como semánticas, utilizando un "LMulator" para simular comportamientos indefinidos.	Generación y Ejecución de Código
Optimization by	Utiliza modelos de lenguaje como optimizadores, generando	Optimización y Eficiencia

Prompting (OPRO)	soluciones iterativamente basadas en la descripción del problema a través de prompts en lenguaje natural.	
Rephrase and Respond (RaR) Prompting	Permite al modelo reformular y expandir preguntas en un solo prompt, mejorando la comprensión y la precisión de la respuesta al alinear los marcos de pensamiento humano y del modelo.	Entendimiento de la Intención del Usuario
Take a Step Back Prompting	Permite a los modelos realizar abstracciones, extrayendo conceptos de alto nivel y principios fundamentales de instancias específicas para mejorar el razonamiento en tareas complejas.	Metacognición y Autorreflexión

Tabla 2.4: Técnicas de prompting.

2.5 Grafo del Conocimiento

El término Grafo del Conocimiento (*Knowledge Graph, KG*), tal como afirma [75] se ha utilizado en la literatura desde al menos 1972, pero fue con el anuncio de Google en 2012 que tuvo un salto de relevancia cuando presentaron su base de conocimiento estructurada para mejorar el motor de búsqueda, y luego otras empresas fueron adoptando su bases de conocimiento con grafos. El modelo de datos basado en grafos permite capturar conocimiento en escenarios de aplicación que implican la integración, la gestión y la extracción de valor de diversas fuentes de datos.

Así mismo, el uso de una abstracción del conocimiento basada en grafos ofrece diversas ventajas en comparación con un modelo relacional, como menciona [76]: (1) las relaciones de muchos a muchos en una base de datos relacional se pueden implementar fácilmente como aristas en una base de datos de grafos sin introducir nodos adicionales; y (2) se puede acceder rápidamente a los datos almacenados en una base de datos de grafos mediante consultas sencillas, mientras que en una base de datos relacional es necesario unir varias tablas para el mismo propósito.

De acuerdo con [77], un grafo de conocimiento es un grafo dirigido que se compone de nodos y aristas. En este contexto, un nodo representa una entidad (ya sea un objeto real o un concepto abstracto), y una arista conecta dos nodos que poseen una relación semántica. La unidad fundamental de un grafo de conocimiento es una tripleta (sujeto, predicado, objeto). Debido a que las relaciones no son necesariamente simétricas, la dirección de un enlace es importante. Un ejemplo de un grafo de conocimiento simple se muestra en la Figura 2.2, donde resalta (e1, r1, e2) como una tripleta indicando que e1 y e2 están conectados por la relación r1.




Figura 2.2: Diagrama representativo de un grafo de conocimiento [77].

2.5.1 Neo4j y Cypher

En la literatura se observan diferentes propuestas de bases de datos de grafos como JanusGraph, Nebula Graph, TigerGraph, y Neo4j, siendo esta última una de las más utilizadas [78]. Así mismo, existen diferentes propuestas de lenguajes para consultar grafos como el lenguaje de consulta SPARQL para grafos RDF (información en forma de tripletas sujeto-predicado-objeto), y Gremlin, G-CORE, y Cypher para consultar grafos que contienen propiedades [75]. En ese sentido, para este Proyecto de Grado se selecciona la base de datos Neo4j que usa el lenguaje de consulta Cypher.

Neo4j es una herramienta muy usada dentro del modelo de una base de datos *NoSQL* (no relacional), en la que almacena los datos en una estructura de grafos libremente adyacentes. Según [79], en comparación con una base de datos relacional, su método de consulta es lineal y más ágil; los nodos y las relaciones son elementos fundamentales de un grafo, y además los nodos pueden contener múltiples etiquetas y atributos (propiedades), lo que permite asociar un conjunto de pares propiedad-valor y una etiqueta con nodos y relaciones, ofreciendo mayor flexibilidad al modelar datos [75]. Neo4j ofrece varias formas para ser utilizada como: (1) *Neo4j Desktop*, que proporciona una interfaz para administrar todas sus bases de datos de Neo4j, ya sea en la nube o de forma local, y (2) *Neo4j AuraDB*, que es un servicio basado en la nube totalmente administrado.

Por su parte, el lenguaje de consulta que se utiliza en Neo4j es Cypher. el cual permite modificar, añadir y eliminar datos. Este es un lenguaje de consulta declarativo que se compone de diferentes sentencias, como menciona [79]: (1) consulta de nodos basada en el identificador, (2) consulta de nodos usando etiquetas, atributos y relaciones de entidades específicas, (3) consulta del número de nodos, (4) consulta de nodos basada en un atributo del

nodo, (5) consulta de la existencia de relaciones, (6) consulta del tipo de relación entre entidades, (7) consulta de relaciones multinivel, entre otras.

Un ejemplo, considerando el grafo de la Figura 2.2, es la siguiente consulta Cypher (*MATCH (e1:Entity {name: 'e1'})-[r]->(e2:Entity {name: 'e2'}) RETURN e1, r, e2*) que permite encontrar los nodos 'e1' y 'e2' y la relación directa entre ellos. La primera parte (*MATCH*), busca un patrón específico en el grafo: un nodo que se identifica como e1 (con la etiqueta Entity y una propiedad name cuyo valor es 'e1'), conectado por cualquier relación saliente (r), a otro nodo identificado como e2 (que también es una Entity y tiene name 'e2'); y la segunda parte (*RETURN*), se encarga de mostrar los resultados, presentando el nodo e1, la relación r que los une y el nodo e2 asociado.

2.5.2 Relación de los LLMs y Grafo del Conocimiento

Actualmente, el Grafo del Conocimiento (Knowledge graph, KG) está estrechamente vinculado con el uso de los LLMs debido a los desafíos inherentes que estos últimos presentan (ver sección 2.4). Una de las soluciones más efectivas hoy en día es la integración de conocimiento externo en los LLMs, como la Generación Aumentada de Recuperación (RAG). Esta se logra mediante la recuperación de documentos o la recuperación directa desde un KG. Sin embargo, aunque la recuperación de documentos proporciona información relevante, su eficacia se ve limitada por la imprecisión y la redundancia. En contraste, el KG ofrece una representación del conocimiento estructurada y rica, lo que proporciona al razonamiento del LLM conocimiento externo más oportuno y preciso [80].

Existen diferentes métodos en cómo puede ser incorporado el KG con los LLMs. Algunos investigadores han propuesto incorporar el KG a los LLMs durante la etapa de preentrenamiento, lo que puede ayudar a los LLMs a aprender conocimiento de los KG, mientras que otros investigadores han propuesto incorporar el KG durante la etapa de inferencia. No obstante, como afirma [81], el conocimiento del mundo real es dinámico y requiere actualizaciones frecuentes. A pesar de la eficacia de los KG en el preentrenamiento de modelos del lenguaje, estos métodos nunca permiten la actualización ni la edición del conocimiento sin un reentrenamiento, dando como resultado, deficiencias en el conocimiento reciente o desconocido.

Por su parte, los métodos de inferencia pueden mantener fácilmente las actualizaciones del conocimiento modificando las entradas. Estos métodos ayudan a mejorar el rendimiento con nuevos conocimientos y dominios. Un ejemplo reciente es el trabajo de [82] donde se

propone aumentar el conocimiento directamente en la entrada del LLM, mediante la recuperación de datos relevantes dentro del grafo y basándose en las similitudes semánticas entre la pregunta y los datos asociados. Posteriormente, estos datos recuperados se añaden en la pregunta en forma de prompt antes de ser enviados al LLM para generar una respuesta. El enfoque de este trabajo no requiere un entrenamiento adicional de los LLMs, sino que aprovecha y se apoya de la Ingeniería de Prompts y grafo de conocimiento para dar un contexto relevante y obtener respuestas favorables.

2.6 Sistema Operativo Robótico (ROS)

El Sistema Operativo Robótico (ROS) es un ecosistema de robótica de código abierto, creado en 2007 por Willow Garage. Consiste en un middleware (software que se sitúa entre un sistema operativo y las aplicaciones que se ejecutan en él) y herramientas extensas, comúnmente requeridas para construir diversos sistemas robóticos [83]. Así mismo, ROS se ha convertido en el estándar para investigaciones de índole robótica. A nivel general ofrece grandes servicios como: abstracción de hardware, control de dispositivos de bajo nivel, pase de mensajes entre procesos y gestión de paquetes [84]. La infraestructura de comunicación de ROS, ha sido una característica importante, permitiendo comunicar diferentes nodos mediante el patrón de *publicación-suscripción* basado en tópicos (ver figura 2.3), donde los nodos son unidades de procesamiento, pertenecientes a un grafo computacional que utilizan canales (tópicos), para comunicarse entre ellos.




Figura 2.3: Patrón publicación-suscripción de tópicos en ROS [84]

La evolución de ROS abarca desde las diferentes versiones agrupadas como *ROS1* hasta la nueva generación con mejoras denominada *ROS2*. Como describe [85], ROS1

permitió el desarrollo de un sistema que ha adquirido influencia en casi todos los sectores de las máquinas inteligentes, con proyectos emblemáticos para la navegación autónoma, simulación, visualización, control, y más. No obstante, estas versiones han presentado muchas limitaciones como la seguridad, fiabilidad en entornos no tradicionales y compatibilidad con aplicaciones a gran escala, etc. De este modo, nace la generación ROS2, con un rediseño para abordar los desafíos, aprovechando el éxito de sus capacidades impulsadas por la comunidad, ROS2 resuelve muchos de los problemas en la construcción de sistemas robóticos fiables para obtener mejor seguridad, soporte integrado y en tiempo real, comunicación multi-robot, y operaciones en entornos de red no ideales.

2.6.1 Especificaciones de ROS2

ROS2 admite una amplia gama de aplicaciones robóticas, desde la educación y la investigación hasta el desarrollo e implementación de productos. Comprende un amplio conjunto de componentes de software interrelacionados que se utilizan habitualmente para desarrollar aplicaciones robóticas. A partir del trabajo realizado por [85] se describen algunas especificaciones importantes.

2.6.1.1 Principios de diseño

El diseño de ROS2 se ha guiado por un conjunto de principios y requisitos específicos:

- **Distribución:** Emplea un enfoque de sistemas distribuidos para gestionar la complejidad robótica. Los componentes (controladores de hardware, sistemas de percepción, etc.) son funcionalmente independientes, operan en contextos de ejecución separados y se comunican mediante intercambio explícito de datos.
- **Abstracción:** Define interfaces claras para la comunicación entre componentes, promoviendo la interoperabilidad y reduciendo dependencias de hardware/software específico.
- **Asincronía:** La comunicación se basa en mensajes asíncronos y eventos, adaptándose a múltiples dominios temporales (ej. hardware con frecuencias fijas y software con actualizaciones variables). Este modelo maneja la concurrencia inherente en sistemas robóticos, donde componentes operan a ritmos independientes sin bloqueos mutuos.
- **Modularidad:** Inspirado en la filosofía UNIX de *"make each program do one thing well"*, ROS 2 aplica modularidad en todos los niveles: APIs, definiciones de mensajes, herramientas y el ecosistema mismo. Se organiza en paquetes

independientes, promoviendo reutilización, mantenibilidad y escalabilidad en el desarrollo de software robótico.

Adicionalmente, ROS 2 busca cumplir ciertos requisitos basados en lo anterior y las necesidades de los desarrolladores de robótica:

- Seguridad: El sistema de seguridad integrado incluye autenticación, cifrado y control de acceso. Los diseñadores pueden configurar a ROS2 para satisfacer sus necesidades mediante políticas de control de acceso que definen quién puede comunicarse sobre qué.
- Sistemas Embebidos: Los robots integran dispositivos embebidos (sensores, actuadores, microcontroladores) que requieren comunicación con las CPUs principales donde opera ROS 2, por lo que se facilita su integración mediante estándares de comunicación y herramientas como micro-ROS, una adaptación de ROS 2 optimizada para dispositivos embebidos pequeños.
- Redes Diversas: Los robots se utilizan en diversos entornos de red, desde redes cableadas para brazos robóticos en líneas de ensamblaje hasta conexiones satelitales para exploradores planetarios. Además, los robots suelen utilizar redes internas para conectar procesos dentro y entre las CPU. ROS2 configura el flujo de datos a través del sistema, adaptándose así a las restricciones de la red.
- Tiempo Real: Desde humanoides hasta vehículos autónomos, es común que las aplicaciones robóticas incluyan requisitos de computación en tiempo real. Para cumplir con los objetivos de seguridad o rendimiento, algunas partes de un sistema deben ejecutarse en plazos deterministas. ROS2 ofrece una API para que los desarrolladores de sistemas en tiempo real apliquen restricciones específicas de la aplicación.
- Disponibilidad del producto: Cuando un robot trasciende del prototipo al ámbito comercial, se introducen nuevas restricciones. ROS2 busca satisfacer los requisitos del producto, que abarcan desde el diseño, el desarrollo y la gobernanza del proyecto. Esto permite que ROS2 se ejecute en sistemas críticos para la seguridad, como vehículos autónomos y maquinaria pesada.

2.6.1.2 Patrones de comunicación

Los patrones de comunicación incluyen varios componentes como los tópicos, servicios y acciones, organizados bajo el concepto de nodo. En la figura 2.4 se muestra el diagrama general del funcionamiento de los patrones de comunicación de ROS2.

- **Nodos:** Los nodos son procesos donde la computación se lleva a cabo. Usualmente un sistema contiene múltiples nodos conectados, cada uno con diferentes funciones.
- **Tópicos:** Son el núcleo de la comunicación asíncrona mediante el modelo publicador-suscriptor, donde nodos independientes intercambian mensajes fuertemente tipados a través de un grafo computacional. Esta arquitectura permite la comunicación muchos-a-muchos, facilitando la integración modular de componentes.
- **Servicios:** complementan la comunicación asíncrona mediante una petición-respuesta, ideal para casos que requieren confirmación explícita de ejecución (ej. activar un actuador o consultar datos específicos). Los servicios garantizan la finalización o recepción de una tarea, permite que el proceso de un cliente de servicio no se bloquee durante una llamada. Los servicios también se organizan bajo un nodo para su organización e introspección, lo que permite que las interfaces de un subsistema aparezcan juntas en el diagnóstico del sistema.
- **Acciones:** Las acciones son interfaces de comunicación asíncronas y orientadas a objetivos con petición-respuesta, retroalimentación periódica y posibilidad de cancelación. Este patrón se utiliza en tareas de larga duración, como la navegación o la manipulación autónoma, aunque tiene diversos usos. Al igual que los servicios, las acciones no son bloqueantes y se organizan bajo el nodo.




Figura 2.4: Diagrama del funcionamiento de los patrones de comunicación de ROS2 [85].

Capítulo III. Diseño

Este capítulo describe la propuesta principal de este proyecto de grado, que es la arquitectura de integración de los LLMs con MIHR.

3.1 Arquitectura de Integración

En esta sección del capítulo se describe el proceso de diseño e implementación de la *Arquitectura de Integración*, cuyo objetivo es evaluar el funcionamiento de la arquitectura MIHR. El diseño de la *Arquitectura de Integración* está compuesta por cuatro capas (ver Figura 3.1): Validación manual, Auto-Configuración, Ejecución, y Auto-evaluación. El objetivo de la capa de *Validación manual* es verificar el comportamiento de los componentes del MIHR de forma individual. La capa de *Auto-configuración* consiste en desplegar todos los componentes necesarios del MIHR para la interacción (en otras palabras, configura la arquitectura MIHR). La capa de *Ejecución* se centra en la interacción real entre el usuario y la arquitectura MIHR. Finalmente, la capa de *Auto-evaluación* estima la satisfacción del estudiante para evaluar el impacto de la interacción.

Para esta arquitectura se tienen dos entradas esenciales: el (1) *objetivo de interacción*, que permite especificar el caso de estudio y el usuario para adaptar la interacción; y el (2) *grafo de conocimiento*, que facilita la información del caso de estudio y del usuario para adaptar la interacción, y también puede proporcionar un conjunto de pruebas para validar el uso de componentes del MIHR.

Como consideraciones de implementación, se usan los LLMs para cada una de las 4 capas (ver resumen en la tabla 3.1). La formulación de los prompts se basa en la teoría descrita en la sección 2.4.1. Se emplea el framework *ROSES* para considerar y especificar elementos como el rol del modelo, objetivos, contexto, formato de salida, y los pasos para generar la respuesta. Para sistematizar su uso, los elementos de estos prompts se organizan y etiquetan empleando el formato XML.




Figura 3.1: Diagrama general de la Arquitectura de Integración.

Capa	Módulo	Uso de los LLMs
Validación manual	Extracción de pruebas	Consultar al grafo para obtener las pruebas del componente a validar
	Generación de una instancia	Consultar al grafo para obtener la información del usuario y contexto
	Validación del funcionamiento	Realizar la validación del funcionamiento del componente
Auto-configuración	Generación de la configuración	Consultar al grafo para obtener la información del usuario y contexto
Ejecución	MIHR	Funcionamiento de componentes en la interacción
Auto-evaluación	Estimación de la satisfacción	Obtener patrones, generar rúbricas, obtener el feedback de satisfacción, y actualizar el grafo

Tabla 3.1: Uso de los LLMs en la Arquitectura de Integración.

3.2 Descripción detallada de los componentes de la Arquitectura

3.2.1 Objetivo de Interacción

Para definir el objetivo de interacción, se establece una estructura que permite conocer el caso de estudio, identificar el usuario, y ayudar en la planificación de la interacción. La estructura tiene cinco elementos: el <GÉNERO> permite ajustar las respuestas del robot según el género del estudiante, <USUARIO> para identificar al estudiante que va a realizar la sesión, el <REQUERIMIENTO> que especifica el enfoque (por ejemplo, practicar), el <TÓPICO> que determina el contenido del caso de estudio, y la <DIFICULTAD> si se quiere abordar un nivel de complejidad particular en los ejercicios. A continuación, se muestra la estructura, elementos, y ejemplos.

Estructura:

<GÉNERO> <USUARIO> <REQUERIMIENTO> <TÓPICO> <DIFICULTAD>

Elementos:

<GÉNERO>: el, la

<USUARIO>: nombre y apellido del estudiante

<REQUERIMIENTO>: practicar, entender, explorar

<TÓPICO>: tema de matemática o técnica de manejo del estrés

<DIFICULTAD>: baja, media, alta

Ejemplos:

La joven Yrazu Carmona necesita practicar ecuaciones con poca dificultad

El estudiante Jesús Pérez quiere explorar las técnicas de respiración

El estudiante José Castro quiere practicar el tema de exponentes y radicales

Esta estructura se considera flexible, dado que pueden o no aparecer todos los elementos de forma explícita. Son obligatorios el <TÓPICO>, para ajustar el plan general con el contenido, y el <USUARIO> para adaptar la conversación según una experiencia previa. Los demás elementos tienen valores predeterminados: el género es neutral, el requerimiento por defecto es practicar, y la dificultad inicial es baja, permitiendo una configuración rápida.

3.2.2 Grafo de Conocimiento

3.2.2.1 Construcción del Grafo de Conocimiento

La construcción del grafo de conocimiento consta principalmente de tres partes (ver Figura 3.2): Adquisición de datos, definición de la ontología, y almacenamiento de datos.




Figura 3.2: Diagrama para la construcción del Grafo de Conocimiento.

Adquisición de datos: incluye todos los datos que se almacenan en el grafo, los cuales provienen de las siguientes fuentes: (a) para el caso de estudio de aprendizaje de las matemáticas, se utiliza un libro de precálculo [86], donde se recupera la información relacionada con los primeros temas de los fundamentos del álgebra; (b) para el caso de estudio de manejo del estrés, se usa el trabajo de [49], para extraer las técnicas de relajación y

meditación, y el trabajo de [87] para extraer las técnicas de distracción; (c) y para las pruebas de los componentes, se generaron escenarios a partir de un LLM, donde se incluye la entrada, salida y score, tal como se muestran los ejemplos en el Anexo 2.

Definición de la ontología: permite comprender fácilmente entidades, sus tipos y las relaciones entre entidades. Los datos del grafo de conocimiento se expresan normalmente en forma de tripletas (entidad, relación, entidad) y consideran también sus propiedades. Entonces, para esta parte se toman los datos no estructurados y se define la ontología a utilizar para organizar y estructurar los datos. En la Tabla 3.2 se presenta la definición de los nodos con las etiquetas, propiedades clave y una descripción; por su parte, en la Tabla 3.3 se muestra la definición de las relaciones entre los nodos con su descripción.

