



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES**

TITULO DEL TRABAJO DE TITULACIÓN

Sistema de clasificación de prompts evasivos y seguros usando
procesamiento de lenguaje natural supervisado.

AUTOR

Gonzabay Floreano, Karen Zully

EXAMEN COMPLEXIVO

Previo a la obtención del grado académico en
INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN

TUTOR

Ing. Rosero Vásquez, Shendry Balmore, Msc.C.

Santa Elena, Ecuador

Año 2026




**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES**


TRIBUNAL DE SUSTENTACIÓN



Ing. José Sánchez Aquino Mgtr.
DIRECTOR DE LA CARRERA



Ing. Shendry Rosero Vázquez. Mgtr.
TUTOR



Lsi. Daniel Quirumbay Yagual. Mgtr.
DOCENTE ESPECIALISTA



Ing. Marjorie Coronel Suárez. Mgtr.
DOCENTE GUÍA UIC



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES**

CERTIFICACIÓN

Certifico que luego de haber dirigido científica y técnicamente el desarrollo y estructura final del trabajo, este cumple y se ajusta a los estándares académicos, razón por el cual apruebo en todas sus partes el presente trabajo de titulación que fue realizado en su totalidad por Gonzabay Floreano Karen Zully, como requerimiento para la obtención del título de Ingeniero en Tecnologías de la Información.

La Libertad, a los 16 días del mes de Julio del año 2026

TUTOR

**Shendry
Rosero**

Firmado digitalmente
por Shendry Rosero
DN: cn=Shendry Rosero
gn=Shendry Rosero c=ES
Spain I=ES Spain
e=shendry.rosero.v@gmail.com
Motivo: Soy el autor de este
documento
Ubicación:
Fecha: 2026-07-17 15:17:05.00

Ing. Shendry Rosero V. Msc.C.



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES**

DECLARACIÓN DE RESPONSABILIDAD

Yo, GONZABAY FLOREANO KAREN ZULLY

DECLARO QUE:

El trabajo de Titulación, Sistema de clasificación de prompts evasivos y seguros usando procesamiento de lenguaje natural supervisado. previo a la obtención del título en Ingeniero en Tecnologías de la Información, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

La Libertad, a los 16 días del mes de Julio del año 2026

EL AUTOR

Gonzabay Floreano Karen Zully



UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA

FACULTAD DE SISTEMAS Y TELECOMUNICACIONES

CERTIFICACIÓN DE ANTIPLAGIO

Certifico que después de revisar el documento final del trabajo de titulación denominado **Sistema de clasificación de prompts evasivos y seguros usando procesamiento de lenguaje natural supervisado**, presentado por el estudiante, GONZABAY FLOREANO KAREN ZULLY fue enviado al Sistema Antiplagio, presentando un porcentaje de similitud correspondiente al 9%, por lo que se aprueba el trabajo para que continúe con el proceso de titulación.



Certificado de análisis
Compilatio Studium

GONZABAY_FLOREANO_KAREN_ZULLY_MODALIDAD_COMPLEXIVO

ID : 059353261f6ae912fc006bb97eb14eb64a30415f



9%

Textos sospechosos

Nombre del fichero :

GONZABAY_FLOREANO_KAREN_ZULLY_MODALIDAD_COMPLEXIVO.txt

Tamaño del archivo original : 4,13 MB

Número de palabras : 14.236

Depositante : karen gonzabay

Fecha de depósito : 14 de julio de 2026

Tipo de carga : interface

fecha de fin de análisis : 14 de julio de 2026

TUTOR

Shendr
y
Rosero

Firmado digitalmente
por Shendry Rosero
DN: cn=Shendry Rosero,
gn=Shendry Rosero c=ES,
Spain, o=ES, Spain,
e=shendry.rosero.vi@gmail.co
m
Motivo Soy el autor de este
documento
Ubicación:
Fecha: 2026-07-17
15:17:05.00

Ing. Shendry Rosero V. Msc.C.



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES**

AUTORIZACIÓN

Yo, Gonzabay Floreano Karen Zully

Autorizo a la Universidad Estatal Península de Santa Elena, para que haga de este trabajo de titulación o parte de él, un documento disponible para su lectura consulta y procesos de investigación, según las normas de la Institución.

Cedo los derechos en línea patrimoniales del presente trabajo de titulación con fines de difusión pública, además apruebo la reproducción dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor

Santa Elena, a los 16 días del mes de julio del año 2026

EL AUTOR

Karen Gonzabay

Gonzabay Floreano Karen Zully

AGRADECIMIENTO

Quiero expresar mi agradecimiento a Dios por darme la sabiduría, constancia y claridad de pensamientos necesarios para culminar este proceso académico.

Agradecer a la Universidad Estatal Península de Santa Elena por abrirme sus puertas. A sus docentes por brindarme los conocimientos que sustentan la culminación de este proyecto con compromiso y profesionalismo.

A mi familia por ser la base de mi desarrollo personal y por su apoyo incondicional durante esta etapa.

Karen Zully, Gonzabay Floreano

DEDICATORIA

Dedico este logro a mi pareja Luis Vásquez, quien con su amor incondicional y su apoyo ha sido mi sostén a lo largo de este camino. Gracias por creer en mí y por nunca dejarme sola en este proceso de mis estudios. Y a mi hijo Aaron Perero, quien sin saberlo se convirtió en mi mayor razón para seguir adelante y no rendirme jamás.

A mis padres Jaime Gonzabay y Martha Floreano, quienes en cada momento de dificultad extendieron su mano y su corazón para brindarme el apoyo que necesitaba. Su amor y su presencia han sido fundamentales en mi vida y en mi crecimiento personal.

A la señora Emilia Suárez, una persona especial que en el momento indicado sembró en mí las palabras y el impulso necesario para no detenerme, para no quedarme estancada y para creer que siempre es posible seguir superándome.

Karen Zully, Gonzabay Floreano

ÍNDICE GENERAL

TRIBUNAL DE SUSTENTACIÓN	II
CERTIFICACIÓN	III
DECLARACIÓN DE RESPONSABILIDAD	IV
CERTIFICACIÓN DE ANTIPLAGIO	V
AUTORIZACIÓN	VI
AGRADECIMIENTO	VII
DEDICATORIA	VIII
ÍNDICE GENERAL	IX
ÍNDICE DE TABLAS	XII
ÍNDICE DE FIGURAS	XII
RESUMEN	XIV
ABSTRACT	XVI
INTRODUCCIÓN	1
CAPÍTULO 1. FUNDAMENTACIÓN	2
1.1. Antecedentes	2
1.2. Descripción del Proyecto	4
1.3. Objetivos del Proyecto	8
1.3.1. Objetivo General	8
1.3.2. Objetivos Especifico	8
1.4. Justificación del Proyecto	8
1.5. Alcance del Proyecto	10
CAPÍTULO 2. MARCO TEÓRICO Y METODOLOGÍA DEL PROYECTO	12
2.1 Marco Conceptual	12

2.1.1. Inteligencia Artificial	12
2.1.2. Procesamiento de Lenguaje Natural	12
2.1.3. Prompts Evasivos	12
2.1.4. Clasificación de Texto	13
2.1.5. Modelos de Clasificación	13
2.1.5.1. SVM	13
2.1.5.2. BERT	13
2.1.5.3. RoBERTA	14
2.1.6. Procesamiento de Datos	14
2.1.6.1. Tokenización	14
2.1.6.2. <i>Embedding</i>	15
2.1.6.3. <i>Oversampling</i>	15
2.1.7. Métricas de Evaluación	15
2.1.7.1. Precisión	16
2.1.7.2. Recall	16
2.1.7.3. <u>F1</u> -Score	16
2.1.7.4. PR-AUC	16
2.1.7.5. Matriz de confusión	17
2.2. Herramientas y Tecnologías	17
2.2. Marco Teórico	19
2.2.1. Detección de ataques de inyección de prompts en modelos de lenguaje	19
2.2.2. Generación, detección y evaluación de ataques de jailbreak basados en juegos de rol en modelos de lenguaje a gran escala	20
2.2.3. Defensas contra Prompt Injection y Jailbreak en LLM	20

2.3. Metodología del Proyecto	21
2.3.1. Metodología de investigación	21
2.3.2. Técnicas e instrumentos de recolección de datos	22
2.3.3. Análisis de Recolección de datos	23
2.3.4. Metodología de Desarrollo	24
CAPÍTULO 3. PROPUESTA	27
3.1. Fase 1: Comprensión del Problema.	27
3.2. Fase 2: Comprensión de los Datos	27
3.3. Fase 3: Preparación de los Datos	30
3.4. Fase 4: Modelado	34
3.5. Fase 5: Evaluación	39
3.6. Fase 6: Despliegue	45
CONCLUSIONES	53
RECOMENDACIONES	54
REFERENCIAS	56
ANEXOS	63