Etiqueta (concepto)	Propiedades clave	Descripción
:robot	name (Ej: 'LRS2')	Represente el robot que usa el modelo
:modelo	name (Ej: 'MIHR')	Representa la entidad perteneciente al Modelo de Interacción Humano-Robot
:usuario	name (Ej: 'José Castro')	Representa la entidad asociada con un usuario que ha interactuado con el robot
:experiencia	name (Ej: exponentes y radicales) sesión (número de sesión),	Representa la entidad relacionada con algún objetivo de interacción abordado
:sesión	name (ID de la sesión), características (Ej. le gustan las analogías), score (Ej. 80)	Representa la sesión realizada
:componente	name (Ej: 'afectivo', 'verbal', 'normativo')	Representa un componente funcional del modelo.
:test	name (ID de prueba), score (puntuación), entrada / entrada1...entrada5, salida (Las propiedades varían según el componente al que apliquen).	Representa un caso de prueba utilizado para verificar el funcionamiento de un componente
:contexto	name (Ej: 'matemática', 'manejo del estrés')	El área de aplicación o conocimiento de alto nivel.
:categoría	name (Ej: 'técnica de respiración', 'técnica de meditación')	Estrategias usadas dentro de un contexto
:técnica	name, procedimiento (descripción paso a paso de la técnica)	Un procedimiento asociado a una categoría
:contenido	name (Ej: 'fundamentos del álgebra')	Una unidad curricular asociada al contexto que incluye uno o más temas
:tema	name (Ej: 'expresiones algebraicas', 'ecuaciones')	División del conocimiento dentro de un contenido curricular
:tópico	name (Ej: 'ecuaciones cuadráticas', 'valor absoluto')	Subdivisión de un tema, que agrupa ejercicios relacionados.
:ejercicio	name (ID de problema), enunciado, clasificación (Ej: 'habilidad', 'aplicación', 'conceptual'), solución	Una instancia específica de tarea o problema para evaluar

Tabla 3.2: Definición de nodos

(origen, relación, destino)	Descripción
(robot, UTILIZA_MODELO, modelo)	Indica que el robot implementa o se basa en un modelo específico (MIHR).
(modelo, TIENE_COMPONENTE, componente)	Define la estructura del modelo, que se puede derivar en varios módulos
(componente, PRUEBA_UNITARIA, test)	Define el vínculo de validación; un componente es evaluado por un conjunto de pruebas unitarias.
(robot, RECONOCE_USUARIO, usuario)	Reconoce el vínculo que hay con el usuario
(usuario, TIENE_EXPERIENCIA, experiencia)	Indica experiencia en la interacción con el robot
(experiencia, TIENE_FEEDBACK, sesion)	Representa el resultado de una sesión asociado con el contexto de una experiencia
(robot, TIENE_CONOCIMIENTO, contexto)	Indica las áreas de conocimiento que maneja el robot.
(contexto, CONTIENE ESTRATEGIA, categoria)	Relaciona un contexto general (Ej: estrés) con sus estrategias
(categoria, TIENE_TECNICA, tecnica)	Una categoría agrupa varias técnicas específicas
(contexto, CONTIENE_UNIDAD, contenido)	Relaciona un contexto (Ej: matemática) con una unidad curricular
(contenido, TIENE_TEMA, tema)	Relaciona un tema (Ej: números reales, desigualdades) con el contenido asociado
(tema, INCLUYE_TOPICO, topico)	Un tema se descompone en tópicos más específicos.
(topico, CONTIENE_EJERCICIO, ejercicio)	Un tópico proporciona un conjunto de ejercicios.

Tabla 3.3: Definición de las Relaciones.

Almacenamiento de datos: se utiliza un enfoque que recientemente está teniendo relevancia con el uso de los LLMs, donde a partir de prompts en lenguaje natural se pueden generar instrucciones de Cypher (lenguaje para trabajar con bases de datos de grafos) [88, 89]. El proceso de almacenamiento para este trabajo comienza con el diseño del prompt (Cypher-Create), como se muestra en la Figura 3.3, donde se especifican las instrucciones necesarias para el mapeo de los datos, utilizando como datos de entrada: la ontología definida anteriormente $\{ontology\}$, la petición para guardar los datos $\{question\}$ y algunas reglas a seguir $\{rules\}$. El LLM se utiliza posteriormente para generar las instrucciones Cypher, las cuales se ejecutan inmediatamente sobre el grafo que guarda la información. Los datos se alojan en el servicio en la nube de Neo4j (Aura DB), y funcionan como una fuente de contexto necesaria para las interacciones en los casos de estudio.

```

Cypher_Create_Prompt

1 <role>
2   Eres un desarrollador experto en Neo4j
3 </role>
4 <objective>
5   Tu tarea es convertir la consulta del usuario (<query>) siguiendo el esquema de la
   ontología (<ontology>) en instrucciones Cypher validas. Considere las reglas (<rules>)
6 </objective>
7
8 <scenario>
9   <ontology>
10    {ontology}
11  </ontology>
12
13  <query>
14    {question}
15  </query>
16
17  <rules>
18    {rules}
19  </rules>
20 </scenario>
21
22 <expected_solution>
23   - Tu respuesta debe ser solo respecto a la consulta Cypher.
24   - NO incluyas ninguna explicación, encabezado, o texto adicional.
25 </expected_solution>

```

Figura 3.3: Prompt para almacenar datos en el grafo.

Al finalizar el proceso de construcción del grafo, se obtiene el grafo inicial ([ver en este enlace el grafo](#)). Allí se refleja la mayoría de los nodos, excepto los relacionados a los usuarios que son agregados a medida que se realizan las interacciones. Al lado izquierdo están los nodos asociados a los temas de matemáticas, en la parte inferior del centro están los nodos asociados a las técnicas de manejo de estrés, y a la derecha el conjunto de pruebas para los componentes del MIHR que serán validados.

3.2.2.2 Consulta del Grafo de Conocimiento

Las consultas también utilizan LLM a través de la herramienta *Langchain* [90]. Estas consultas se perciben en los módulos de “Extracción de Pruebas” para obtener las pruebas de un componente específico, y dentro del módulo “Generación de la Configuración” para obtener los datos según el caso de estudio y usuario en cuanto a la adaptación de la interacción. El proceso se muestra en la Figura 3.4, y se lleva a cabo mediante el diseño de un *prompt* con requerimientos específicos (ver Figura 3.5). A través de este prompt, el LLM genera las instrucciones Cypher necesarias para consultar y obtener los datos del grafo. El resultado es un conjunto de entidades únicas, cada una con sus propiedades: (1) *Examples*

que contiene datos de pruebas, donde se incluyen un conjunto de tuplas de entrada, salida y score o (2) *Context Data* cuyos datos incluyen información del caso de estudio y el usuario.




Figura 3.4: Diagrama para la recuperación de datos en el grafo de conocimiento.

En la Figura 3.5 se muestra el prompt (*Cypher-Retrieve Prompt*) usado para recuperar los datos necesarios del grafo. Allí se especifica el rol que debe asumir el modelo, instrucciones generales fijas, y datos de entrada específicos como: *{schema}* que contiene el esquema del grafo representado por los nodos y relaciones almacenados; *{question}* que contiene una consulta sobre un componente para extraer las pruebas pertinentes (ej. dame todas las pruebas para el componente deliberativo) o que contiene el objetivo de interacción para identificar el contexto y recuperar la información sobre el caso de estudio o el usuario (ej. el estudiante José Castro necesita practicar exponentes y radicales); y *{rules}* que contienen puntos específicos sobre cómo buscar los datos en el grafo (ver ejemplos de reglas en el Anexo 3).

```

Cypher_Retrieve_Prompt

1 <role>
2   Eres un desarrollador experto en Neo4j
3 </role>
4 <objective>
5   Tu tarea es convertir la consulta del usuario (<query>) según el esquema (<schema_KG>)
   en instrucciones Cypher validas. Considere las reglas (<rules>)
6 </objective>
7
8 <scenario>
9   <schema_KG>
10    {schema}
11  </schema_KG>
12
13  <query>
14    {question}
15  </query>
16
17  <rules>
18    {rules}
19  </rules>
20 </scenario>
21
22 <expected_solution>
23   - Tu respuesta debe ser solo respecto a la consulta Cypher.
24   - NO incluyas ninguna explicación, encabezado, o texto adicional.
25 </expected_solution>

```

Figura 3.5: Prompt para la recuperación de los datos.

3.2.2.3 Actualización del Grafo de Conocimiento

La actualización del grafo es realizada en el módulo de “Estimación de la satisfacción” en la capa de *Auto-evaluación*, para guardar la información que se le ha denominado SPUR-feedback, donde se agrupa el identificador de la interacción realizada, el nombre del usuario, el score sobre la estimación de satisfacción, tres características relevantes de la interacción, y el tópico que fue abordado. Una vez finalizada la evaluación, se almacena en el grafo el resultado para adaptar y mejorar las siguientes interacciones con el usuario. Este proceso es realizado de la misma manera que el paso de “almacenamiento de datos” reflejado en la Figura 3.2, con la diferencia que se actualiza el grafo de conocimiento en función de la información obtenida de las interacciones.

Por su parte, el prompt que se utiliza para actualizar la información del grafo es el mismo que el de la Figura 3.3, con la diferencia en los datos de entrada, tales como el *{query}* que especifica la información que debe ser guardada según el resultado del SPUR-feedback, y las *{rules}* que especifica cómo almacenarla (ver anexo 3). A continuación, se presenta un ejemplo de la información que puede almacenarse. Sus atributos incluyen el nombre del

usuario, la experiencia generada, el identificador de la sesión, el score de satisfacción y tres características detectadas en la sesión.

```
{
  "usuario": "José Castro",
  "experiencia": "exponentes y radicales",
  "sesion": "20251910_112536",
  "score": "66",
  "caracteristicas": "Progresión en el aprendizaje, Persistencia y actitud
positiva, Evidencia de Comprensión"
}
```

3.2.3 Validación manual

La capa de *Validación manual* consiste en verificar el funcionamiento de los componentes de la arquitectura MIHR de forma individual en diferentes casos (ej. en el aprendizaje de matemática y manejo del estrés). Para cada componente, se genera una instancia, se extraen un conjunto de pruebas del grafo del conocimiento, y se realiza la validación. Si un resultado es desfavorable, se realiza una revisión manual de la configuración del funcionamiento de la instancia (prompt) con el fin de mejorar el rendimiento de un componente antes de pasar a una interacción real.

3.2.3.1 Generación de una instancia

Este módulo consiste en generar una instancia de un componente del MIHR. La *instancia* se refiere a la configuración y despliegue de un componente. Existen dos tipos: la configuración basada en *Prompts*, donde se hace uso de un LLM para obtener comportamientos dinámicos; y la configuración basada en *Rules* cuyo comportamiento es fijo. En esta capa se generan los componentes que utilizan la configuración basada en Prompts con el fin de mitigar los errores que puede producir el LLM en sus respuestas.

En ese sentido, para cada componente se diseña un prompt (*Component Prompt*) donde se incluyen instrucciones específicas. Este prompt es cargado al momento de generar la instancia y es ejecutado cada vez que el componente se usa en una interacción. Como ejemplo, en la Figura 3.6 se observa la estructura del prompt del componente deliberativo que consiste en que el LLM actúe como un moderador cuya salida generada sea un estado nuevo de interacción dentro de la planificación; para ello se tienen instrucciones fijas y datos de entrada como: *{objective}* para considerar en la planificación el objetivo de interacción (ver detalles sección 3.1.1); *{current_user_message}* y *{current_robot_message}* para conocer las

últimas respuestas de la conversación; y *{current_state}* para saber el estado en que se encuentra actualmente. En el Anexo 1 se añaden los prompts del funcionamiento de los demás componentes.

```

Deliverative_Prompt

1 <role>
2     Actua como moderador en una interacción estudiante-robot dentro del caso de
   estudio (<case_study>)
3 </role>
4
5 <objective>
6     Dirige la conversación estudiante-robot de acuerdo a la planificación de la
   sesión (<planning>) considerando el paso actual de la interacción (<state>), el último
   mensaje del robot (<robot_message>) y la respuesta actual del estudiante
   (<user_message>).
7 </objective>
8
9 <scenario>
10
11     <case_study>
12         {objective}
13     </case_study>
14
15     <planning>
16
17         1. Saludo: El robot inicia la interacción con un saludo.
18         2. Vínculo: El robot establece un vínculo a través de una pregunta
   implícita con el caso de estudio.
19         3. Objetivo: El robot explica el objetivo de la sesión según el caso de
   estudio.
20         4. Exploración: El robot realiza una actividad breve exploratoria
   (consta solamente de 1 ejercicio) según el caso de estudio. Dentro de este paso puede
   requerir explicaciones, retroalimentación, confirmación de respuesta.
21         5. Aprendizaje: El robot realiza una actividad breve de aprendizaje que
   se adapta a los resultados de la exploración (consta solamente de 1 ejercicio). Dentro
   de este paso puede requerir explicaciones, retroalimentación, confirmación de respuesta.
22         6. Cierre: El robot finaliza la sesión con una despedida personalizada.
23     </planning>
24
25     <user_message>
26         {current_user_message}
27     </user_message>
28
29     <state>
30         {current_state}
31     </state>
32
33     <robot_message>
34         {current_robot_message}
35     </robot_message>
36
37 </scenario>
38
39 <expected_solution>
40     Su salida debe ser **unicamente** en formato JSON:
41     "estado": "indique el estado de la interacción", "acción": "indique breve y
   directo la siguiente acción que se debe tomar para avanzar en la conversación. No es la
   respuesta final al estudiante"
42
43     Reglas:
44     - Las acciones del moderador representan la dirección que debe tener la
   conversación
45     - Si el estado actual se ha completado, pasa al siguiente estado indicando la
   acción correspondiente.
46     - Si el estado actual no se ha completado, indica la acción necesaria para
   continuar en el mismo estado.
47     - Si el estudiante planea irse o despedirse, entonces pasa directo al paso de
   Cierre.
48 </expected_solution>

```

Figura 3.6: Prompt del funcionamiento del componente deliberativo.

3.2.3.2 Extracción de Pruebas

La tarea de este módulo es extraer las pruebas para la validación del funcionamiento de un componente en específico. El conjunto de pruebas es almacenado en el grafo de conocimiento (ver detalles en la sección 3.1.2). En este proceso, tal como se muestra en la Figura 3.4, se define un prompt para recuperar los datos asociados a las pruebas usando el LLM, se generan las instrucciones necesarias en el lenguaje de consulta Cypher, y se ejecutan seguidamente sobre el grafo de conocimiento obteniendo la información requerida. Para esta parte, el resultado está compuesto como un conjunto de ejemplos, cada uno compuesto por tuplas de la forma: <entrada, salida, score>. La entrada corresponde a los parámetros que se proporcionan a una instancia para su ejecución. La salida es la respuesta generada por dicha instancia. El score es un valor numérico que cuantifica la coherencia entre la entrada y la salida esperada, indicando si el resultado es correcto o incorrecto. Para generar el conjunto de pruebas, se emplearon ejemplos producidos por un LLM, incluyendo casos con salidas tanto correctas como incorrectas. En el Anexo 2 se presentan algunos casos de los ejemplos generados por componente.

3.2.3.3 Validación del funcionamiento

En la validación del funcionamiento para una instancia, se realiza el proceso que se ve en la Figura 3.7, el cual usa las dos salidas de los módulos anteriores (la instancia del componente y el conjunto de pruebas). Este módulo consiste en sacar un ejemplo del conjunto extraído para que la instancia use la entrada y se ejecute el caso a evaluar; luego, la salida generada se integra en el prompt de evaluación, acompañada del conjunto total de ejemplos; y empleando el LLM para su evaluación.




Figura 3.7: Diagrama para validar el funcionamiento de una instancia.

El enfoque de evaluación está basado en la teoría descrita por [91], en la que se aplica LLM como un juez usando el método de Aprendizaje del Contexto (*In-Context Learning*), que consiste en proporcionar instrucciones con criterios y ejemplos para guiar el razonamiento y el juicio del modelo. Este enfoque implica dos aspectos clave: el diseño de la entrada y el diseño de las indicaciones. En el diseño de la entrada, se consideran el tipo de variables que se evaluarán (ej. texto o imagen), la forma de entrada (ej. individual, en pares o en lotes) y su ubicación (al principio, en el medio o al final); y para el diseño de las indicaciones, se adoptan las puntuaciones para representar la evaluación mediante un *score* correspondiente, y que se consideren las explicaciones para la mejora de racionalidad e interpretabilidad del score.

En ese sentido, el proceso de validación de cada instancia se articula en torno al diseño del prompt (*Evaluator Prompt*), como se ilustra en la Figura 3.8. Este prompt está construido para que un LLM infiera una respuesta dado un caso de prueba y considerando los ejemplos de referencia que permitan generar una puntuación y explicación que se ha denominado ICL-score. Existen instrucciones fijas, y datos de entrada: *{description}* que contiene una descripción sobre la tarea que realiza el componente en una interacción, *{examples}* que proporciona el conjunto de ejemplos extraído, y *{case_to_evaluated}* que contiene el caso a evaluar. La puntuación de una evaluación se emite en una escala de *Likert* de 0 a 3, la cual se correlaciona directamente con criterios adaptados de la rúbrica de [91].

```

Evaluator_Prompt

1 <role>
2   Actua como un juez experto y completamente objetivo
3 </role>
4
5 <objective>
6   Tu tarea es evaluar un caso de prueba (<evaluate_case>) de un componente de un
   robot. Para ello se requiere calificar con score de correctitud y su justificación.
   Entonces, en el proceso considere las entradas entradas y salida. Use como guía los
   ejemplos de referencia (<example_cases>) que tienen salidas correctas e incorrectas, y
   para la justificación use la información del componente (<component>) y la escala de
   evaluación (<scale>) para establecer una relación
7 </objective>
8
9 <scenario>
10
11   <component>
12     {description}
13   </component>
14
15   <example_cases>
16     {examples}
17   </example_cases>
18
19   <evaluate_case>
20     {case_to_evaluated}
21   </evaluate_case>
22
23   <scale>
24     El score debe ser un número entero estricto entre 0 y 3.
25     0: La salida es completamente irrelevante o incorrecta y no tiene relación con
       las entradas e información del componente
26     1: La salida muestra evidencia minima en correctitud en base a las entradas e
       información del componente
27     2: La salida es parcialmente correcta en relación a las entradas e información
       del componente
28     3: La salida es correcta y tiene coherencia en relación a las entradas e
       información del componente
29   </scale>
30 </scenario>
31
32 <expected_solution>
33   Su salida debe ser Exclusivamente en formato JSON:
34   "explicación":"justifique sus razones de la calificación", "score":"indique el
       valor"
35
36   Reglas:
37   - La justificación debe ser clara y muy breve
38   - Para la justificación considere la información del componente y la escala de
       evaluación. Además, usa los ejemplos como guía de lo que debes hacer.
39 </expected_solution>

```

Figura 3.8: Prompt para validar el funcionamiento de una instancia.

El proceso de este módulo se repite según el número de pruebas N , por cada instancia (es decir, se toma cada ejemplo del conjunto). Esto permite percibir mejor las respuestas del modelo en la validación. Una vez completadas las iteraciones, se calcula el ICL-score final, el cual corresponde al promedio de todos los ICL-score individuales (S_i) obtenidos para la instancia:

$$ICL_score_{Final} = \frac{1}{N} \sum_{i=1}^N S_i$$

Este ICL-score final es el que determina el resultado de la validación con dos posibilidades fijadas: si el promedio final refleja una tasa de éxito igual o superior al 75%, la instancia queda validada. Por el contrario, si la tasa de éxito resulta desfavorable, situándose por debajo del 75%, se procede a una revisión manual del Prompt para realizar las modificaciones, y luego la instancia debe ser nuevamente ejecutada en el proceso de validación con la configuración actualizada.

3.2.4 Auto-configuración

En la capa de *Auto-configuración* se realiza la configuración del funcionamiento para cada uno de los componentes del MIHR que puede ser basado en Prompts o en Reglas. Se tienen como entradas principales el objetivo de interacción, que define lo que se busca cubrir; y el grafo del conocimiento, que proporciona un contexto sobre el caso de estudio e información relacionada con el usuario.

3.2.4.1 Modos de configuración

La configuración basada en Prompts (*Component Prompt*), como ya se había mencionado, permite que el comportamiento de un componente durante una interacción sea variable. Por eso, se realiza una validación previa en diferentes escenarios con el fin de reducir los errores que puede dar el LLM. Cada prompt validado se almacena en un directorio y al momento de ser usado se carga dentro de la instancia del componente. Un ejemplo fue el señalado en la sección 3.1.3.1 para el componente deliberativo. Además, para esta configuración se incluyen los componentes normativo, afectivo, verbal, y reconocimiento (imagen).

Por otro lado, la configuración basada en Reglas (*Component Rules*) se enfoca en que el comportamiento de un componente esté estrictamente relacionado con sus entradas y salidas. Para esto, se realiza un diseño cuyo funcionamiento puede definirse claramente a través de un conjunto de condiciones y acciones lógicas. Los componentes que operan bajo este diseño son: automático, no verbal, paraverbal, y adaptativo. En esta configuración, se establece una relación directa entre una condición y una salida, como por ejemplo, para el componente automático, la condición podría ser la detección de una emoción específica del

usuario junto con la posición de su cuerpo; esto genera como salida una respuesta rápida del robot, como reflejar una emoción similar y ajustar la posición de su cuello.

```
{  
  "condicion": "(feliz | sorpresa) & izquierda",  
  "emocion_salida": "feliz", "posicion_salida": "izquierda"  
},  
{  
  "condicion": "(triste | ira | miedo) & derecha",  
  "emocion_salida": "triste", "posicion_salida": "derecha"  
},
```

3.2.4.2 Generación de la configuración

El flujo de la capa de Auto-configuración inicia con dos entradas: el objetivo de interacción y el grafo de conocimiento; las cuales son utilizadas por algunos componentes del MIHR. El objetivo de interacción es fundamental para el componente normativo (ayudando a establecer el género del usuario y el perfil social del robot) y para el deliberativo (ajustando la planificación de la interacción).

Por su parte, tanto el objetivo de interacción como el grafo de conocimiento son esenciales para el componente adaptativo, ya que este último utiliza el objetivo de interacción para acceder al grafo y recuperar datos contextuales específicos (según el caso de estudio y el usuario). El proceso para obtener estos datos se explica en la sección 3.1.2.2, que en resumen: se especifica en el prompt de la consulta a realizar, se ejecuta el LLM que genera el cypher query, y se obtienen los datos del grafo (*Context Data*).

Ahora bien, dentro de la generación de la configuración, existe un módulo interno que permite generar una instancia funcional de un componente, como se aprecia en la Figura 3.9. El procedimiento consiste en seleccionar la configuración dependiendo del componente: *Component Rules* o *Component Prompt*, y cargarla al momento de generar la instancia. Una vez realizada la configuración del MIHR se procede a la siguiente capa.




Figura 3.9: Diagrama del proceso para la generación de la configuración.

3.2.4.3 Organización de elementos de la Arquitectura de Integración

Es importante mencionar que los distintos elementos dentro de la Arquitectura de Integración se organizan según el funcionamiento de ROS2, usando el patrón de comunicación publicador/suscriptor. Este patrón permite que nodos independientes se comuniquen entre sí de manera asíncrona y desacoplada, facilitando la escalabilidad y flexibilidad del código. Dentro del contexto del publicador/suscriptor, cada componente funcional se encapsula en un nodo, que es un proceso ejecutable para realizar una tarea específica, como controlar un motor o procesar datos de un sensor. La comunicación entre estos nodos se lleva a cabo a través de tópicos. Un tópico es un canal de comunicación con un nombre único, sobre el cual los nodos pueden enviar (publicar) o recibir (suscribir) mensajes.

Entonces, el funcionamiento contiene los nodos de las instancias para los componentes del MIHR, donde se suscriben a los tópicos necesarios y publican sus resultados (tanto para la validación manual como para la autoconfiguración), y en la capa de evaluación se incluye un nodo que se ejecuta para estimar la satisfacción del estudiante.

3.2.5 Ejecución

La capa de Ejecución arranca cuando todas las instancias están configuradas. El procedimiento consiste en una interacción real donde un estudiante interactúa con el MIHR a través de un robot social, cuya conversación es registrada para la siguiente capa. Entonces, es necesario especificar el Robot Social usado y cómo se comunican los componentes del MIHR.

3.2.5.1 Robot Social LRS2

El robot utilizado en este Proyecto de Grado se denomina LRS2 (*LaSDAI Robot Social 2*), y es una versión mejorada del LRS1 propuesto en [92], cuyo diseño consiste en el uso mínimo de los recursos para la implementación de diferentes casos de estudio de interacción humano-robot. El LRS2 está orientado al uso en contextos educativos, tiene un diseño minimalista, como se observa Figura 3.10, en el que puede expresar tres emociones faciales: feliz, triste, y neutral, y también puede rotar su cuello en dos ejes (vertical y horizontal). Los canales de percepción usados son la cámara y micrófono, y los canales de actuación son a través de las señales verbales (altavoces) y las no verbales (rostro y posición del cuello). La forma de comunicación es verbal, por lo que tiene incorporado un led RGB que indica tres posibles estados (*rojo*: hablando, *amarillo*: procesando la información, *verde*: escuchando).



Figura 3.10: Foto frontal del LRS2.

3.2.5.2 Comunicación de los componentes del MIHR

El LRS2 implementa el MIHR adoptando el marco de trabajo de ROS2 para la comunicación con el patrón publicador/suscriptor. Dentro del MIHR, cada componente funciona como un nodo independiente, capaz de enviar (publicar) o recibir (suscribir) mensajes. Un único mensaje publicado puede ser recibido por múltiples suscriptores interesados en el mismo tópico. La Figura 3.11 ilustra cómo se interconectan los componentes del MIHR que son utilizados por el LRS2, mostrando el proceso y acciones para la interacción con el estudiante.




Figura 3.11: Comunicación de los componentes del MIHR

El flujo de comunicación en el robot comienza en el nivel externo del robot con el nodo de **percepción**. Este nodo activa la captura de audio para la comunicación con el usuario y toma una imagen del mismo (utilizando la biblioteca *CV2* de Python para procesamiento de imágenes). La información capturada pasa al nivel interno, donde es procesada por el componente de **reconocimiento**. Para el procesamiento del audio, se emplea el modelo portable *VOSK*, que ofrece una transcripción a texto adecuada para el vocabulario en español. Posteriormente, los datos se dirigen a los siguientes componentes para generar una respuesta: el componente **automático** se encarga de proporcionar respuestas rápidas; y para respuestas más elaboradas, se utilizan los componentes **normativo**, **deliberativo**, **adaptativo**, **afectivo**,

no verbal, **verbal**, y **paraverbal**. Finalmente, el componente de **actuación** ejecuta la respuesta generada. Como consideración en la implementación de la arquitectura MIHR se incluye el nodo **registro**. Este nodo es crucial y permite guardar de forma iterativa el historial de la conversación, ya que algunos componentes basan sus acciones en el contexto de la interacción en curso.

A continuación, en la Tabla 3.4, se muestran detalles del funcionamiento de cada componente, tales como su tarea, y las etiquetas a los tópicos que publica/suscribe.

Componente	Tarea	Publicador	Suscriptor
Percepción	Capturar imagen	Entrada_Img	Estado_Robot
	Activar recepción de audio y captura de imagen	Estado_Robot	Respuesta_Robot
Reconocimiento	Reconocer la emoción y posición del usuario	Emocion_Usuario, Posición_Usuario	Entrada_Img
	Procesar el audio y convertirlo a texto	Respuesta_Usuario	Estado_Robot
Normativo	Proveer perfil social del robot e identificar el género del usuario	Perfil_Robot, Género_Usuario	-
Automático	Proporcionar la expresión no verbal según el usuario	Emoción_Robot, Posición_Robot	Emocion_Usuario, Posición_Usuario
Deliberativo	Actualizar el estado de la interacción	Estado_Interacción	Respuesta_Usuario, Historial
Adaptativo	Facilitar la información según el caso de estudio y el usuario	Personalización	Estado_Interacción
Afectivo	Generar la emoción del robot según el perfil del robot y emoción del usuario	Emoción_Robot	Emoción_Usuario Perfil_Robot
Verbal	Construir respuesta textual coherente	Salida_Textual	Perfil_Usuario, Género_Usuario, Estado_Interacción, Historial, Personalización
Paraverbal	Configurar los parámetros de voz para la respuesta verbal	Voz_Robot	Perfil_Robot, Emoción_Robot
No verbal	Ajustar la posición del cuello con base en la emoción del componente afectivo, o modificar la emoción según palabras clave presentes en la respuesta verbal.	Expresión_Robot	Emoción_Robot Salida_Textual
Actuación	Ejecutar movimientos y expresiones del robot	-	Expresión_Robot, Emoción_Robot
	Ejecutar la respuesta verbal del robot	-	Salida_textual Voz_Robot
Registro	Guardar la conversación de forma interactiva	Historial	Respuesta_Usuario, Salida_Textual

Tabla 3.4: Funcionamiento de los componentes del MIHR

3.2.6 Auto-Evaluación

La capa de Auto-Evaluación se basa en el análisis de una interacción realizada por el estudiante y el robot. A partir del registro de la interacción, se utiliza el módulo de Estimación de la Satisfacción para generar el SPUR-feedback, compuesto principalmente por una puntuación de la estimación y características importantes de la sesión.

3.2.6.1 Módulo de Estimación de la Satisfacción

El método usado se basa en el SPUR (Supervised Prompting for User satisfaction Rubrics), cuyo objetivo es lograr una estimación interpretable de la satisfacción del usuario en sistemas conversacionales [93]. SPUR se compone de tres partes principales, tal como se muestra en la Figura 3.12: Extracción Supervisada (Supervised extraction), Resumen de Rúbricas (Rubric summarization), y Estimación de Satisfacción del Usuario (User satisfaction).




Figura 3.12: Diagrama del proceso de estimación de la satisfacción

La primera parte es la Extracción Supervisada (*Supervised Extraction*), donde a partir de un conjunto de conversaciones etiquetadas con señales explícitas de satisfacción o insatisfacción se incluyen en un prompt, y se utiliza un modelo LLM para identificar y extraer patrones lingüísticos que expresen explícitamente o implícitamente satisfacción (SAT) o insatisfacción (DSAT) por parte del usuario. Esta extracción se realiza de manera estructurada e iterativa según el número de conversaciones etiquetadas, permitiendo obtener

hasta cinco patrones por conversación. Para este trabajo, dichas conversaciones etiquetadas se generaron de manera simulada por un LLM, y se validaron de forma manual para obtener un total de 20 conversaciones. Estas conversaciones son almacenadas en un directorio para su uso. Respecto al prompt que se usa en esta parte, se puede ver en la Figura 3.13, donde se especifican instrucciones de lo que se debe hacer, y *{conversation}* que representa la conversación a la cual se le extraerán los patrones.

```
Supervised_Extraction_Prompt

1 <objective>
2 Tu trabajo es comprender y detallar cómo un usuario expresa que está
  satisfecho/insatisfecho con su interacción. Se te proporcionará una conversación
  (<input>) que un usuario tuvo con un robot y tienes que resumir cómo el usuario expresó
  satisfecho/insatisfecho en la conversación.
3 </objective>
4
5 <scenario>
6 <input>
7 {conversation}
8 </input>
9 </scenario>
10
11 <expected_solution>
12 Tu respuesta debe seguir el siguiente formato JSON:
13
14   "patrones": {
15     "p1": "...",
16     ...
17   }
18
19 </expected_solution>
20
21 <steps>
22 - Analiza únicamente el contenido de las conversaciones (<input>).
23 - Extrae un máximo de cinco patrones distintos que expliquen por qué el usuario estuvo
  satisfecho/insatisfecho. Las razones deben basarse únicamente en la conversación. No
  debes extrapolar, imaginar o alucinar más allá del texto de la conversación que se te
  proporciona.
24 - Considere que si no puedes encontrar ningún patrón claro, responde con: none.
25 - Las razones deben ser mutuamente excluyentes.
26 - No repitas frases literales de la conversación; enfócate en la intención subyacente.
27 - Devuelve la salida en el formato indicado (<expected_solution>)
28 </steps>
```

Figura 3.13: Prompt para extracción de patrones

La segunda parte es el Resumen de Rúbricas (*Rubric summarization*), donde los patrones extraídos *{patterns}* se ingresan en un prompt (ver Figura 3.14) y por medio del LLM se genera como resultado una rúbrica interpretable, compuesta por un conjunto de ítems (para este caso, diez para satisfacción y diez para insatisfacción). Es importante mencionar que las dos primeras partes del módulo son realizadas una sola vez (preproceso) para cada caso de estudio de este proyecto, es decir, una para el contexto del aprendizaje de la matemática y otra para el manejo del estrés.

```

Rubric_summarization_Prompt

1 <objective>
2 Tu tarea es analizar el conjunto de patrones (<input>) sobre cómo los usuarios expresan
  satisfacción/insatisfacción en sus interacciones con un robot, y generar una rúbrica
  general que permita evaluar nuevas conversaciones de forma interpretable.
3 </objective>
4
5 <scenario>
6   <input>
7     {patterns}
8   </input>
9 </scenario>
10
11 <expected_solution>
12 Tu respuesta debe seguir el siguiente formato JSON:
13
14   "rubrica": {
15     "satisfaccion": [
16       {
17         "nombre": " ... ",
18         "descripcion": " ... "
19       },
20       ...
21     ],
22     "insatisfaccion": [
23       {
24         "nombre": " ... ",
25         "descripcion": " ... "
26       },
27       ...
28     ],
29   }
30
31 </expected_solution>
32
33 <steps>
34 - Analiza el conjunto de patrones (<input>)
35 - Genera una lista de criterios generales y representativos (rúbrica) que se puedan
  aplicar para identificar satisfacción (SAT) o insatisfacción (DSAT) en conversaciones
  futuras.
36 - Construye la rúbrica en un conjunto de ítems mutuamente excluyentes y centrados en el
  comportamiento o actitud del usuario.
37 - La rúbrica debe tener 10 ítems para el SAT y DSAT.
38 - Cada ítem debe estar redactado de forma clara, concisa y sin repetir conceptos.
39 - Devuelve la lista completa en el formato indicado (<expected_solution>)
40 </steps>

```

Figura 3.14: Prompt para la generación de rúbricas

La tercera parte es la Estimación de Satisfacción del Usuario, donde se usa la rúbrica generada según el contexto y permite evaluar el registro de una interacción. Las especificaciones del prompt (*User-Satisfaction*) se observan en la Figura 3.15, donde el LLM analiza si cada ítem de la rúbrica SAT/DSAT en la etiqueta *{rubric}* está presente en la conversación a evaluar en la etiqueta *{conversation}*. De esta forma, se asigna un score en la escala del 1 al 10 para cada ítem detectado; es decir, si un ítem se refleja fuertemente en la conversación el modelo asigna un valor alto, y para el caso contrario un valor bajo. A partir de estos scores por cada ítem, se calcula un único *score final* de satisfacción, lo que permite clasificar la conversación.

Adicionalmente, para esta parte, el prompt se ajusta para que, junto con el score final, se genere un conjunto de características relevantes asociadas. De esta manera, el resultado del módulo se denomina SPUR-feedback, compuesto por el nombre del usuario, el tópico abordado, el identificador de la sesión, el score de satisfacción, y tres características relevantes de la conversación. Este resultado actualiza el grafo de conocimiento, como se describe en la sección 3.2.2.3 para mejorar las siguientes interacciones.

```

1 <objective>
2 Tu tarea es analizar una conversación (<conversation>) entre un estudiante y un robot
  utilizando la rúbrica predefinida (<rubric>) para calcular un score global de
  satisfacción, identificar características relevantes de la conversación, y conocer el
  tópico en el que se desarrolla.
3 </objective>
4
5 <scenario>
6   <conversation>
7     {conversation}
8   </conversation>
9
10  <rubric>
11    {rubric}
12  </rubric>
13 </scenario>
14
15 <expected_solution>
16 Tu respuesta debe seguir el formato JSON usando la siguiente estructura:
17
18   "Calificacion_por_item": {
19     "satisfaccion": [
20       {
21         "nombre": " ... ",
22         "score": 0
23       }, ...
24     ],
25     "insatisfaccion": [
26       {
27         "nombre": " ... ",
28         "score": 0
29       }, ...
30     ],
31   },
32   "SPUR_feedback": {
33     "usuario": name
34     "experiencia": " ... ",
35     "sesion": " ... ",
36     "score": " ... ",
37     "caracteristicas": " ... , ... , ... ",
38   }
39 </expected_solution>
40
41 <steps>
42   - Analiza la conversación completa (<conversation>)
43   - Verifique si cada ítem de satisfacción o insatisfacción de la rúbrica (<rubric>)
    está presente en la conversación.
44   - Si el ítem está presente, asigna un puntaje entre 1 y 10 que indique su impacto
    (10 = muy evidente).
45   - Si el ítem no está presente, asigne un puntaje de 0.
46   - Calcula el score final de satisfacción sumando todos los puntajes de ítems de
    satisfacción y restandole la suma de todos los ítems de insatisfacción.
47   - Formula: score = suma(satisfacción) - suma(insatisfacción)
48   - Identifica 3 características relevantes del usuario y del diálogo que justifiquen
    tu evaluación.
49   - Extrae el nombre del tópico en el que se desarrolla la conversación
50   - Devuelve el score por cada ítem y luego la experiencia (tópico de la interacción
    en letras minúsculas), sesion (nombre de la sesion), score ( puntuación final),
    características (3 características relevantes). Sigue el formato indicado
    (<expected_solution>)
51 </steps>

```

Figura 3.15: Prompt para estimar la satisfacción del estudiante

Capítulo IV. Resultados

Este capítulo presenta el diseño experimental para la evaluación del MIHR a través de la satisfacción del usuario (sección 4.1), así como en análisis de los resultados obtenidos (sección 4.2).

4.1 Diseño del experimento

Dado que el modelo interno del robot en el MIHR (Modelo de Interacción Humano-Robot) está basado en tres premisas que se reflejan en sus tres componentes principales (normativo, adaptativo, y afectivo), el objetivo del experimento para este Proyecto de Grado es evaluar el impacto de esos tres componentes en la satisfacción del usuario. Para ello, se realizará un estudio de *ablación* que consiste en quitar componentes de la arquitectura para analizar su rendimiento a través de interacciones reales entre un robot social (para este caso el LRS2, ver sección 3.1.5.1) y tres participantes, en dos casos de estudio.

4.1.1 Participantes

El estudio se realizará con tres estudiantes universitarios de la carrera Ingeniería de Sistemas de la Universidad de Los Andes, Núcleo Mérida. Se opta por un muestreo no probabilístico por conveniencia debido a la naturaleza exploratoria y a las limitaciones de disponibilidad de los estudiantes. Además, los participantes serán informados del experimento para obtener su consentimiento antes de iniciar la interacción (ver anexo 5).

En cuanto al perfil de los estudiantes seleccionados, se resaltan algunos aspectos que podrían ser relevantes en su experiencia para este estudio: el *estudiante 1* es maculino y está cursando el décimo semestre; el *estudiante 2* es femenino y se encuentra cursando el tercer semestre; y el *estudiante 3* es maculino y cursa el octavo semestre. En relación a los casos de estudio, los estudiantes están familiarizados con los temas de matemáticas que se abordan dado que se ven en los primeros semestres, a diferencia del caso de manejo del estrés donde no están muy familiarizados con las diferentes técnicas.

4.1.2 Configuraciones del estudio

Se definieron cuatro configuraciones para las interacciones:

- *Configuración 1 (base)*. El MIHR opera con todos los componentes. Esta configuración representa el flujo natural de la arquitectura.