ÍNDICE DE TABLAS

Tabla 1: Resumen cronológico del procesamiento del dataset.	32
Tabla 2: Configuración experimental y entorno de ejecución de los modelos.	36
Tabla 3: Métricas obtenidas de los modelos.	46
Tabla 4: Entorno de ejecución y principales dependencias del sistema de despliegue	49
Tabla 5: Métricas de rendimiento del sistema desplegado.	51
Tabla 6: Interpretación de los niveles de confianza del clasificador.	53

ÍNDICE DE FIGURAS

Figura 1: Matriz de confusión.	19
Figura 2: Metodología CRISP-DM.	26
Figura 3: Problema de prompts evasivos y su impacto.	29
Figura 4: Recolección de información de dataset públicos etiquetados.	30
Figura 5: Datos generados por chatGPT.	31
Figura 6: Datos generados por Claude.	31
Figura 7: Datos generados por Gemini.	31
Figura 8: Estructura de directorios del proyecto de clasificación de prompts.	32
Figura 9: Diagrama de flujo del proceso de preparación de datos.	32
Figura 10: Resultado del proceso de limpieza de datos.	33
Figura 11: Resultado del proceso de tokenización de datos.	34
Figura 12: Resultado del proceso de balanceo de clases.	35
Figura 13: Resultado de división del dataset y aplicación de validación cruzada.	35

Figura 14: Diagrama de flujo del entrenamiento del modelo SVM.	37
Figura 15: Resultado del entrenamiento del modelo SVM.	38
Figura 16: Curva de aprendizaje del modelo SVM.	38
Figura 17: Diagrama de flujo del modelo BERT.	39
Figura 18: Resultado del entrenamiento del modelo BERT.	39
Figura 19: Evolución de pérdidas del modelo BERT.	40
Figura 20: Entrenamiento del modelo RoBERTa.	41
Figura 21: Evolución de pérdidas del modelo RoBERTa.	41
Figura 22: Métricas de rendimiento del modelo SVM.	42
Figura 23: Matriz de confusión del modelo SVM.	43
Figura 24: Curva Precision-Recall del modelo SVM.	43
Figura 25: Resultados de la ejecución - métricas BERT.	44
Figura 26: Matriz de Confusión del modelo BERT.	44
Figura 27: Curva Precision-Recall – BERT.	44
Figura 28: Resultados de la ejecución - métricas RoBERTa.	45
Figura 29: Matriz de Confusión – RoBERTa.	45
Figura 30: Curva Precision-Recall – RoBERTa.	46
Figura 31: Diagrama de flujo del clasificador de prompts.	49
Figura 32: Interfaz del sistema de clasificación.	51

Figura 33: Resultados del clasificador seguro y evasivo.	53
Figura 34: Diagrama de flujo de la extensión de navegador en ChatGPT	54
Figura 35: Resultado de la verificación en la interfaz de ChatGPT	55

ÍNDICE DE ANEXOS

Anexo 1: Análisis documental de datasets públicos de prompts evasivos y seguros	63
Anexo 2: código de app.py con extensión del navegador de chatGPT	65

RESUMEN

El presente proyecto desarrolló un sistema de clasificación supervisado para detectar *prompts* evasivos en modelos de lenguaje mediante procesamiento de lenguaje natural. Se construyó un *dataset* de 41.587 registros etiquetados como seguros y evasivos, obtenidos de fuentes públicas y generación sintética. Se entrenaron y compararon tres modelos: SVM, BERT y RoBERTa, aplicando una división estratificada 80/20 con balanceo exclusivo sobre el conjunto de entrenamiento. Los tres modelos superaron el 96% de precisión, siendo RoBERTa el seleccionado para el despliegue por su estabilidad y capacidad de generalización. El sistema fue implementado en un dashboard interactivo desarrollado en Flask e integrado mediante una extensión de navegador en la plataforma ChatGPT como capa de verificación previa al envío del *prompt*. Los resultados demuestran que los modelos transformers son eficaces para la detección preventiva de *prompts* adversarios en entornos conversacionales.