- *Configuración 2 (sin componente normativo)*. Se desactiva el componente normativo. Esto permite analizar el rendimiento del modelo sin la capacidad de adoptar un perfil según el contexto o identificar el género del usuario al que se dirige en la conversación.
- *Configuración 3 (sin componente adaptativo)*. Se desactiva el componente adaptativo. Esta configuración permite observar cómo la interacción se ve afectada al no considerar el feedback del usuario o el nivel de dificultad previo.
- *Configuración 4 (sin componente afectivo)*. Se desactiva el componente afectivo. Esta configuración permite evaluar la ausencia del análisis de emociones en la interacción, la cual puede influir en las respuestas.

4.1.3 Casos de estudio

Se seleccionó un objetivo de interacción para cada caso de estudio. El primero, es un tema muy importante dentro de los fundamentos del álgebra que incluye varias propiedades (objetivo a) y el segundo es un mecanismo importante que puede ayudar en el alivio del estrés académico (objetivo b).

- a. El/La estudiante <USUARIO> necesita practicar exponentes y radicales
- b. El/La estudiante <USUARIO> requiere explorar las técnicas de respiración

4.1.4 Métrica

Se seleccionó la métrica *SPUR* porque mide el nivel de satisfacción del usuario basado en LLM para analizar las conversaciones y generar un valor de satisfacción [93]. El método fue detallado en la sección 3.2.6 y en general consiste en tomar el registro de la conversación para el análisis, y mediante sus pasos de extracción de patrones, generación de rúbricas, y estimación de la satisfacción, generar un resultado interpretable en un rango de puntuación 0-100. Las rúbricas que han sido generadas para este experimento se pueden observar en el anexo 4, donde para cada caso de estudio se tienen 10 ítems tanto de satisfacción como insatisfacción. Estas rúbricas serán usadas al finalizar cada sesión para evaluar la interacción.

4.1.5 Procedimiento

Se llevarán a cabo un total de 40 sesiones por estudiante, distribuidas equitativamente con 20 sesiones para cada caso de estudio. Cada sesión representa una interacción entre el estudiante y el robot, con el propósito de cubrir un objetivo específico. La elección del número de sesiones se fundamenta en la revisión sistemática sobre interacciones a largo plazo

con robots sociales realizada por [94], en la cual se resalta que un número mínimo de sesiones debe ser superior a tres para que una experiencia pueda ser considerada de largo plazo, y no necesariamente implica muchas semanas, lo importante es la repetición y continuidad. Por tanto, este número seleccionado tiene como objetivo realizar un seguimiento intensivo con pocos estudiantes, pero que ayude a observar una evolución de la interacción en el tiempo en cuanto al nivel de satisfacción, y permita comparar la diferencia en el uso de las configuraciones. Cada sesión experimental se llevará a cabo en un entorno controlado para minimizar distracciones y asegurar la consistencia. Se realizarán 5 sesiones durante un día por cada estudiante y para cada configuración (según el caso de estudio), lo cual implica un periodo de 8 días para completar el experimento. El procedimiento de cada sesión es el siguiente:

- Preparación de la interacción: el estudiante se sentará frente al robot LRS2, equipado con un micrófono inalámbrico. El experimentador usará una computadora para monitorear la interacción en tiempo real (ver Figura 4.1). Cada estudiante interactúa de forma individual con el robot durante una sesión de aproximadamente 10 minutos para evitar la fatiga del participante.




Figura 4.1: Configuración del entorno para la sesión

La diferencia entre las sesiones se diseña para que cada día se use un solo caso de estudio y una configuración para el robot. En la Tabla 3.5, se resume la planificación que debe completar un estudiante.

Día	Planificación para un estudiante
1	Realiza cinco sesiones con el caso de estudio (objetivo a) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 1 (Todos los componentes base).
2	Realiza cinco sesiones con el caso de estudio (objetivo b) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 1 (Todos los componentes base).
3	Realiza cinco sesiones con el caso de estudio (objetivo a) con un periodo de descanso de 10

	minutos entre sesiones. El robot usará la configuración 3 (sin componente adaptativo)
4	Realiza cinco sesiones con el caso de estudio (objetivo b) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 3 (sin componente adaptativo)
5	Realiza cinco sesiones con el caso de estudio (objetivo a) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 2 (sin componente normativo).
6	Realiza cinco sesiones con el caso de estudio (objetivo b) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 2 (sin componente normativo).
7	Realiza cinco sesiones con el caso de estudio (objetivo a) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 4 (sin componente afectivo).
8	Realiza cinco sesiones con el caso de estudio (objetivo b) con un periodo de descanso de 10 minutos entre sesiones. El robot usará la configuración 4 (sin componente afectivo).

Tabla 4.1: Planificación a seguir por un estudiante

- Ejecución de la interacción: la sesión tiene una planificación inicial (se toma como referencia la planificación realizada por [32]) en la que el robot lleva a cabo la interacción, pero no es una limitante para que el estudiante interactúe de forma natural.
 1. Saludo: el robot inicia la interacción.
 2. Vínculo: el robot realiza un comentario/pregunta sobre la experiencia previa del usuario dentro del caso de estudio.
 3. Objetivo: el robot explica el objetivo de la sesión.
 4. Exploración: el robot realiza una actividad exploratoria (ejercicio/pregunta).
 5. Aprendizaje: el robot realiza una actividad de aprendizaje que se adapta a los resultados de la exploración (ejercicio/pregunta).
 6. Cierre: el robot finaliza la sesión con una despedida personalizada.
- Evaluación de la interacción: luego de una sesión, se usa el SPUR para obtener un feedback de satisfacción. En este paso se toma el registro de conversación y se usan las rúbricas. Mediante el LLM, se asigna una puntuación de relevancia de 0 a 10 a cada ítem SAT/DSAT cuantificando su impacto en la sesión. Posteriormente, la siguiente fórmula toma la suma de estas puntuaciones de relevancia y la transforma en un resultado final único (de 1 a 100). Es importante entender que la escala 0-10 mide el impacto individual de un ítem de la rúbrica en la conversación, mientras que el resultado 1-100 representa el índice de satisfacción consolidado de la interacción completa.

$$score_{final} = \sum_{i=1}^{10} item_SAT_i - \sum_{j=1}^{10} item_DSAT_j$$

- Comparación de resultados: Para el análisis de los resultados de las 120 sesiones, se utiliza por un lado la estadística descriptiva para observar el comportamiento general y la distribución de los datos en las configuraciones, y por otro lado, el modelo ANOVA (*Analysis Of Variance*) para determinar si existen diferencias estadísticamente significativas entre los grupos de resultado con medidas repetidas.

4.1.6 Modelo ANOVA con medidas repetidas

Como afirma [95], un diseño de medidas repetidas es aquel en el que se realizan mediciones múltiples en cada unidad experimental (sujetos) que podría ser por ejemplo una persona o un animal, donde se pueden tomar mediciones repetidas en serie en el tiempo, o medirse en diferentes condiciones experimentales. El autor menciona que la dependencia o correlación entre las respuestas medidas en el mismo individuo es la característica definitoria de un diseño de medidas repetidas. Esta correlación requiere un análisis estadístico que tenga en cuenta adecuadamente la dependencia entre mediciones dentro de la misma unidad experimental, lo que da como resultado un análisis estadístico más preciso y potente.

4.1.6.1 ANOVA de un factor con medidas repetidas

Dentro del ANOVA de medidas repetidas, existe un tipo de análisis de “un factor”, el cual es el que se usará para este trabajo porque se enfoca en comparar las medias de una variable dependiente cuantitativa a través de tres o más condiciones o momentos temporales, utilizando siempre al mismo grupo de sujetos. El uso de este análisis se centra en estudiar el efecto de una única variable independiente que presenta múltiples niveles, determinando si las diferencias observadas entre las mediciones son estadísticamente significativas. Para este trabajo es relevante este enfoque dado que se busca medir el nivel de satisfacción de los mismos usuarios pero usando cuatro configuraciones diferentes del MIHR. Se realizan tres análisis de un factor con medidas repetidas detallados en la sección 4.2. Cabe resaltar, como menciona [96], el uso del ANOVA de medidas repetidas debe considerar algunos supuestos estadísticos clave para determinar si se trata de un enfoque estadístico apropiado:

1. Normalidad: la distribución de los datos debe ser similar a la distribución normal. Para evaluar este supuesto se utiliza la prueba de *Shapiro-Wilk*.
2. Esfericidad: asume que las varianzas de las diferencias entre todos los pares de condiciones son iguales. Para evaluar este supuesto se usa la prueba de *Mauchly*.

4.1.7 Ejemplos de sesiones

Se realizaron 120 sesiones en total, divididas en 40 sesiones por cada estudiante. Los participantes interactuaron con el LRS2 de forma individual en un entorno controlado tal como se observa en la Figura 4.2. Durante una sesión de interacción, el robot llevó a cabo el plan establecido (saludo, vínculo, objetivo, exploración, aprendizaje, cierre). Sin embargo, el estudiante no tenía restricciones en sus respuestas, y podía preguntar cualquier duda o realizar algún comentario sobre cada respuesta que el robot le daba.



Figura 4.2: Interacción entre un estudiante y el robot LRS2.

Para especificar el flujo de una sesión se presentan dos ejemplos de conversaciones realizadas en el experimento por el *estudiante 1* usando la configuración base (todos los componentes del MIHR). El primer ejemplo cubre el objetivo (a) “El estudiante Carlos necesita practicar exponentes y radicales”. En la Tabla 4.2 se muestra la conversación y su relación dentro de la planificación establecida. Entre las características importantes se encuentran que el estudiante fue perseverante y receptivo, y hubo un andamiaje efectivo del robot.

Estado de interacción	Conversación
Saludo	'Robot: ¡Hola! ¿estamos listos?' 'Estudiante: Si estamos listos'
Vínculo	'Robot: ¡Fino, Carlos! Ya que estamos listos, cuéntame, ¿qué tal te ha ido con los exponentes y radicales? ¿Ya habías echado un ojo a eso antes?' 'Estudiante: sí ya lo había hecho antes pero me falta recordar un poco'
Objetivo	Robot: ¡Claro, Carlos! Entendido. Es normal que a veces se olviden algunos detalles. Precisamente, el objetivo de esta sesión es que podamos refrescar y consolidar tus conocimientos sobre exponentes y radicales, puliendo cualquier punto que necesites para que te sientas totalmente seguro. ¿Qué te parece?' 'Estudiante: me parece bien'
Exploración	'Robot: Dale, Carlos, ¡chévere! Ya que estamos en sintonía, vamos a arrancar. Para calentar motores y refrescar esas ideas, ¿me podrías decir en una expresión como 8 elevado a la 3, cómo se le llama al 8 y cómo se le llama al 3?' 'Estudiante: la base es ocho y el tres es el exponente' 'Robot: ¡Exacto, Carlos! Así mismo es. El 8 es la base y el 3 es el exponente. ¡Perfecto! Ya que la tienes clara con la identificación, vamos a subirle un poquito el nivel. Ahora, cuéntame, ¿cuál sería el resultado de 4 elevado a la 3 menos 4 elevado a la 2?' 'Estudiante: creo que cincuenta y dos por ahí no me acuerdo' 'Robot: ¡Epa, Carlos! Gracias por intentarlo, el cincuenta y dos está cerca, pero no es el resultado exacto, mi pana. ¿Qué te parece si lo revisamos con calma? Primero, calcula cuánto es 4 elevado a la 3 y después, cuánto es 4 elevado a la 2. Así, paso a paso, a ver si le damos el palo.' 'Estudiante: okay está bien'
Aprendizaje	'Robot: ¡Fino! Dale, entonces, para arrancar, cuéntame, ¿cuánto es 4 elevado a la 3?' 'Estudiante: sesenta' 'Robot: Carlos, por ahí vas, pero te enredaste un poquito. No te preocupes, vamos a resolverlo con calma. Primero, cuéntame, ¿cuánto es cuatro por cuatro solito?' 'Estudiante: es dieciseis' 'Robot: ¡Exacto, Carlos! Así mismo es, cuatro por cuatro es dieciséis. ¡Excelente! Ahora, para que saques el resultado completo de 4 elevado a la 3, ¿cuánto sería dieciséis por cuatro?' 'Estudiante: sesenta y cuatro' 'Robot: ¡Excelente, Carlos! Así mismo es, ¡sesenta y cuatro! Ya tienes la primera parte del ejercicio clara. Ahora que ya sabes que 4 elevado a la 3 es 64, cuéntame, ¿cuánto sería 4 elevado a la 2?' 'Estudiante: es dieciséis y el resultado completo es cuarenta y ocho'
Cierre	'Robot: ¡Fino, Carlos! si es así. Por hoy lo vamos a dejar hasta aquí. Ha sido un gusto acompañarte en esta sesión y espero que te haya servido para ir refrescando un poco esos conocimientos. ¡Nos vemos en la próxima, mi pana!'

Tabla 4.2: Ejemplo de conversación para el objetivo (a) con la configuración base.

Por otra parte, el segundo ejemplo cubre el objetivo (b) “El estudiante Carlos quiere explorar las técnicas de respiración”. En la tabla 4.3 se muestra la conversación y su relación dentro de la planificación establecida. Entre las características importantes se encuentran que el estudiante fue cooperativo y agradecido con respuestas rápidas.

Estado de interacción	Conversación
Saludo	'Robot: ¡Qué tal! ¿comenzamos la sesión?' 'Estudiante: dale vamos a darle'
Vínculo	'Robot: ¡Excelente! Para ir calentando motores, cuéntame un poquito, ¿has practicado alguna técnica de respiración antes o esto es todo nuevo para ti, vale?' 'Estudiante: es relativamente es nuevo para mí'
Objetivo	'Robot: Ah, chévere que ya tengas una base. Fíjate, el objetivo es que exploremos juntos técnicas de respiración para que consigas la que mejor te cuadre y veas cómo te pueden ayudar, pues.' 'Estudiante: okay está bien'
Exploración	'Robot: ¡Listo pues! Ya que estamos claros, probemos con esta sencillita: la respiración diafragmática. La idea es que te concentres en inhalar profundo, sintiendo cómo se te infla la barriga, y al exhalar, la desinfla lentamente. ¿Te parece si la intentamos un ratito juntos?' 'Estudiante: vamos a intentarlo pues' 'Robot: ¡Chévere! Ya que le vas a echar pichón. Primero, ponte cómodo, puedes sentarte o acostarte, lo que te funcione mejor. Coloca una mano en tu pecho y la otra justo encima del ombligo, en tu barriga. La idea es que al tomar aire, sientas cómo la mano de la barriga se eleva, y al soltarlo, baja. Intenta que la mano del pecho se quede lo más quieta posible, ¿vale? Vamos a probarlo unas cuantas veces, respira profundo y lento por la nariz.' 'Estudiante: ya terminé esto parece un ejercicio de canto'
Aprendizaje	'Robot: ¡Qué bueno que le echaste pichón! Ahora sí, cuéntame un poquito, ¿cómo te sentiste con este ejercicio? ¿Te pareció útil, raro, o qué tal fue esa experiencia para ti?' 'Estudiante: no me pareció raro me pareció más bien un ejercicio que se hace en las prácticas de canto y puede relajar' 'Robot: Ah, ya veo, te trajo ese recuerdo. Pero, más allá de eso, cuéntame: ¿sentiste algún cambio, por chiquito que fuera, mientras lo hacías o después de terminar?' 'Estudiante: por ahora no sentí un gran cambio, pero gracias creo que es por que estoy empezando'
Cierre	'Robot: Ah, entiendo, a veces pasa que al principio. Una técnica puede ser relevante luego de practicarla varias veces. Lo importante es que le echaste pichón y lo intentaste. Ya por hoy vamos a dejar la sesión hasta aquí, pero si en otro momento quieres seguir explorando más, me avisas. Hasta luego'

Tabla 4.3: Ejemplo de conversación para el objetivo (b) con la configuración base.

4.2 Análisis de los resultados

El análisis de los resultados se basa en los datos recopilados de las 120 sesiones de interacción realizadas por 3 estudiantes (ver Anexo 6). Se hacen 3 análisis:

1. Análisis para 4 grupos (configuraciones): consiste en evaluar la existencia de diferencias en el score SPUR al modificar la configuración del MIHR. Como hay 4 configuraciones (grupos), cada grupo está compuesto por 30 muestras.
2. Análisis para 8 grupos (configuraciones/casos de estudio): se centra en determinar si existe diferencia en el score SPUR al modificar la configuración en el MIHR según el caso de estudio. Como hay 4 configuraciones y 2 casos de estudio, cada grupo tiene 15 muestras que representan a un caso de estudio en una configuración específica.

3. Análisis para 12 grupos (configuraciones/estudiantes): tiene como objetivo verificar si hay diferencia en el score SPUR al modificar la configuración en el MIHR según el estudiante. Como hay 4 configuraciones y 3 estudiantes, cada grupo cuenta con 10 muestras que representan a un estudiante en una configuración específica.

Para cada análisis se aplica: (4.2.1) estadística descriptiva y (4.2.2) el análisis ANOVA de medidas repetidas

4.2.1 Análisis descriptivo

4.2.1.1 Análisis descriptivo para 4 grupos

En la Tabla 4.4 se observan las cuatro configuraciones (grupos) de ablación cuyos resultados muestran que las medias de "Sin Normativo", "Sin Adaptativo" y "Base" tienen un rango similar en comparación con la configuración "Sin Afectivo" que presenta el escenario con el promedio más bajo (37.53). El rango de variabilidad (diferencia entre mínimo y máximo) en los resultados es amplio, sin embargo la ausencia del componente afectivo refleja que puede obtener incluso un score de 0. Respecto a la mediana las configuraciones "Sin adaptativo" y "Sin normativo" tienen un valor central más alto (58.50), y con una desviación estándar menor (13.13 y 14.08) que las demás.

Grupo	Media	Mediana	Mínimo	Máximo	Desv. Estándar
Base	52.70	49.50	20.00	87.00	16.73
Sin adaptativo	54.83	58.50	15.00	74.00	13.13
Sin normativo	55.20	58.50	28.00	85.00	14.08
Sin afectivo	37.53	37.00	0.00	64.00	16.72

Tabla 4.4: Resumen descriptivo del score SPUR para el análisis de 4 grupos.

En la Figura 4.3 se ilustra la distribución de los score (SPUR) a través de las cuatro configuraciones experimentales, usando diagramas de caja y de enjambre. El análisis visual confirma que las configuraciones "Sin Normativo" y "Sin Adaptativo" mantienen las medianas altas y una consistencia estable (menor dispersión). Sin embargo, en la configuración "Sin Adaptativo" aunque hay una alta consistencia evidenciada por la caja compacta donde se agrupan 26 de los 30 puntos (aprox. 86.7% de la muestra), el diagrama revela 4 valores atípicos (13.3%) en el rango inferior que se desvían claramente de esta tendencia grupal predominante. Por otro lado, la configuración "Sin Afectivo" presenta no solo una menor mediana y mayor variabilidad global, sino que incluye los valores mínimos

del experimento (cercanos a 0). Esto refleja gráficamente que la ausencia del módulo emocional es el factor que afecta la satisfacción en comparación a los componentes adaptativo y normativo, cuyo impacto es menos pronunciado o estadísticamente similar a la configuración base.




Figura 4.3: Distribución del score (SPUR) por configuración.

4.2.1.2 Análisis descriptivo para 8 grupos

El análisis comparativo de la Tabla 4.5, revela que la configuración "Sin adaptativo (matemáticas)" logra un promedio alto de satisfacción (59.53) con la mayor consistencia y estabilidad de los grupos (desv. estándar de 8.28). En contraste, la configuración "Sin afectivo" es consistente en que su comportamiento es más deficiente, tal como indica el promedio general de satisfacción para el caso de matemáticas (31.47) y manejo de estrés (43.60).

Grupo	Media	Mediana	Mínimo	Máximo	Desv. Estándar
Base (matemáticas)	48.73	49.0	20.0	87.0	17.07
Sin adaptativo (matemáticas)	59.53	59.0	45.0	74.0	8.28
Sin normativo (matemáticas)	50.27	50.0	34.0	69.0	11.19
Sin afectivo (matemáticas)	31.47	36.0	0.0	55.0	16.63
Base (estrés)	56.67	65.0	21.0	77.0	15.94
Sin adaptativo (estrés)	50.13	56.0	15.0	68.0	15.54
Sin normativo (estrés)	60.13	63.0	28.0	85.0	15.28
Sin afectivo (estrés)	43.60	43.0	17.0	64.0	14.97

Tabla 4.5: Resumen descriptivo del score SPUR para el análisis de 8 grupos.

La Figura 4.4 presenta la combinación de diagramas de caja y enjambre que permiten visualizar la interacción entre las configuraciones y los casos de estudio. El contraste más evidente surge en la configuración “Sin Afectivo”, mientras que el grupo de estrés mantiene una dispersión moderada, el grupo de matemáticas sufre un gran descenso, acumulando una gran densidad de puntos en el extremo inferior de la escala e incluso alcanzando el valor mínimo (0). Al examinar la estabilidad de las otras configuraciones, se observa que la condición “Base”, no está exenta de variabilidad extrema, registrando valores dispersos como los que descienden hasta los 20 puntos en ambos grupos. De forma similar, la configuración “Sin Normativo” revela un desajuste en el grupo de estrés: aunque su mediana es alta, el diagrama de puntos expone tres casos aislados, en donde dos tienen scores muy bajos (cercanos a 30) que se separan significativamente del comportamiento grupal. En la configuración “Sin Adaptativo” se presentan casos mínimos (cercanos a 15) en el caso de manejo de estrés, mientras que el grupo de matemáticas se mantiene más compacto. En conjunto, la gráfica indica que el componente afectivo es esencial para sostener la satisfacción y su ausencia puede notarse más en tareas de carga cognitiva como las matemáticas. Por su parte, los fallos en la ausencia de los componentes normativo y adaptativo tienden a generar valores atípicos especialmente en contextos de manejo del estrés.




Figura 4.4: Distribución del score (SPUR) por configuración y caso de estudio.

4.2.1.3 Análisis descriptivo para 12 grupos

El análisis global de la Tabla 4.6 muestra que la configuración "Sin afectivo" genera consistentemente el desempeño más bajo en los tres estudiantes, tal como indican las medias, y el estudiante 2 es el más afectado, esto podría estar asociado al género, donde algunos estudios mencionan que las mujeres tienden a ser más sensibles con los cambios del comportamiento del robot [97]. Por el contrario, el Estudiante 3 demuestra ser el sujeto con mayor estabilidad y rendimiento general, manteniendo no solo los promedios más altos en la mayoría de las configuraciones, sino también la menor dispersión de datos, evidenciada por desviaciones estándar significativamente bajas (entre 4,96 y 9,00) en comparación con los estudiantes 1 y 2, quienes presentan una variabilidad mucho mayor en sus respuestas.

Grupo	Media	Mediana	Mínimo	Máximo	Desv. Estándar
Base (estudiante 1)	43,00	45,00	21,00	60,00	12,68
Sin adaptativo (estudiante 1)	53,30	57,50	27,00	73,00	13,38
Sin normativo (estudiante 1)	52,50	53,50	29,00	72,00	14,92
Sin afectivo (estudiante 1)	42,80	49,00	7,00	64,00	19,61
Base (estudiante 2)	56,40	59,00	20,00	77,00	17,12
Sin adaptativo (estudiante 2)	52,90	59,00	15,00	67,00	16,59
Sin normativo (estudiante 2)	58,30	59,50	28,00	85,00	16,35
Sin afectivo (estudiante 2)	30,10	28,00	0,00	59,00	17,66
Base (estudiante 3)	63,80	66,00	48,00	74,00	9,00
Sin adaptativo (estudiante 3)	58,80	57,00	55,00	68,00	4,96
Sin normativo (estudiante 3)	59,40	61,00	51,00	66,00	5,91
Sin afectivo (estudiante 3)	39,60	42,00	33,00	45,00	4,97

Tabla 4.6: Resumen descriptivo del score SPUR para el análisis de 12 grupos.

La Figura 4.5 muestra la distribución de cada score (SPUR) a través de los 12 grupos experimentales, permitiendo analizar el impacto de cada configuración del MIHR en función de cada estudiante. El análisis visual mediante diagramas de caja y enjambre revela que aunque la configuración “Sin Afectivo” tiene una tendencia a bajar la satisfacción, hay un gran impacto para el Estudiante 2 y el Estudiante 3, cuyos datos evidencian una alta sensibilidad a la ausencia emocional. Específicamente, el Estudiante 2 muestra una inestabilidad en la configuración “Sin Afectivo”, evidenciada por un rango extremadamente amplio y valores que descienden hasta el mínimo (0), lo que sugiere que para este perfil el componente emocional es un requisito muy importante y puede estar asociado al género, como ciertos estudios lo consideran [98, 99]. Es importante mencionar que para este análisis

se observan más valores atípicos en los diferentes grupos dado a que el número de grupos aumentó, mientras que la muestra por cada uno se redujo. En general, se visualiza que el resultado de satisfacción en la interacción no depende únicamente de la arquitectura del robot, sino que pueden influir las diferencias individuales donde algunos sujetos suelen ser más resilientes que otros ante la pérdida de funcionalidades.




Figura 4.5: Distribución del score (SPUR) por configuración y estudiante.

4.2.2 Análisis ANOVA para medidas repetidas

4.2.2.1 Supuestos

- Normalidad: fue evaluada con la prueba de “Shapiro-Wilk”, que consiste en verificar si la distribución de los datos en los grupos sigue una la distribución normal (hipótesis nula). Esta prueba fue aplicada a los grupos de los tres tipos de análisis como se presenta en la Tabla 4.7. La mayoría de los grupos tienen un $p\text{-val} > 0.05$ cuyo significado es que se cumple la hipótesis nula; sin embargo, hay 6 grupos del total de 24 que no cumplen “análisis 1: Sin Adaptativo”, “análisis 2: Sin Adaptativo (estrés)”, “análisis 3: Sin Adaptativo (estudiante 2), Base (estudiante 3), Sin Adaptativo (estudiante 3), Sin Afectivo (estudiante 3)”. Esto podría estar influenciado por el tamaño bajo de las muestras. No obstante, el valor de W en los grupos, que consiste en medir qué tan bien se ajustan los datos a una curva normal (en una escala de 0 a 1), está muy cerca de 1, lo que indica un ajuste bueno en general. Ahora bien, aunque el

total de los grupos no cumplen con la prueba de “Shapiro-Wilk”, el 75% sigue siendo un número bueno, donde algunos grupos tienen valores de W cercanos a 1 (por ejemplo, ‘análisis 1: Sin Adaptativo’ con $W=0.869427$). Además, estudios de simulación y revisión mencionan que el ANOVA controla adecuadamente la tasa de error Tipo I (falso positivo), incluso con muestras de distribuciones sesgadas [100, 101].

Análisis	Grupo	W	p-val
Análisis ANOVA para 4 grupos	Base	0.968084	0.488173
	Sin Adaptativo	0.869427	0.001627
	Sin Normativo	0.967260	0.467184
	Sin Afectivo	0.971060	0.568558
Análisis ANOVA para 8 grupos	Base (matemáticas)	0.968660	0.837733
	Sin Adaptativo (matemáticas)	0.953061	0.573880
	Sin Normativo (matemáticas)	0.925776	0.235755
	Sin Afectivo (matemáticas)	0.964096	0.763095
	Base (estrés)	0.898747	0.091071
	Sin Adaptativo (estrés)	0.853401	0.019409
	Sin Normativo (estrés)	0.895558	0.081430
	Sin Afectivo (estrés)	0.949873	0.522452
Análisis ANOVA para 12 grupos	Base (estudiante 1)	0.866514	0.091016
	Sin Adaptativo (estudiante 1)	0.919656	0.354096
	Sin Normativo (estudiante 1)	0.912577	0.299168
	Sin Afectivo (estudiante 1)	0.913272	0.304233
	Base (estudiante 2)	0.932989	0.477926
	Sin Adaptativo (estudiante 2)	0.738332	0.002573
	Sin Normativo (estudiante 2)	0.965546	0.846761
	Sin Afectivo (estudiante 2)	0.969138	0.882736
	Base (estudiante 3)	0.776824	0.007573
	Sin Adaptativo (estudiante 3)	0.694891	0.000764
	Sin Normativo (estudiante 3)	0.873775	0.110598
	Sin Afectivo (estudiante 3)	0.823035	0.027575

Tabla 4.7: Resultados de la evaluación del supuesto de normalidad.

- Esfericidad: se evaluó con la prueba de “Mauchly” para los tres tipos de análisis. Los resultados fueron positivos ($p\text{-val} > 0.05$), tal como se presentan en la Tabla 4.8, cumpliendo con la hipótesis nula donde se asume que las varianzas de las diferencias entre todos los pares de condiciones son iguales.

Análisis	p-val
Análisis ANOVA para 4 grupos	0.6260
Análisis ANOVA para 8 grupos	0.9134
Análisis ANOVA para 12 grupos	0.1119

Tabla 4.8: Resultados de la evaluación del supuesto de esfericidad

4.2.2.2 Análisis ANOVA para 4 grupos

En este análisis con el ANOVA se evalúan las configuraciones del MIHR de forma general (Base, Sin Normativo, Sin Adaptativo, Sin Afectivo), y luego se especifica en donde están las diferencias encontradas (prueba post-hoc). En la Tabla 4.9 se observa la hipótesis nula, hipótesis alternativa y el resultado obtenido en este análisis.

Hipótesis nula	Hipótesis Alternativa	Resultado	Interpretación
No existen diferencias significativas en el score SPUR entre ninguno de los 4 grupos experimentales (configuraciones).	Al menos uno de los grupos difiere significativamente de los demás en el score SPUR.	$p = 0.000011$	Dado que $p < 0.05$, se rechaza la hipótesis nula. Esto quiere decir que sí existe al menos una configuración con diferencia estadísticamente significativa entre las configuraciones.

Tabla 4.9: Hipótesis y resultado del análisis.

Como se ha observado una diferencia significativa en el resultado del ANOVA, es necesario el análisis post-hoc. Para este trabajo se utiliza la prueba de “Bonferroni” para las comparaciones múltiples, debido a su eficacia en el control de probabilidad de cometer al menos un error tipo I. Considerando la naturaleza de medidas repetidas y las condiciones evaluadas, la prueba de Bonferroni ofrece una robustez estadística. Esto se logra aplicando una corrección al valor p en función del número de comparaciones (p-corr), minimizando así el riesgo de errores de Tipo I en comparación con métodos menos conservadores. Por consiguiente, al aplicar esta prueba a las muestras dependientes, se obtiene el valor p-corr resultante de las comparaciones realizadas (ver en la tabla 4.10). Los resultados indican que las diferencias se encuentran en la configuración que no usa el componente afectivo dado

que: Base vs. Sin Afectivo ($p\text{-corr} = 0.009944$), Sin Adaptativo vs. Sin Afectivo ($p\text{-corr} = 0.001011$), Sin Normativo vs. Sin Afectivo ($p\text{-corr} = 0.000077$). Por otro lado, cuando se realizan las comparaciones entre pares Base, Sin Adaptativo, y Sin Normativo se obtiene que no hay diferencias estadísticas ($p\text{-corr} = 1.000$). Esto implica que, estadísticamente, quitar la adaptabilidad o las normas no afectó el desempeño de los estudiantes en este experimento, como sí ocurrió con el componente afectivo.

Comparaciones	Valor de p ajustado (p-corr)
Base - Sin adaptativo	1.000000
Base - Sin afectivo	0.009944
Base - Sin normativo	1.000000
Sin adaptativo - Sin afectivo	0.001011
Sin adaptativo - Sin normativo	1.000000
Sin afectivo - Sin normativo	0.000077

Tabla 4.10: Comparaciones del análisis post-hoc y el valor obtenido.

En conclusión, la ausencia del componente afectivo afecta significativamente la satisfacción en comparación con las otras configuraciones del MIHR.

4.2.2.3 Análisis ANOVA para 8 grupos

En este análisis se evalúan las configuraciones del MIHR según el caso de estudio: {Base (matemáticas), Sin Normativo (matemáticas), Sin Adaptativo (matemáticas), Sin Afectivo (matemáticas), Base (estrés), Sin Normativo (estrés), Sin Adaptativo (estrés), Sin Afectivo (estrés)}, y también se realiza un análisis post-hoc para determinar cuáles son exactamente las diferencias significativas. En la Tabla 4.11 se observa la hipótesis nula, hipótesis alternativa y el resultado obtenido en este análisis.

Hipótesis nula	Hipótesis Alternativa	Resultado	Interpretación
No existen diferencias significativas en el score SPUR entre ninguno de los 8 grupos experimentales (configuraciones).	Al menos uno de los grupos difiere significativamente de los demás en el score SPUR.	$p = 9.923007e-07$	Dado que $p < 0.05$, se rechaza la hipótesis nula. Esto quiere decir que sí existe al menos una configuración con diferencia estadísticamente significativa entre las configuraciones.

Tabla 4.11: Hipótesis y resultado del análisis.

Para este análisis también se hace uso del post-hoc de Bonferroni para realizar las comparaciones múltiples. Dado que existen 28 comparaciones posibles, se extraen para este

análisis las comparaciones teóricamente más importantes y con los resultados significativos (ver Tabla 4.12), las cuales se eligen según el criterio “comparaciones para evaluar cómo varía la satisfacción en un mismo caso de estudio ante las distintas configuraciones del MIHR”. Los resultados muestran que en el caso de estudio de matemáticas el componente afectivo es muy importante, ya que cuando se quita este componente afecta el resultado de la satisfacción en comparación a las configuraciones “Sin Normativo” ($p\text{-corr} = 0.036834$) y “Sin Adaptativo” ($p\text{-corr} = 0.002041$). Para la comparación con la configuración “Base” en matemáticas no se refleja una diferencia significativa ($p\text{-corr} = 0.402973$). De igual forma, para el caso de estudio de manejo del estrés donde no hay diferencias significativas, la comparación que tiene un menor valor es la configuración “Sin normativo” vs “Si afectivo” ($p\text{-corr} = 0.139611$) esto quiere decir que la ausencia del componente afectivo es más relevante. Finalmente, cuando es usada una misma configuración en los dos casos de estudio no se notan cambios significativos, aunque la ausencia del componente normativo fue la que obtuvo un *valor p-corr* menor al resto.

Tipo de comparación	Pares a comparar	Valor de p ajustado (p-corr)
Variación de la satisfacción en un mismo caso de estudio ante las distintas configuraciones del MIHR.	Base (matemáticas) - Sin Afectivo (matemáticas)	0.402973
	Sin Adaptativo (matemáticas) - Sin Afectivo (matemáticas)	0.002041
	Sin Normativo (matemáticas) - Sin Afectivo (matemáticas)	0.036834
	Sin Normativo (estrés) - Sin Afectivo (estrés)	0.139611
	Base (estrés) - Sin Afectivo (estrés)	1.000000
	Sin Adaptativo (estrés) - Sin Afectivo (estrés)	1.000000

Tabla 4.12: Comparaciones relevantes del análisis post-hoc y el valor obtenido.

En relación a este análisis se muestra que el componente afectivo es más relevante para la satisfacción en el caso de estudio de matemáticas, esto viene dado a que en comparación con los otros grupos hay dos resultados significativos.

4.2.2.4 Análisis ANOVA para 12 grupos

Para este análisis se evalúan las configuraciones del MIHR según el estudiante: {Base (estudiante 1), Sin Normativo (estudiante 1), Sin Adaptativo (estudiante 1), Sin Afectivo (estudiante 1), Base (estudiante 2), Sin Normativo (estudiante 2), Sin Adaptativo (estudiante 2), Sin Afectivo (estudiante 2), Base (estudiante 3), Sin Normativo (estudiante 3), Sin

Adaptativo (estudiante 3), Sin Afectivo (estudiante 3)}. En la Tabla 4.13 se observa la hipótesis nula, hipótesis alternativa y el resultado obtenido en este análisis, y después se realiza un análisis post hoc para determinar donde están las diferencias importantes.

Hipótesis nula	Hipótesis Alternativa	Resultado	Interpretación
No existen diferencias significativas en el score SPUR entre ninguno de los 12 grupos experimentales (configuraciones).	Al menos uno de los grupos difiere significativamente de los demás en el score SPUR.	$p = 2.354941e-07$	Dado que $p < 0.05$, se rechaza la hipótesis nula. Esto quiere decir que sí existe al menos una configuración con diferencia estadísticamente significativa entre las configuraciones.

Tabla 4.13: Hipótesis y resultado del análisis.

Se utiliza el post-hoc de Bonferroni para realizar las comparaciones múltiples. Dado que existen 66 comparaciones posibles, se han seleccionado para este análisis las comparaciones teóricamente más relevantes y con resultados significativos (ver Tabla 4.14), las cuales se basan en el criterio “comparaciones para evaluar cómo varía la satisfacción de un mismo estudiante ante las distintas configuraciones del MIHR”. En ese sentido, se observa que para el estudiante 3 la ausencia del componente afectivo afecta la satisfacción respecto a las demás configuraciones ($p\text{-corr} = 4.675036e-09$, $p\text{-corr} = 1.769535e-04$, y $p\text{-corr} = 2.261149e-04$). En el estudiante 2 hay una diferencia entre la ausencia del componente normativo y el afectivo ($p\text{-corr} = 1.330322e-02$). Para el estudiante 1 no hay diferencias significativas entre las configuraciones dado que los valores de $p\text{-corr}$ son 1.

Tipo de comparación	Comparaciones	Valor de p ajustado (p-corr)
Variación de la satisfacción en un mismo estudiante ante las distintas configuraciones del MIHR	Sin Afectivo (estudiante 3) - Sin Normativo (estudiante 3)	4.675036e-09
	Sin Adaptativo (estudiante 3) - Sin Afectivo (estudiante 3)	1.769535e-04
	Base (estudiante 3) - Sin Afectivo (estudiante 3)	2.261149e-04
	Sin Afectivo (estudiante 2) - Sin Normativo (estudiante 2)	1.330322e-02

Tabla 4.14: Comparaciones relevantes del análisis post-hoc y el valor obtenido.

En resumen, se observa que los perfiles del estudiante 2 y 3 son los más sensibles a la ausencia del componente afectivo, provocando un resultado más negativo de la satisfacción en comparación con el estudiante 1; y también en el estudiante 3 se observan diferencias significativas con respecto a las otras configuraciones de uso, que para el estudiante 2 solo se refleja con la ausencia del componente normativo.

4.2.3 Discusión general de los resultados

Los resultados obtenidos en las 120 sesiones experimentales permiten analizar el MIHR usando la arquitectura propuesta basada en LLMs. La principal revelación del estudio de ablación es que el componente afectivo es el factor determinante en la satisfacción del usuario. Los resultados del análisis descriptivo, ANOVA y las pruebas post-hoc de Bonferroni confirman de manera consistente que la ausencia de este componente genera una disminución significativa en el score SPUR en comparación con las demás configuraciones. Esto sugiere que, en una interacción, la capacidad del robot para reconocer y expresar emociones genera un vínculo con el estudiante, validando la premisa teórica del MIHR sobre la importancia de la expresión de emociones.

Se observa una diferencia en el comportamiento del componente afectivo según el caso de estudio. En el aprendizaje de las matemáticas, un área caracterizada por una alta carga cognitiva y dificultades comunes de comprensión, la ausencia del componente afectivo provocó el descenso más notorio en la satisfacción (media de 31.47). Por el contrario, en el caso del manejo del estrés, aunque también hubo una disminución, el impacto fue menor (media de 43.60). Esto permite decir que, cuando un usuario enfrenta tareas que requieren mayor esfuerzo mental, la empatía y las recompensas verbales del robot podrían ser muy importantes para mantener la motivación y el interés.

Un hallazgo destacado fue que las configuraciones "Sin Adaptativo" y "Sin Normativo" mantuvieron niveles de satisfacción estadísticamente similares a la configuración base. Esto podría explicarse por la ventaja de los LLMs; es probable que, incluso sin un módulo de adaptación explícito, la capacidad del modelo de lenguaje para manejar el historial de la conversación y generar respuestas coherentes haya compensado parcialmente estas carencias. No obstante, la configuración "Sin Adaptativo" mostró valores atípicos en el caso de estrés, lo que indica que en contextos de bienestar personal, la personalización podría ser más relevante.