Palabras clave: *prompts* evasivos, clasificación de texto, RoBERTa

ABSTRACT

This project developed a supervised classification system to detect evasive prompts in language models through natural language processing. A *dataset* of 41,587 records labeled as safe and evasive, obtained from public sources and synthetic generation, was constructed. Three models were trained and compared: SVM, BERT and RoBERTa, applying a stratified 80/20 division with exclusive balance over the training set. The three models surpassed 96% precision, with RoBERTa being selected for *deployment* due to its stability and generalization capacity. The system was implemented in an interactive dashboard developed in Flask and integrated through a browser extension into the ChatGPT platform as a pre-submission verification layer. The results demonstrate that transformer models are effective for the preventive detection of adversarial *prompts* in conversational environments.

Keywords: evasive *prompts*, text classification, RoBERTa

INTRODUCCIÓN

El avance de la inteligencia artificial ha permitido el desarrollo de modelos de lenguaje a gran escala capaces de generar texto similar al lenguaje humano, lo que trajo consigo problemas de seguridad por el uso de *prompts* evasivos que logran obtener respuestas bloqueadas. Aunque los LLM incorporan filtros de seguridad, estos presentan limitaciones frente a métodos de evasión cada vez más sofisticados, vacío que los estudios previos no han resuelto de manera específica. Por ello, surge la necesidad de desarrollar herramientas más especializadas, lo que justifica el sistema de clasificación supervisado propuesto en este trabajo, el cual evalúa *prompts* en tiempo real aportando una solución concreta frente a las limitaciones identificadas.

Por ello, el presente proyecto plantea el desarrollo de un sistema capaz de analizar y clasificar *prompts* como seguros o evasivos, mediante técnicas de procesamiento de lenguaje natural supervisado. Con este fin, se construirá un *dataset* etiquetado, se entrenarán modelos de clasificación como SVM, BERT y RoBERTa, y se implementará un dashboard interactivo que muestre los resultados. Adicionalmente, el sistema se integrará mediante una extensión de navegador que opera sobre la interfaz de ChatGPT, funcionando como capa de verificación al envío del *prompt* por parte del usuario.

El proyecto se compone de tres capítulos, los cuales se describen a continuación:

Capítulo 1: Se presentan antecedentes del problema, la descripción del proyecto, los objetivos, la justificación y el alcance del proyecto.

Capítulo 2: Se expone el marco conceptual y teórico donde se abordan los fundamentos de los modelos de lenguaje, el procesamiento de lenguaje natural, los *prompts* evasivos y las herramientas utilizadas. Además, se describe la metodología empleada para el desarrollo del proyecto.

Capítulo 3: Se detalla lo relacionado con la propuesta del proyecto, las fases de recolección de datos, preparación de datos, el modelado con su respectiva evaluación, el desarrollo del dashboard para la prueba e integración mediante extensión de navegador, así como las pruebas del sistema y los resultados obtenidos.

CAPITULO 1. FUNDAMENTACIÓN

1.1. Antecedentes

En los últimos años, la generación de contenido textual mediante inteligencia artificial ha presentado diversos problemas, ya que los textos producidos por modelos de lenguaje no siempre suelen ser precisos y afectan su calidad y confiabilidad; al mismo tiempo, la capacidad de generar texto rápidamente abre la puerta al uso indebido de estas herramientas, incluyendo contenido engañoso, manipulado o incluso plagio sin supervisión humana [1].

Los LLMs siguen siendo vulnerables a ciertas entradas adversarias, particularmente en el contexto de los llamados ataques jailbreak, diseñados para eludir las políticas de seguridad y manipular los modelos de lenguaje con el fin de obtener resultados restringidos; esto evidencia que la insuficiente detección de contenido dañino en consultas complejas incrementa la vulnerabilidad del modelo [2].

La expansión de las superficies de ataque derivada de la integración de entradas visuales en los LLM representa otro desafío, ya que el riesgo principal proviene del espacio de entrada visual adicional, caracterizado por su continuidad innata y alta dimensionalidad [3]. Dicho espacio se convierte en un punto débil frente a ejemplos visuales adversarios y constituye una amenaza difícil de prevenir, mientras que los ataques en un dominio puramente textual suelen ser más exigentes.