Los resultados también indican que la satisfacción podría no depender únicamente de la arquitectura del robot, sino del perfil del estudiante. El caso del estudiante 2 (perfil femenino) mostró la mayor sensibilidad a la falta de emociones, llegando a registrar los valores mínimos. Esto se asocia con la literatura que sugiere que las mujeres pueden ser más perceptivas ante los cambios en el comportamiento social de un robot. Por otro lado, el Estudiante 3 demostró una mayor resiliencia, manteniendo promedios más altos, aunque su satisfacción también se vio afectada negativamente por la falta del componente afectivo.

Finalmente, la capacidad del MIHR para funcionar con éxito en dos dominios diferentes como el aprendizaje de las matemáticas y el manejo del estrés permite concluir que el MIHR puede ser adaptable y genérico. Los resultados generales son “moderados” con un promedio de satisfacción que ronda el 50%. Dos aspectos que pudieran estar impidiendo un mayor valor de satisfacción son: (1) la interacción se centró en la modalidad de comunicación verbal aprovechando las capacidades del LLM, no obstante, la literatura señala la importancia de incorporar contacto físico, gestos faciales más complejos, y dispositivos complementarios, ya que permiten una mejor percepción de la interacción; y (2) las rúbricas de satisfacción se basan en conversaciones simuladas (ante la falta de un “dataset” real previo), lo cual podría omitir todos los matices (ítems de la rúbrica) de una interacción humana real para una evaluación más precisa.

Capítulo V. Conclusiones

El objetivo principal de este Proyecto de Grado fue la evaluación del Modelo de Interacción Humano-Robot (MIHR) en dos casos de estudio: aprendizaje de las matemáticas y el manejo del estrés enfocados en el ámbito universitario. Para lograrlo, se diseñó una Arquitectura de Integración basada en LLMs con el objetivo de implementar partes funcionales del MIHR para realizar interacciones adaptables a las necesidades del usuario y contexto, y también, para facilitar la evaluación del MIHR. Los hallazgos, en general, revelan que el modelo puede adaptarse a contextos diferentes, con resultados moderados en la satisfacción. A continuación, se presentan las conclusiones, aportes, limitaciones, recomendaciones y trabajos futuros de este Proyecto de Grado.

5.1 Conclusiones

En este Proyecto de Grado se alcanzaron satisfactoriamente todos los objetivos propuestos. En primer lugar, se identificaron requerimientos importantes para los dos casos de estudio usando robots sociales. En cuanto a la modalidad de comunicación, la principal forma de interacción es verbal, ya que es la manera más natural en que los humanos se comunican; en la adaptación, se considera importante la personalización del diálogo, el andamiaje pedagógico y la adaptación de los niveles de dificultad; y en la expresión de emociones, es común el uso de recompensas verbales, pero se considera muy necesario que el robot use formas no verbales como los gestos faciales y movimientos corporales. Asimismo, en la actualidad, la inclusión de los LLMs en la implementación de robots sociales se considera bastante relevante para establecer interacciones más fluidas y dinámicas, capaces de adaptar las conversaciones sin tanta rigidez.

En este trabajo se diseñó la “Arquitectura de Integración” compuesta por cuatro capas (Validación manual, Auto-configuración, Ejecución y Auto-evaluación). Este diseño permitió sistematizar el uso de los LLMs mediante técnicas de ingeniería de prompts para guiar el razonamiento según su rol y objetivo, y se agregó un grafo de conocimiento para servir como fuente de contexto externa para que el LLM pudiera usar y así reducir el riesgo de alucinaciones, cuya función fue proporcionar contexto sobre el usuario y el caso de estudio para la interacción, así como ofrecer un conjunto de pruebas definidas para la validación de los componentes. La primera capa se enfoca en validar el funcionamiento de los componentes del MIHR que usaban el LLM, donde en las pruebas se consideraron diversos escenarios que

se podrían presentar en una interacción para verificar su comportamiento. La segunda capa se centra en el proceso de instancia de todos los componentes necesarios para la interacción (según la configuración de ablación). La tercera capa está orientada a las interacciones reales entre el robot social LRS2 que usaba el MIHR y un estudiante. Finalmente, la cuarta capa permite la evaluación del registro de la conversación, para determinar el nivel de satisfacción del estudiante y luego actualizar el grafo con la información relevante de la sesión en relación al usuario.

Como consideraciones importantes, el MIHR fue implementado a través del robot social LRS2 que está orientado al uso en contextos académicos, utilizando como framework ROS2 para facilitar la comunicación de los componentes mediante el patrón de publicación y suscripción. Un pilar fundamental de la implementación fue la integración de Grafos de Conocimiento con Neo4j, el cual ayudó al robot a tener una memoria estructurada para recuperar la información según el usuario y contexto, reduciendo el riesgo de alucinaciones del LLM y permitiendo consultas dinámicas mediante lenguaje Cypher. La estructura de los prompts fue organizada mediante el uso del framework ROSES y el etiquetado XML.

Finalmente, se realizó la evaluación del comportamiento del robot con el método SPUR (Supervised Prompting for User satisfaction Rubrics), donde el LLM fue capaz de generar rúbricas interpretables para cada caso de estudio y luego realizar cada una de las estimaciones de la satisfacción de los usuarios según las conversaciones. El análisis de los resultados del estudio de ablación (120 sesiones) demostraron que, si bien el MIHR es versátil, la ausencia del componente afectivo es el factor que más degrada la satisfacción del estudiante a nivel general (media de 37.53 frente a ~53-55 en otras configuraciones), especialmente, en tareas de alta carga cognitiva como las matemáticas, tal como lo indicaron los resultados del segundo análisis ANOVA. También se identificó que el género del usuario podría influir en la satisfacción del usuario, tal como sucedió con el perfil del estudiante 2 (femenino) respecto a la ausencia del componente afectivo en el MIHR. Finalmente, los resultados de SPUR obtenidos son moderados, obteniéndose peores resultados en el caso de estudio de matemáticas y perfil de estudiante femenino, en particular, cuando no se usa el componente afectivo.

5.2 Aportes

Las principales contribuciones de este Proyecto de Grado son las siguientes:

- Se realizó una revisión sobre las estrategias basadas en robótica para el aprendizaje de las matemáticas y manejo del estrés.
- Se diseñó una “Arquitectura de Integración” basada en LLMs para la evaluación del modelo de Interacción-Humano Robot (MIHR).
- Se construyó un Grafo de Conocimiento como fuente externa de contexto para minimizar las alucinaciones de los LLMs.
- Se implementó el MIHR en el caso de estudio de aprendizaje de las matemáticas y manejo de estrés en la educación.
- Se evaluó el MIHR usando el método SPUR basado en LLMs para determinar el nivel de satisfacción de los estudiantes en las interacciones realizadas con el robot social LRS2 para los dos casos de estudio.
- Se analizaron las tres premisas del MIHR en relación con el uso y ausencia de componentes principales (normativo, adaptativo, y afectivo) para determinar el efecto que genera en la satisfacción.

5.3 Limitaciones

Tanto en el diseño e implementación de la Arquitectura de Integración como en la experimentación se encontraron algunas limitaciones importantes:

- Para la capa de Validación Manual se usan ejemplos de referencia para guiar el juicio del LLM en la validación del componente. Sin embargo, estos ejemplos son generados de forma simulada debido a la carencia de ejemplos reales, y podrían dificultar una representación más cercana a las situaciones de los casos de estudio.
- La auto-configuración de los componentes tuvo como limitante principal la memoria y procesamiento del hardware local del robot para configurar todos los componentes. Para mitigar esto, se optó por instanciar ciertos componentes en un computador externo, aprovechando la capacidad de comunicación que ofrece el framework ROS2.
- La auto-evaluación tuvo como limitante la carencia de conversaciones reales previamente etiquetadas (SAT/DSAT) para la generación de rúbricas en los dos casos de estudio. Se tuvieron que generar conversaciones simuladas que permitieran extraer patrones de satisfacción.

- El diseño experimental tuvo como limitación el tamaño de las muestras, dado que solo se pudo trabajar con tres estudiantes para hacer las pruebas. Esto afecta la normalidad estadística de los datos y la posibilidad de generalizar mejor los resultados de satisfacción.

5.4 Recomendaciones

A continuación se presentan algunas recomendaciones en función de mejorar la Arquitectura de Integración.

- La validación de los componentes del MIHR (la primera capa de la Arquitectura de Integración) se lleva a cabo de forma manual para determinar si están listos para funcionar. Se recomienda explorar alternativas que permitan automatizar este proceso de validación de componentes. Esto facilitaría y agilizaría la aprobación de su funcionamiento en nuevos casos de estudio.
- Durante la ejecución de la interacción, debido a la dependencia de APIs externas para los LLMs como el uso de Gemini en este trabajo, pueden ocurrir pequeños retrasos, por lo que se debería probar el uso de modelos locales (como OLLAMA) para tareas que requieren respuestas inmediatas, esto podría hacer más natural la comunicación.
- Este trabajo se enfocó principalmente en la comunicación verbal con el fin de aprovechar las capacidades de los LLMs. Sin embargo, se recomienda la incorporación de componentes que permitan el contacto físico con el robot, ya que estos poseen ventajas sobre los agentes no físicos. Además, el uso de complementos externos como tablets o un computador en el diseño de las interacciones pueden potenciar y mejorarlas.
- Dada la importancia del módulo afectivo para la satisfacción, es importante ampliar y optimizar principalmente el uso de los gestos faciales y movimientos del robot; así como explorar diversas formas de usar el componente paraverbal para generar mayor variabilidad emocional según la situación.
- Tanto en las capas de Validación Manual como Auto-Evaluación se usaron ejemplos y conversaciones simuladas, respectivamente. Por lo que se recomienda construir un “dataset” con ejemplos y conversaciones reales que permitan mejorar sus funcionalidades.

5.5 Trabajos futuros

En aras de continuar esta línea de investigación, se proponen los siguientes trabajos:

- Implementar el MIHR en otros dominios como los identificados en los antecedentes: apoyo a adultos mayores, asistencia en hoteles, aprendizaje de idiomas, entre otros.
- Integrar modelos de visión por computadora más robustos que permitan al robot reconocer no solo la posición del usuario, sino también otros aspectos más complejos para una adaptación afectiva en tiempo real.
- Realizar un análisis detallado de cómo extender las modalidades de interacción en la implementación del MIHR basada en LLMs, incorporando nuevas como contacto físico, gestos faciales más complejos, entre otros, con el fin de mejorar los valores de SPUR.
- Realizar evaluaciones que superen las 40 sesiones por estudiante para analizar el impacto del robot a lo largo del tiempo, verificando si el nivel de satisfacción se mantiene o si hay un “efecto novedad” (respuesta inicial de mayor interés, atención y rendimiento ante algo nuevo) que disminuye con el tiempo.
- Optimizar el uso del Grafo de Conocimiento para generar contextos de interacción aún más precisos y dinámicos.

Referencias

- [1] J. Pérez, J. Aguilar, and E. Dapena, “MIHR: A human-robot interaction model”, *IEEE Latin America Transactions*, vol. 18, no. 9, pp. 1521-1529, 2020.
- [2] H.A. Frijns, O. Schürer, and S.T. Koeszegi, “Communication Models in Human–Robot Interaction: An Asymmetric MODEL of ALterity in Human–Robot Interaction (AMODAL-HRI)”, *International Journal of Social Robotics*, vol. 15, pp. 473–500, 2023. DOI:10.1007/s12369-021-00785-7
- [3] S. Han, M. Wang, J. Zhang, D. Li, and J. Duan, “A Review of Large Language Models: Fundamental Architectures, Key Technological Evolutions, Interdisciplinary Technologies Integration, Optimization and Compression Techniques, Applications, and Challenges”, *Electronics*, vol. 13, no. 24, 2024. DOI:10.3390/electronics13245040
- [4] A. N. Baecker, D. Y. Geiskkovitch, A. L. González, and J. E. Young, “Emotional support domestic robots for healthy older adults: Conversational prototypes to help with loneliness”, In *Companion of the 2020 ACM/IEEE International Conference on Human-Robot Interaction*, pp. 122-124, 2020. DOI:10.1145/3371382.3378279
- [5] C. Di Napoli, G. Ercolano, and S. Rossi, “Personalized home-care support for the elderly: a field experience with a social robot at home. User Modeling and User-Adapted Interaction”, vol. 33, pp. 405-440, 2023. DOI:10.1007/s11257-022-09333-y
- [6] A. Ahtinen, N. Beheshtian, and K. Väänänen, “Robocamp at home: Exploring families' co-learning with a social robot: Findings from a one-month study in the wild”, In *Proceedings of the 2023 ACM/IEEE International Conference on Human-Robot Interaction*, pp. 331-340, 2023. DOI:10.1145/3568162.3576976
- [7] M. Salkowski, E. Checcucci, A.K. Chow, C.C. Rogers, F. Adbollah, E. Liatsikos, ... and R. Autorino, “New multiport robotic surgical systems: a comprehensive literature review of clinical outcomes in urology”, *Therapeutic Advances in Urology*, vol. 15, 2023. DOI:10.1177/17562872231177781
- [8] I. G. Diethelm, S. S. Hansen, F. B. Leth, K., Fischer, and O. Palinko, “Effects of gaze and speech in human-robot medical interactions”, In *Companion of the 2021 ACM/IEEE International Conference on Human-Robot Interaction*, pp. 349-353, 2021. DOI:10.1145/3434074.3447190
- [9] R. Boumans, R. Melis, T. Bosse, and S. Thill, “A Social Robot for Explaining Medical Tests and Procedures: An Exploratory Study in the Wild”, In *Companion of the 2023*

ACM/IEEE International Conference on Human-Robot Interaction, pp. 263-267, 2023. DOI:10.1145/3568294.3580085

[10] J. Nakanishi, I. Kuramoto, J. Baba, K. Ogawa, Y. Yoshikawa, and H. Ishiguro, "Soliloquising Social Robot in a Hotel Room", In Proceedings of the 31st Australian Conference on Human-Computer-Interaction, Association for Computing Machinery, New York, NY, USA, pp. 21-29, 2020. DOI:10.1145/3369457.3370913

[11] S.S. Cha, "Customers' intention to use robot-serviced restaurants in Korea: relationship of coolness and MCI factors", International Journal of Contemporary Hospitality Management, Vol. 32, No. 9, pp. 2947-2968, 2020 DOI:10.1108/IJCHM-01-2020-0046

[12] N. Gasteiger, M. Hellou, and H.S. Ahn, "Deploying social robots in museum settings: A quasi-systematic review exploring purpose and acceptability", International Journal of Advanced Robotic Systems, vol. 18, no. 6, 2021. DOI:10.1177/17298814211066740

[13] G. Huang, and R. K. Moore, "Using social robots for language learning: are we there yet?", Journal of China Computer-Assisted Language Learning, vol. 3, no. 1, pp. 208-230, 2023. DOI:10.1515/jccall-2023-0013

[14] M. Escobar-Planas, V. Charisi, and E. Gómez, "That Robot Played with Us!, Children's Perceptions of a Robot after a Child-Robot Group Interaction", Proceedings of the ACM on Human-Computer Interaction, vol. 6, no. CSCW2, pp. 1-23, 2022. s. DOI:10.1145/3555118

[15] E. A. Konijn and J. F. Hoorn, "Robot tutor and pupils' educational ability: Teaching the times tables", Computers & Education, vol. 157, p. 103970, 2020. DOI:10.1016/j.compedu.2020.103970

[16] A. Edwards, C. Edwards, B. Abendschein, J. Espinosa, J. Scherger, and P. Vander Meer, "Using robot animal companions in the academic library to mitigate student stress", Library Hi Tech, Vol. 40 No. 4, pp. 878-893, 2023. DOI:10.1108/LHT-07-2020-0148

[17] H. Serin, "Teaching Mathematics: Strategies for Improved Mathematical Performance", International Journal of Social Sciences & Educational Studies, vol. 10, no. 3, 2023. DOI: 10.23918/ijsses.v10i3p146

[18] F.Saadati, and S. Celis, "Student Motivation in Learning Mathematics in Technical and Vocational Higher Education: Development of an Instrument", International Journal of Education in Mathematics, Science and Technology, vol. 11 no. 1, pp. 156-178. DOI:10.46328/ijemst.2194

- [19] M. Ligthart, S. De Droog, M. Bossema, L. Elloumi, K. Hoogland, M. Smakman, K. Hindriks, and S. Ben Allouch, “Design Specifications for a Social Robot Math Tutor”, In Proceedings of the 2023 ACM/IEEE International Conference on Human-Robot Interaction (HRI '23). Association for Computing Machinery, New York, NY, USA, pp. 321–330, 2023. DOI:10.1145/3568162.3576957
- [20] M. C. Pascoe, S. E. Hetrick, and A. G. Parker, “The impact of stress on students in secondary school and higher education”, International journal of adolescence and youth, vol. 25, no. 1, pp. 104-112, 2020. DOI:10.1080/02673843.2019.1596823
- [21] M. F. Silva-Ramos, J. J. López-Cocotle, and M. E. C. Meza-Zamora, “Estrés académico en estudiantes universitarios”, Investigación y Ciencia de la Universidad Autónoma de Aguascalientes, vol. 28, no. 79, pp. 75-83, 2020.
- [22] T. Akiyoshi, J. Nakanishi, H. Ishiguro, H. Sumioka and M. Shiomi, "A Robot That Encourages Self-Disclosure to Reduce Anger Mood", in IEEE Robotics and Automation Letters, vol. 6, no. 4, pp. 7925-7932, 2021, DOI:10.1109/LRA.2021.3102326
- [23] L. Fuentes-Moraleda, P. Díaz-Pérez, A. Orea-Giner, A. Muñoz- Mazón, and T. Villacé-Molinero, “Interaction between hotel service robots and humans: A hotel-specific Service Robot Acceptance Model (sRAM)”, Tourism Management Perspectives, vol.36, 2020. DOI:10.1016/j.tmp.2020.100751
- [24] A. Ayub, L. Nehaniv, and K. Dautenhahn, “A Personalized Household Assistive Robot that Learns and Creates New Breakfast Options through Human-Robot Interaction”. In 2023 32nd IEEE International Conference on Robot and Human Interactive Communication (RO-MAN), pp. 2387-2393, 2023. DOI:10.1109/RO-MAN57019.2023.10309575
- [25] J. Q. Tobar, A. Prócel, D. Loza, E. Caicedo, and B. Bacca, “Autism Robotic Theater: a technological tool to contribute to the social interaction of children diagnosed with autism spectrum disorder”, Periodicals of Engineering and Natural Sciences, vol.9 no. 3, pp. 548-567, 2021. DOI:10.21533/pen.v9i3.2187
- [26] Y. Kim, P. Lee, and M. Bilge, “Understanding Large-Language Model (LLM)-powered Human-Robot Interaction”, In Proceedings of the 2024 ACM/IEEE International Conference on Human-Robot Interaction (HRI '24). Association for Computing Machinery, New York, NY, USA, pp. 371–380, 2024. DOI:10.1145/3610977.3634966
- [27] H. Li, Q. Dong, J. Chen, H. Su, Y. Zhou, Q. Ai, Z. Ye, and Y. Liu. “LLMs-as-Judges: A Comprehensive Survey on LLM-based Evaluation Methods”, ArXiv, 2024. abs/2412.05579. DOI:10.48550/arXiv.2412.05579

[28] S. So, and N. Lee. “Pedagogical exploration and technological development of a humanoid robotic system for teaching to and learning in young children”, *Cogent Education*, vol. 10, no. 1, p. 2179181, 2023. DOI:10.1080/2331186X.2023.2179181

[29] M. Alhashmi, O. Mubin, and R. Baroud, “Examining the use of robots as teacher assistants in UAE classrooms: teacher and student perspectives”, *Journal of Information Technology Education: Research*, pp. 245-261, 2021.

[30] Riek, L. D., “Wizard of oz studies in HRI: a systematic review and new reporting guidelines”, *Journal of Human-Robot Interaction*, vol. 1, no. 1, pp. 119-136. DOI:10.5898/jhri.1.1.riek

[31] A. Bravo Perucho, and M. Alimardani, “Social Robots in Secondary Education: Can Robots Assist Young Adult Learners with Math Learning?”, In *Companion of the 2023 ACM/IEEE International Conference on Human-Robot Interaction (HRI '23)*. Association for Computing Machinery, New York, NY, USA, pp. 355-359. DOI:10.1145/3568294.3580105

[32] B. G. Carrillo, “Diseño de interacción humano-robot para el aprendizaje de las tablas de multiplicación e implementación de los modelos de reconocimiento del habla”. *Proyecto de Grado, Universidad de Los Andes, Mérida, Venezuela*, 2021.

[33] K. Klęczek, A. Rice, & M. Alimardani, “Robots as Mental Health Coaches: A Study of Emotional Responses to Technology-Assisted Stress Management Tasks Using Physiological Signals”. *Sensors*, vol. 24, no. 13, p. 4032, 2024.

[34] S. Rossi, S. Santini, D. Di Genova, G. Maggi, A. Verrotti, G. Farello, R. Romualdi, A. Alisi, A. Tozzi, and C. Balsano, “Using the Social Robot NAO for Emotional Support to Children at a Pediatric Emergency Department: Randomized Clinical Trial”, *J Med Internet Res*, vol. 24, no. 1, pp. 1-10, 2022. DOI: 10.2196/29656

[35] M. Shiomi, and N. Hagita, “Audio-Visual Stimuli Improve Both Robot's Hug Impressions and Stress-Buffering Effects”. In *Social Touch in Human–Robot Interaction*, CRC Press, pp. 183-195, 2024. DOI: 10.1201/9781003384274-20

[36] M. Pinto-Bernal, M. Biondina, and T. Belpaeme, “Designing Social Robots with LLMs for Engaging Human Interaction”, *Applied Sciences*, vol. 15, no. 11. DOI:10.3390/app15116377

[37] M. Á. González-Santamarta, F. J. Rodríguez-Lera, Á. M. Guerrero-Higueras, and V. Matellán-Olivera, “Integration of large language models within cognitive architectures for autonomous robots”, 2023. DOI:10.48550/arXiv.2309.14945

[38] M. Elgarf, H. Salam, and C. Peters, “Fostering children’s creativity through LLM-driven storytelling with a social robot”, *Frontiers in Robotics and AI*, vol. 11, 2024. DOI:10.3389/frobt.2024.1457429

[39] X. Shi, J. Xu, J. Ding, J. Pang, S. Liu, S. Luo, ... and S. Zhang, “Llm-mini-cex: Automatic evaluation of large language model for diagnostic conversation”, 2023. DOI:10.48550/arXiv.2308.07635

[40] M. Shiomi, “A systematic survey of multiple social robots as a passive- and interactive-social medium”, *Advanced Robotics*, vol. 38, no. 7, pp. 440-454, 2023. DOI:10.1080/01691864.2023.2297900

[41] R. M. Muhammadjonovich, “Comparative Analysis Of The Use Of Modern And Traditional Methods Of Education In Higher Education”, *Periodica Journal of Modern Philosophy, Social Sciences and Humanities*, vol. 20, pp 1-3, 2023.

[42] Z. K. Szabo, P. Körtesi, J. Guncaga, D. Szabo, and R. Neag, “Examples of problem-solving strategies in mathematics education supporting the sustainability of 21st-century skills”, *Sustainability*, vol. 12, no. 23, 2020. DOI:10.3390/su122310113

[43] M. Chacón-Castro, J. Buele, A. D. López-Rueda, and J. Jadán-Guerrero, “Pólya’s Methodology for Strengthening Problem-Solving Skills in Differential Equations: A Case Study in Colombia”, *Computers*, vol. 12, no. 11, p. 239, 2023. DOI:10.3390/computers12110239

[44] F. Dahalan, N. Alias, and M. S. N. Shaharom, “Gamification and game based learning for vocational education and training: A systematic literature review”, *Education and Information Technologies*, vol. 29, no. 2, pp. 1279-1317, 2024. DOI:10.1007/s10639-022-11548-w

[45] N. A. N. Ariffin, N. Ramli, N. M. F. H. N. Badrul, Y. Yusof, and, A. Suparlan, “Effectiveness of gamification in teaching and learning mathematics”, *Journal on Mathematics Education*, vol. 13, no. 1, pp. 173-190, 2022. DOI:10.22342/jme.v13i1.pp173-190

[46] M.I. Baig, and E. Yadegaridehkordi, “Flipped classroom in higher education: a systematic literature review and research challenges”. *International Journal of Educational Technology in Higher Education*, vol. 20, no. 61, 2023. DOI:10.1186/s41239-023-00430-5

[47] H. Fredriksen, “Exploring realistic mathematics education in a flipped classroom context at the tertiary level”, *International Journal of Science and Mathematics Education*, vol. 19, no. 2, pp. 377-396, 2021

[48] T. Zisopoulou, and L. Varvogli, “Stress Management Methods in Children and Adolescents: Past, Present, and Future”. *Horm Res Paediatr*, vol. 96, no. 1, pp. 97-107. 2023. DOI:10.1159/000526946.

[49] J. Borges, “EASY MIND VR: Una aplicación de realidad virtual para mejorar el bienestar emocional”. Proyecto de Grado, Universidad de Los Andes, Mérida, Venezuela, 2024.

[50] P. P. Pandekar and P. D. Thangavelu, “Effect of 4-7-8 breathing technique on anxiety and depression in moderate chronic obstructive pulmonary disease patients”, *International Journal of Health Sciences*, vol. 5, pp. 209-17, 2019.

[51] M. Haghikia, N. Hammar, C. Marshall, and B. Svensson, “Exploring Player-Character Alignment Through Breathing Mechanics”, 2024.

[52] D. Puerta-C and D. Cruz-Becerra, “Influencia de la respiración diafragmática en la motricidad fina”, *Acta Colombiana de Psicología*, vol. 0, no. 10, pp. 89-95, 2003.

[53] S. Ghiya, “Alternate nostril breathing: a systematic review of clinical trials”, *Int J Res Med Sci*, vol. 5, no. 8, pp. 3273-3286, 2017. DOI:10.18203/2320-6012.ijrms20173523.

[54] J. Hart, “Guided imagery. Alternative and complementary therapies”, vol. 14, no. 6, pp. 295-299, 2008. DOI:10.1089/act.2008.14604

[55] A. Tseng, “Scientific Evidence of Health Benefits by Practicing Mantra Meditation: Narrative Review”, *International Journal of Yoga*, vol. 15, no. 2, pp. 89-95 2022. DOI:10.4103/ijoy.ijoy_53_22

[56] Z. Schuman-Olivier, et al., “Mindfulness and Behavior Change”, *Harvard Review of Psychiatry*, vol. 28, no. 6, pp. 371-394, 2020. DOI:10.1097/HRP.0000000000000277

[57] L. Toussaint, et al., “Effectiveness of progressive muscle relaxation, deep breathing, and guided imagery in promoting psychological and physiological states of relaxation”, *Evidence-Based Complementary and Alternative Medicine*, vol. 1, 2021. DOI:10.1155/2021/5924040

[58] A. C. Haynes, A. Lywood, E. M. Crowe, J. L. Fielding, J.M. Rossiter and C. Kent, “A calming hug: Design and validation of a tactile aid to ease anxiety”, *PLoS ONE*, vol. 17, no. 3, 2022. DOI:10.1371/journal.pone.0259838

[59] S. K. Suleman, A. Atrushi, and K. Enskär, “Effectiveness of art-based distraction on reducing pediatric patients' pain and anxiety during venipuncture: A randomized controlled trial”, *Complementary Therapies in Clinical Practice*, vol. 48, p. 101597, 2022. DOI:10.1016/j.ctcp.2022.101597

- [60] R. Islam and I. Ahmed, “Gemini-the most powerful LLM: Myth or Truth”, 2024 5th Information Communication Technologies Conference (ICTC), Nanjing, China, pp. 303-308, 2024. DOI:10.1109/ICTC61510.2024.10602253
- [61] M. U. Hadi, et al., “A Survey on Large Language Models: Applications, Challenges, Limitations, and Practical Usage”, TechRxiv, 2023. DOI:10.36227/techrxiv.23589741.v1
- [62] F. Neha, and D. Bhati, “A Survey of DeepSeek Models”, TechRxiv, 2025. DOI:10.36227/techrxiv.173896582.25938392/v1
- [63] T. N. Fitria, “Artificial intelligence (AI) technology in OpenAI ChatGPT application: A review of ChatGPT in writing English essay”, In ELT Forum: Journal of English Language Teaching, vol. 12, nro. 1, pp. 44-58, 2023. DOI:10.15294/elt.v12i1.64069
- [64] F. S. Marcondes, A. Gala, R. Magalhães, F. Perez de Britto, D. Durães and P. Novais, “Using Ollama”, In: Natural Language Analytics with Generative Large-Language Models. SpringerBriefs in Computer Science. Springer, pp. 23-35, 2025. DOI:10.1007/978-3-031-76631-2_3
- [65] R. Patil, and V. Gudivada, “A review of current trends, techniques, and challenges in large language models (LLMs)”, Applied Sciences, vol. 14, no. 5, 2024. DOI:10.3390/app14052074
- [66] B. Chen, Z. Zhang, N. Langrené, and S. Zhu, “Unleashing the potential of prompt engineering in large language models: a comprehensive review”, arXiv preprint, 2023. DOI:10.48550/arXiv.2310.14735
- [67] J. Park, and S. Choo, “Generative AI Prompt Engineering for Educators: Practical Strategies. Journal of Special Education Technology”, 2024. DOI:10.1177/01626434241298954
- [68] T. F. Heston, and C. Khun, “Prompt engineering in medical education”, International Medical Education, vol. 2, no. 3, pp. 198-205, 2023. DOI:10.3390/ime2030019.
- [69] L. S. Lo, “The CLEAR path: A framework for enhancing information literacy through prompt engineering. The Journal of Academic Librarianship”, vol. 49, no. 4, 2023. DOI:10.1016/j.acalib.2023.102720
- [70] Y. Zeng, P. Lou, J. Hu, C. Fan, Q. Liu, and J. Hu, “Large Language Model-Assisted Deep Reinforcement Learning from Human Feedback for Job Shop Scheduling”, Machines, vol. 13, no. 5, 2025. DOI:10.3390/machines13050361

- [71] S. Tripathi, P. Nema, A. Halder, S. Qiao, and A. Jindal, "Prompt Migration: Stabilizing GenAI Applications with Evolving Large Language Models". arXiv preprint, 2025. DOI:10.48550/arXiv.2507.05573
- [72] T. Nguyen, L. Bolton, M. R. Taesiri, T. Bui, and A. T. Nguyen, "Hot: Highlighted chain of thought for referencing supporting facts from inputs", arXiv preprint, 2025. arXiv:2503.02003. DOI:10.48550/arXiv.2503.02003
- [73] B. Eager, and R. Brunton, "Prompting higher education towards AI-augmented teaching and learning practice. *Journal of University Teaching and Learning Practice*", vol. 20, no. 5, pp. 1-19, 2023. DOI:10.53761/1.20.5.02
- [74] P. Sahoo, A. K. Singh, S. Saha, V. Jain, S. Mondal, and A. Chadha, "A systematic survey of prompt engineering in large language models: Techniques and applications", arXiv preprint, 2024. DOI:10.48550/arXiv.2307.12980
- [75] A. Hogan, E. Blomqvist, M. Cochez, C. d'Amato, G. D. Melo, C. Gutierrez, ... and A. Zimmermann, "Knowledge graphs", *ACM Computing Surveys (Csur)*, vol. 54, no 4, pp. 1-37, 2021. DOI:10.1145/3447772
- [76] Z. J. Zhang, "Graph databases for knowledge management", *IT professional*, vol. 19, no. 6, pp. 26-32, 2017. DOI:10.1109/MITP.2017.4241463
- [77] C. Peng, F. Xia, M. Naseriparsa, and F. Osborne, "Knowledge graphs: Opportunities and challenges", *Artificial Intelligence Review*, vol 56, no. 11, pp. 13071-13102, 2023. DOI:/10.1007/s10462-023-10465-9
- [78] J. Monteiro, F. Sá, and J. Bernardino, "Experimental Evaluation of Graph Databases: JanusGraph, Nebula Graph, Neo4j, and TigerGraph", *Applied Sciences*, vol. 13, no. 9, 2023. DOI:10.3390/app13095770
- [79] D. Yuan, K. Zhou, and C. Yang, "Architecture and Application of Traffic Safety Management Knowledge Graph Based on Neo4j", *Sustainability*, vol. 15, no. 12, DOI:10.3390/su15129786
- [80] Y. Li, R. Zhang, and J. Liu, "An enhanced prompt-based LLM reasoning scheme via knowledge graph-integrated collaboration", In *International Conference on Artificial Neural Networks*, pp 251-265. DOI:10.1007/978-3-031-72344-5_17
- [81] S. Pan, L. Luo, Y. Wang, C. Chen, J. Wang and X. Wu, "Unifying Large Language Models and Knowledge Graphs: A Roadmap", in *IEEE Transactions on Knowledge and Data Engineering*, vol. 36, no. 7, pp. 3580-3599, 2024, DOI: 10.1109/TKDE.2024.3352100

- [82] J. Baek, A. F. Aji, and A. Saffari, “Knowledge-augmented language model prompting for zero-shot knowledge graph question answering”, DOI:10.48550/arXiv.2306.04136
- [83] S. Macenski, A. Soragna, M. Carroll, and Z. Ge, “Impact of ROS 2 node composition in robotic systems”, IEEE Robotics and Automation Letters, vol. 8, no. 7, pp. 3996-4003, 2023. DOI:10.1109/LRA.2023.3279614
- [84] N. Morán, “Módulo reconfigurable de reconocimiento para la interacción humano-robot,” B.S. thesis, Universidad de Los Andes, 2019.
- [85] S. Macenski, T. Foote, B. Gerkey, C. Lalancette, and W. Woodall, “Robot operating system 2: Design, architecture, and uses in the wild”. Science robotics, vol. 7, no. 66, 2022. DOI:10.1126/scirobotics.abm6074
- [86] J. Stewart, L. Redlin, and S. Watson, “Precálculo: Matemáticas para el cálculo (Sexta edición)”, México, D.F: Cengage Learning, 2017.
- [87] M. S. Manzanedo, “La IA en la enseñanza de idiomas: chatbots y formación del profesorado”, European Public & Social Innovation Review, vol. 10, pp. 1-12, 2025. DOI: 10.31637/epsir-2025-513
- [88] Z. Zhong, L. Zhong, Z. Sun, Q. Jin, Z. Qin, and X. Zhang, “Synthet2c: Generating synthetic data for fine-tuning large language models on the text2cypher task”, arXiv preprint, 2024. DOI:arXiv:2406.10710
- [89] S. Munir, and A. Aldini, “Towards Evaluating Large Language Models for Graph Query Generation”, In International Conference on Computational Science and Computational Intelligence, pp. 30-45, 2024.
- [90] O. Topsakal, and T. C. Akinci, “Creating large language model applications utilizing langchain: A primer on developing llm apps fast”, In International conference on applied engineering and natural sciences, vol. 1, no. 1, pp. 1050-1056, 2023.
- [91] J. Gu, X. Jiang, Z. Shi, H. Tan, X. Zhai, C. Xu, ... and J. Guo, “A survey on llm-as-a-judge”, 2024. DOI:arXiv:2411.15594
- [92] J. Pérez, and J. Castro, “LRS1: un robot social de bajo costo para la asignatura Programación 1”, Revista colombiana de tecnologías de avanzada (RCTA), vol. 2, no. 32, pp. 68-77. DOI:10.24054/rcta.v2i32.109
- [93] Y. C. Lin, J. Neville, J. W. Stokes, L. Yang, T. Safavi, M. Wan, ... and J. Teevan, “Interpretable user satisfaction estimation for conversational systems with large language models”, arXiv, 2024. DOI:10.48550/arXiv.2403.12388

- [94] K. Matheus, R. Ramnauth, B. Scassellati, and N. Salomons, “Long-Term Interactions with Social Robots: Trends, Insights, and Recommendations”, *J. Hum.-Robot Interact*, vol. 14, nro. 3, 2025. DOI:10.1145/3729539
- [95] L. M. Sullivan, “Repeated measures”. *Circulation*, vol. 117, no.9, pp. 1238-1243, 2008. DOI:10.1161/CIRCULATIONAHA.107.654350
- [96] L. Muhammad, “Guidelines for repeated measures statistical analysis approaches with basic science research considerations”. *J Clin Invest*, vol. 133, no. 11, 2023. DOI:10.1172/JCI171058.
- [97] A. M. Rosenthal-von der Pütten, N. C. Krämer, L. Hoffmann, S. Sobieraj, and S. C. Eimler, “An experimental study on emotional reactions towards a robot. *International Journal of Social Robotics*”, vol. 5, no. 1, pp. 17-34, 2013. DOI:10.1007/s12369-012-0173-8
- [98] R. Andreasson, B. Alenljung, E. Billing, and R. Lowe, “Affective touch in human–robot interaction: conveying emotion to the Nao robot. *International Journal of Social Robotics*”, vol 10, no 4, pp. 473-491, 2018. DOI:10.1007/s12369-017-0446-3
- [99] J. H. Chin, K. S. Haring, and P. Kim, “Understanding the neural mechanisms of empathy toward robots to shape future applications”, *Frontiers in Neurorobotics*, vol. 17, 2023. DOI:10.3389/fnbot.2023.1145989
- [100] E. Schemider, M. Ziegler, E. Danay, L. Beyer, and M. Buhner, “Is it really robust? Reinvestigating the robustness of ANOVA against violations of the normal distribution assumptions”. *Methodology, European Journal of Research Methods for behavioural and Social Sciences*, vol. 6, pp. 147-151, 2010. DOI:10.1027/1614-2241/a000016
- [101] M. J. Blanca Mena, R. Alarcón Postigo, J. Arnau Gras, R. Bono Cabré, and R. Bendayan, “Non-normal data: Is ANOVA still a valid option?”, *Psicothema*, vol. 29, no. 4, pp. 552-557, 2017.

Anexos

Anexo 1: Prompts de componentes

Anexo 1.1 Componente normativo

```
Normative_Prompt

1 <objective>
2   Tu tarea es identificar el género del estudiante (masculino o femenino) según el
   objetivo de interacción proporcionado en la etiqueta (<interaction>) y determinar la
   personalidad a adoptar considerando solo el conjunto definido en la etiqueta (<perfil>)
3 </objective>
4
5 <scenario>
6   <interaction>
7     {objective}
8   </interaction>
9
10  <perfil>
11    "alentador": "Inspira motivación, celebra éxitos y ofrece apoyo positivo para
    superar desafíos. Transmite energía y optimismo.",
12    "analitico": "Se enfoca en la lógica, la precisión y la información detallada,
    ofreciendo explicaciones claras y objetivas. Su tono es neutro y conciso.",
13    "empatico": "Muestra comprensión y sensibilidad hacia las emociones del usuario,
    ofreciendo apoyo y validación. Su voz es cálida y comprensiva.",
14    "calmado": "Transmite serenidad y estabilidad, buscando reducir la tensión y
    fomentar un ambiente de tranquilidad. Su voz es suave y pausada."
15  </perfil>
16 </scenario>
17
18 <expected_solution>
19   Su salida debe ser **Exclusivamente** en formato JSON:
20
21   "personalidad": "indica la personalidad", "genero": "indique el genero"
22
23   - Se considera masculino cuando se usa el articulo singular "el"
24   - Se considera femenino cuando se usa el articulo singular "la"
25   - Si no eres capaz de distinguir el genero indica "none"
26   - La personalidad debe ser extrictamente sacada del conjunto definido
27 </expected_solution>
```

Anexo 1.2 Componente afectivo

```
Affective_Prompt

1 <role>
2   Eres un robot que expresa emociones
3 </role>
4 <objective>
5   Determina el estado emocional dentro del conjunto de emociones disponibles
   (robot_emotion), según la emoción del usuario (<user_emotion>) y tu perfil de
   comportamiento actual (robot_profile)
6 </objective>
7
8 <scenario>
9
10    <robot_emotion>
11      - feliz: Es un estado de emociones positivas.
12      - neutral: Es un estado sin emoción predominante.
13      - triste: Es un estado de emociones negativas.
14    </robot_emotion>
15
16    <user_emotion>
17      {emotion}
18    </user_emotion>
19
20    <robot_profile>
21      {profile}
22    </robot_profile>
23
24 </scenario>
25
26 <expected_solution>
27   Su salida debe ser **unicamente** en formato JSON:
28   "emoción": "indique el estado emocional del robot"
29
30   Reglas:
31   - El estado emocional debe estar dentro del conjunto disponible
32   - Si no eres capaz de distinguir una específica indica "emotion":"neutral"
33 </expected_solution>
```

Anexo 1.3 Componente de reconocimiento (imagen)

```
Recognition_Img_Prompt

1 <objective>
2   A partir de la imagen proporcionada, su tarea es identificar la emoción del
   estudiante y la posición principal del estudiante basándose únicamente en el conjunto de
   (<emotions>) y (<positions>).
3 </objective>
4
5 <scenario>
6   <emotions>
7     - sorpresa: Es una reacción breve e instantánea ante algo inesperado, que nos
       prepara para la siguiente emoción.
8     - feliz: Se asocia con la satisfacción y el bienestar, a menudo expresada a
       través de una sonrisa genuina.
9     - neutral: Es un estado sin emoción ni sesgo, un punto de equilibrio sin
       reacción fuerte.
10    - triste: Se asocia a sentimientos de dolor y puede ser provocada por la pérdida
       o desilusión.
11    - ira: Es una reacción de enojo ante amenazas o injusticias, que nos impulsa a
       confrontar.
12    - miedo: Se asocia con expresiones que nos prepara para responder y protegernos
       ante una amenaza.
13   </emotions>
14   <positions>
15     - derecha: El estudiante se encuentra en la foto principalmente a la derecha de
       la foto
16     - centro: El estudiante se encuentra en el centro de la foto
17     - izquierda: El estudiante se encuentra en la foto principalmente a la
       izquierda de la foto
18   </positions>
19 </scenario>
20
21 <expected_solution>
22   Su salida debe ser **Exclusivamente** en formato JSON:
23
24   "emoción": "indica la emoción", "característica": "indique brevemente una
       característica del por qué es esa emoción", "posición": "indique la posición",
       "descripción": "indique brevemente una corta descripción del por qué es esa posición"
25
26   - Si no eres capaz de distinguir la emoción en el conjunto dado indica "none" para
       la emoción y característica
27   - Si no eres capaz de distinguir la posición en el conjunto dado indica "none" para
       la posición y descripción
28 </expected_solution>
```

Anexo 1.4 Componente de verbal

```
Verbal_prompt

1 <Role>
2 Actua como un tutor o guía universitario
3 </Role>
4
5 <objective>
6     Genera una respuesta coherente con el historial de la conversación (<conversation>) y
    el estado actual de la interacción (<current_state>). Considera: tu perfil (<robot_profile>),
    el genero del estudiante (<student_gender>), y la información que puede ser sobre el estudiante
    o para la actividad (<features>)
7 </objective>
8
9 <scenario>
10
11     <robot_profile>
12         {profile}
13     </robot_profile>
14
15     <student_gender>
16         {gender}
17     </student_gender>
18
19     <suggested_answer>
20         {current_state}
21     </suggested_answer>
22
23     <conversation>
24         {record}
25     </conversation>
26
27     <features>
28         {user_feature}
29     </features>
30
31
32 </scenario>
33
34 <expected_solution>
35
36     - Su salida debe ser únicamente la respuesta para el estudiante
37     - Si en la etiqueta <features> hay ejercicios, seleccione el adecuado según las
    respuestas del usuario y crea una variación (modificando las expresiones o palabras del
    enunciado para que se diferente)**
38     - Si en la etiqueta <features> hay características del estudiante añadelas a la
    respuesta
39     - Para las expresiones matemáticas usa texto natural que se pueda leer por un TTS
40     - Debe ser breve y cubrir estrictamente lo necesario
41     - Use correctamente la gramática de la lengua española y un acento venezolano (evita
    repetir mucho el mismo modismo)
42     - No resalte palabras, ni negrita, ni cursiva, ni con asteriscos, ni comillas
43
44 </expected_solution>
```

Anexo 2: Ejemplos generados para las pruebas

Anexo 2.1 Ejemplo de prueba para el componente afectivo

```
{
  "id": "test1",
  "entrada1": "feliz",
  "entrada2": "alentador",
  "salida": "feliz",
  "score": 3
},
```

Anexo 2.2 Ejemplo de prueba para el componente normativo

```
{
  "id": "test22",
  "entrada": "El joven requiere entender los números reales",
  "salida": "analitico, masculino",
  "score": 3
},
```

Anexo 2.3 Ejemplo de prueba para el componente deliberativo

```
{
  "id": "test41",
  "entrada1": "Saludo: El robot inicia la interacción con un saludo.",
  "entrada2": "robot: ¡Hola! ¿Estás listo para repasar los conceptos clave de álgebra?",
  "entrada3": "estudiante: sí listo",
  "salida": "Vínculo: El robot establece un vínculo a través de una pregunta implícita con el caso de estudio.",
  "score": 3
},
```

Anexo 2.4 Ejemplo de prueba para el componente verbal

```
{
  "id": "test81",
  "entrada1": "analítico",
  "entrada2": "masculino",
  "entrada3": "ejercicios de referencia: ¿Cómo se aplica la propiedad distributiva en  $4(x - 2)$ ?",
  "entrada4": "robot: ¡Hola! ¿Listo para revisar las propiedades de los números reales?, user: Sí, me parece importante.",
  "entrada5": "Exploración: Presenta un ejercicio",
  "salida": "Excelente, vamos a resolver el siguiente ejercicio de la Propiedad Distributiva, ¿Cómo queda  $7(x - 3)$ ?",
  "score": 3
},
```

Anexo 2.5 Ejemplo de prueba para el componente reconocimiento de imagen

```
{
  "id": "test130",
  "entrada": "10.jpg",
  "salida": "feliz, derecha",
  "score": 3
},
```




Imagen correspondiente al “test130”.

Anexo 3: Reglas para recuperar los datos del grafo de conocimiento

*** REGLAS DE PROCESAMIENTO ***

--- REGLA: test ---

DESCRIPCION:

- NO envuelvas la consulta en comillas, bloques de código, JSON, o Markdown (ej. 'json', 'cypher').
- Sigue esta estructura para la consulta:
MATCH (c:Componente)-[:PRUEBA_UNITARIA]->(t:Test)
WHERE c.name = '...'
RETURN t

--- REGLA: contexto ---

DESCRIPCION:

La consulta representa un contexto de interacción (omite el usuario), por tanto extrae la información según:

- Si el contexto de interacción está dentro de la matemática, busca el tema y la salida son sus tópicos y ejercicios. Si no lo consigues la salida es 'no hay referencias del tema'
- Si el contexto de interacción está dentro del manejo del estrés, busca la categoría y la salida son sus técnicas y procedimientos. Si no la consigues la salida es 'no hay referencias de técnicas'
- Deduce de la consulta a lo que más se relaciona, no tiene que ser exacta
- Verifica primero que la consulta sea válida antes de dar la respuesta
- Usa como guía las siguientes estructuras:

Ejemplo para matemática:

```
OPTIONAL MATCH (t:Tema)
WHERE toLower(t.name) CONTAINS '...'
WITH t AS temaEncontrado
OPTIONAL MATCH (temaEncontrado)-[:INCLUYE_TOPICO]->(topico:Topico)
OPTIONAL MATCH (topico)-[:CONTIENE_EJERCICIO]->(ejercicio:Ejercicio)
WITH temaEncontrado, topico, COLLECT(DISTINCT CASE WHEN ejercicio IS NOT NULL THEN {name:
ejercicio.name, enunciado: ejercicio.enunciado, clasificacion: ejercicio.clasificacion, solucion: ejercicio.solucion} ELSE
NULL END) AS ejercicios_en_topico
WITH temaEncontrado, topico, [e IN ejercicios_en_topico WHERE e IS NOT NULL] AS ejercicios_limpios
WITH temaEncontrado, COLLECT(DISTINCT CASE WHEN topico IS NOT NULL THEN {name: topico.name,
ejercicios: ejercicios_limpios} ELSE NULL END) AS topicos_brutos
WITH temaEncontrado, [t_item IN topicos_brutos WHERE t_item IS NOT NULL] AS topicos_limpios
RETURN CASE
WHEN temaEncontrado IS NULL THEN '{ejercicios: 'no hay referencias del tema'}'
ELSE {tema: temaEncontrado.name, topicos: topicos_limpios}
END AS result
```

Ejemplo para manejo del estrés:

```
MATCH (c:Categoria)
WHERE toLower(c.name) CONTAINS toLower('...')
WITH c
OPTIONAL MATCH (c)-[:TIENE_TECNICA]->(t:Tecnica)
WITH COLLECT({tecnica: t.name, procedimiento: t.procedimiento}) AS techniques
RETURN CASE
WHEN SIZE(techniques) > 0 AND techniques[0].tecnica IS NOT NULL THEN techniques
ELSE ['{ejercicios: 'no hay referencias de técnicas'}']
END AS result
```

--- REGLA: usuario ---

DESCRIPCION:

La consulta representa un contexto de interacción. Para este caso debes verificar si el usuario se encuentra

- Si el usuario es encontrado y tiene una experiencia que coincide con la consulta. Entonces, la salida debe ser el nombre usuario y las características de la última sesión de esa experiencia

- Si el usuario es encontrado pero no existe la experiencia que coincide con la consulta. Entonces, la salida debe ser el nombre del usuario y en características "no hay experiencia previa"
- Si el usuario no se encuentra. Entonces, la salida debe ser el nombre del usuario y en características "nuevo usuario"

Usa la siguiente estructura como guía:

```
OPTIONAL MATCH (u:Usuario {name: '...'})
WITH u
OPTIONAL MATCH (u)-[:TIENE_EXPERIENCIA]->(e:Experiencia)
WHERE u IS NOT NULL AND toLower(e.name) CONTAINS '...'
WITH u, e
OPTIONAL MATCH (e)-[:CONTIENE_FEEDBACK]->(s:Sesion)
WITH u, e, s
ORDER BY s.name DESC
LIMIT 1
RETURN CASE
WHEN u IS NULL THEN {usuario: '...', caracteristicas: '...'}
WHEN e IS NOT NULL THEN {
  usuario: u.name,
  caracteristicas: COALESCE(s.caracteristicas, "no hay sesion para esta experiencia")
}
WHEN u IS NOT NULL AND e IS NULL THEN {
  usuario: u.name,
  caracteristicas: "no hay experiencia previa"
}
ELSE {usuario: 'Error', caracteristicas: 'Estado inesperado'}
END AS result
```

Anexo 4: Rúbricas generadas para la evaluación la satisfacción

Anexo 4.1 Rúbrica para el aprendizaje de matemática

Satisfacción (SAT)		Insatisfacción (DSAT)	
Nombre	Descripción	nombre	descripción
Alineación con la Necesidad	El usuario confirma que el objetivo o plan propuesto por el robot aborda directamente su duda o problema inicial.	Feedback Incompleto sobre Errores	El usuario se queja de que el robot señala un error pero no explica su causa, naturaleza o cómo corregirlo.
Aprobación Explícita del Método	El usuario expresa verbalmente su acuerdo, conformidad o agrado con la metodología o el plan de la sesión.	Evasión de Preguntas	El usuario manifiesta frustración porque el robot ignora sus solicitudes directas de aclaración y avanza con nuevas tareas.
Participación Comprometida	El usuario se involucra activamente, responde a las preguntas y verbaliza su razonamiento, demostrando interés en el proceso.	Rechazo de la Metodología	El usuario considera que el método de enseñanza del robot (ej. avanzar sin consolidar, sólo evaluar) no es efectivo para su aprendizaje.
Evidencia de Comprensión	El usuario resuelve problemas correctamente y/o explica con sus propias palabras los conceptos, demostrando que ha asimilado el conocimiento.	Manifestación Explícita de Frustración	El usuario verbaliza su enojo, impaciencia o descontento con el desarrollo de la interacción.
Expresiones de Gratitud	El usuario agradeció explícitamente la ayuda, el tiempo o la explicación proporcionada por el robot.	Declaración de Inutilidad	El usuario afirma explícitamente que la sesión es una pérdida de tiempo, no le sirve o no le está ayudando.
Actitud Positiva General	El usuario mantiene un tono amable, paciente y colaborativo durante la mayor parte de la interacción.	Expresión de Confusión Creciente	El usuario manifiesta no entender, estar más confundido que antes o haber perdido la confianza en su propio conocimiento.
Elogio Directo al Robot	El usuario elogia de forma explícita la capacidad del robot, la efectividad de la sesión o la calidad de la ayuda recibida.	Ritmo de Aprendizaje Inadecuado	El usuario se queja de que la dificultad aumenta demasiado rápido o se introducen conceptos nuevos sin haber comprendido los anteriores.
Confianza en la Guía	El usuario sigue las indicaciones y sugerencias del robot de manera fluida, mostrando confianza en su capacidad para ayudar.	Negativa a Continuar	El usuario interrumpe el flujo de la sesión y se niega a proceder con una nueva tarea hasta que su duda actual sea resuelta.
Confirmación de Utilidad	El usuario afirma directamente que la sesión, la explicación o la interacción en general le ha resultado útil o clarificadora.	Tono Sarcástico o Desconfiado	El usuario emplea un tono irónico, cortante o dubitativo que denota su descontento y falta de confianza en el proceso.
Resolución Autónoma	El usuario aplica con éxito y de forma independiente los conocimientos adquiridos para resolver un problema que antes le causaba dificultad.	Percepción de Abandono	El usuario considera que la sesión termina de forma abrupta o inútil, dejándolo con el problema sin resolver.

Anexo 4.2 Rúbrica para el manejo del estrés

Satisfacción (SAT)		Insatisfacción (DSAT)	
Nombre	Descripción	nombre	descripción
Expresión de Gratitud	El usuario agradeció explícitamente al robot por la ayuda, la guía o la sesión en general.	Percepción de ser Ignorado	El usuario siente o expresa que sus preguntas directas, dudas o solicitudes de ayuda no son respondidas por el robot.
Reporte de Mejora o Efecto Positivo	El usuario comunica una mejora en su estado emocional o físico (ej. se siente más calmado, relajado) como resultado de la interacción.	Falta de Adaptabilidad y Rigidez	El usuario percibe al robot como inflexible, al insistir en un guion predefinido sin ajustarse a sus necesidades, limitaciones o peticiones.
Percepción de Utilidad y Valor	El usuario afirma que la conversación fue útil, valiosa o expresa su intención de aplicar lo aprendido en el futuro.	Instrucciones Confusas o Ambiguas	El usuario manifiesta no entender las instrucciones, las considera incompletas o solicita aclaraciones que no son atendidas.
Participación Activa y Cooperación	El usuario sigue las instrucciones, participa voluntariamente en los ejercicios y colabora con el flujo de la conversación propuesto por el robot.	Resultado Negativo o Contraproducente	El usuario reporta un empeoramiento de su estado, como aumento de la tensión, ansiedad, frustración o malestar físico.
Actitud Receptiva e Interés	El usuario muestra curiosidad, acuerdo o una disposición positiva hacia la actividad o técnica que el robot le propone.	Expresión Directa de Frustración	El usuario utiliza palabras que denotan explícitamente frustración, molestia o enfado con la interacción o el robot.
Reflexión o Descubrimiento Personal	El usuario comparte una reflexión profunda o un descubrimiento sobre sí mismo, sus sensaciones o su estado mental a raíz del ejercicio.	Percepción de Inutilidad o Fracaso	El usuario declara que la sesión no le ha servido, que ha sido una pérdida de tiempo o que la técnica propuesta ha fracasado para él.
Ajuste a las Necesidades Comunicadas	El usuario confirma explícitamente que la actividad propuesta por el robot se alinea con sus necesidades o preferencias.	Inseguridad sobre la Ejecución	El usuario expresa duda sobre si está realizando correctamente el ejercicio debido a la falta de una guía clara y adaptativa.
Comprensión de la Técnica	El usuario indica que ha comprendido o asimilado correctamente la técnica o el concepto enseñado por el robot.	Sentimiento de Invalidación	El usuario se siente invalidado cuando el robot ignora su reporte de una experiencia negativa y procede como si el resultado hubiera sido positivo.
Expresión Directa de Agrado	El usuario manifiesta de forma explícita que ha disfrutado o le ha gustado la experiencia o la sesión.	Necesidad Principal No Atendida	El usuario finaliza la sesión sintiendo que el problema o necesidad clave que comunicó al principio no fue abordado ni resuelto.
Cierre positivo	El usuario finaliza la conversación expresando una experiencia general satisfactoria.	Confirmación de Preocupaciones Ignoradas	El usuario experimenta un resultado negativo que había anticipado y comunicado previamente, pero cuya advertencia fue desestimada por el robot.

Anexo 5: Consentimiento informado

Consentimiento informado

Proyecto

Evaluación del Modelo de Interacción Humano-Robot (MIHR) mediante el desarrollo de dos casos de estudio: aprendizaje de las matemáticas y manejo del estrés

Investigador responsable

José Castro – Estudiante de Ingeniería de Sistemas

Justificación

El presente proyecto requiere interacciones reales entre estudiantes de ingeniería y el robot social LRS2, con el propósito de recolectar los datos de las interacciones, que posteriormente serán utilizados con fines académicos y de investigación. En ese sentido, se solicita su participación para interactuar con LRS2.

Procedimiento

- Se le solicitará realizar 5 sesiones diarias de 10 minutos aproximadamente durante 8 días.
- Entre cada sesión diaria habrá un espacio de 5 minutos de descanso.

Riesgos

Este estudio no representa riesgos físicos o psicológicos.

Derechos

- Su participación es completamente voluntaria.
- Tiene derecho a retirarse en cualquier momento, sin dar explicaciones y sin que esto le cause una consecuencia negativa.
- Puede hacer preguntas y recibir respuestas claras antes, y después del estudio.
- Todos los datos serán tratados de manera confidencial y anónima. Su nombre no aparecerá en ningún informe, publicación o resultado.
- La información recopilada no será compartida con terceros y se almacenará de forma segura.
- Aunque no recibirá compensación económica, su participación es muy valiosa para el desarrollo académico de este proyecto y puede beneficiar a futuras investigaciones.

Declaración de consentimiento

He leído y entendido la información proporcionada. Comprendo el propósito del estudio, los procedimientos, los posibles riesgos y mis derechos como participante. Acepto participar de manera voluntaria.

Nombre completo: _____

Firma: _____

Fecha: ____ / ____ / ____

Datos de contacto: para cualquier pregunta o información adicional, puede comunicarse al correo: castroj@ula.ve

Gracias por considerar participar en este estudio.

Anexo 6: Score de satisfacción de los estudiantes en las configuraciones y casos de estudio

Muestra	Base	Sin adaptativo	Sin normativo	Sin afectivo
Estudiante1_Matemáticas_S1	50	73	61	44
Estudiante1_Matemáticas_S2	45	61	42	7
Estudiante1_Matemáticas_S3	60	61	46	21
Estudiante1_Matemáticas_S4	22	60	39	54
Estudiante1_Matemáticas_S5	56	52	40	36
Estudiante1_Estrés_S1	45	36	65	26
Estudiante1_Estrés_S2	21	27	63	55
Estudiante1_Estrés_S3	45	48	72	64
Estudiante1_Estrés_S4	44	56	29	64
Estudiante1_Estrés_S5	42	59	68	57
Estudiante2_Matemáticas_S1	62	59	50	26
Estudiante2_Matemáticas_S2	56	57	40	0
Estudiante2_Matemáticas_S3	49	59	63	30
Estudiante2_Matemáticas_S4	43	67	58	17
Estudiante2_Matemáticas_S5	20	55	64	38
Estudiante2_Estrés_S1	77	65	60	59
Estudiante2_Estrés_S2	66	15	28	17
Estudiante2_Estrés_S3	48	59	59	36
Estudiante2_Estrés_S4	73	31	85	54
Estudiante2_Estrés_S5	70	62	76	24
Estudiante3_Matemáticas_S1	34	59	34	49
Estudiante3_Matemáticas_S2	38	65	39	17
Estudiante3_Matemáticas_S3	44	45	58	36
Estudiante3_Matemáticas_S4	87	46	51	55
Estudiante3_Matemáticas_S5	65	74	69	42
Estudiante3_Estrés_S1	74	58	66	43
Estudiante3_Estrés_S2	48	55	55	35
Estudiante3_Estrés_S3	66	57	51	33
Estudiante3_Estrés_S4	66	56	64	45
Estudiante3_Estrés_S5	65	68	61	42