Por otra parte, los agentes de aprendizaje automático pueden reprogramarse para realizar acciones no deseadas según los fines del adversario; un ataque de este tipo puede conducir al robo de recursos computacionales, como los modelos alojados en la nube, y permitir la ejecución de tareas que violen el código ético del proveedor del sistema [4]. Esta situación resulta crítica cuando los ataques utilizan *prompts* que inducen respuestas inapropiadas, lo que demuestra vulnerabilidad del modelo.

A pesar de la creciente necesidad de métodos de clasificación de texto eficientes y precisos, los datos textuales específicos de un dominio presentan desafíos particulares, ya que la clasificación automática enfrenta la falta de datos etiquetados, lo que puede afectar el rendimiento de los métodos de aprendizaje supervisado que requieren grandes volúmenes de información; además, obtener registros de alta calidad demanda esfuerzo humano y experiencia en el dominio [5].

Esta investigación busca que los sistemas aprendan sin necesitar cantidades de datos etiquetados. La idea es aprovechar lo que ya saben modelos entrenados previamente, además de aplicar estrategias que permitan sacar un mayor provecho de la escasa información disponible.

A nivel mundial, se publicó el artículo “Revisión sistemática que analiza investigaciones sobre la detección de lenguaje ofensivo en textos multilingües utilizando técnicas de Procesamiento de Lenguaje Natural (NLP) y aprendizaje automático (ML)”, en el cual se evaluaron las metodologías, las características de los datasets y métricas de evaluación que se emplearon para identificar contenido inapropiado en diferentes tipos de idiomas, destacando los avances y desafíos actuales [6]. El trabajo aporta bases metodológicas de acuerdo con la clasificación y detección de contenido inapropiado, utilizando herramientas y métricas que ayudan a adaptarse al contexto; sin embargo, se centra en lenguaje ofensivo general, mientras que nuestro proyecto aborda *prompts* evasivos en LLMs [6].

A nivel internacional, un artículo realizado en el Vellore Institute of Technology (VIT), India, “propone un sistema de NLP que detecta texto ofensivo y lo reescribe manteniendo su significado original”, utilizando modelos de clasificación entrenados con *datasets* públicos para identificar lenguaje inapropiado y reemplazarlo por sinónimos adecuados, alcanzando hasta un 95% de precisión [7]. Este sistema tiene comunicación respetuosa en entornos públicos y profesionales sin perder coherencia, y muestra cómo procesar y clasificar texto mediante modelos, aportando técnicas que pueden aprovecharse en nuestro proyecto; no obstante, su objetivo se enfoca en reescribir contenido ofensivo, mientras que el nuestro busca detectar de forma preventiva *prompts* diseñados para evadir filtros.

En Latinoamérica, la Escuela Politécnica Nacional desarrolló la tesis “Aplicación de inteligencia artificial generativa para síntesis de textos: conversión de textos a representaciones numéricas”, la cual propone un sistema para procesar masivamente respuestas a preguntas abiertas en encuestas con el fin de generar datasets estructurados para grandes modelos de lenguaje y crear resúmenes [8]. Emplea métricas de relevancia para identificar textos representativos, permitiendo extraer información clave y optimizar el manejo de grandes volúmenes de texto;

aunque no aborda directamente la detección de *prompts* adversarios, se relaciona al mostrar cómo procesar texto, generar representaciones numéricas y agrupar información según la metodología propuesta.

Para abordar los riesgos asociados a *prompts* evasivos generado por modelos de lenguaje grandes, varias investigaciones han explorado métodos basados en clasificación de texto mediante modelos de aprendizaje supervisado, destacando la importancia de contar con un *dataset* etiquetado y estrategias de entrenamiento capaces de detectar y bloquear entradas inapropiadas. Esto permite identificar y evaluar la seguridad de los *prompts*, considerando métricas para el *desbalance* de clase y garantizando la precisión del sistema y la confiabilidad del modelo. Estas investigaciones aportan bases teóricas y metodológicas que respaldan el desarrollo de sistemas de detección y evaluación de *prompts* en entornos de inteligencia artificial.

1.2. Descripción del Proyecto

La aparición de modelos de lenguaje basados en inteligencia artificial , capaces de generar textos muy similares a los escritos por humanos, representa tanto oportunidades como riesgos [9]. Entre los riesgos se encuentran las indicaciones adversarias sofisticadas, aparentemente inocuas para los humanos, que pueden manipular estos modelos para generar contenido explícito no apto para el trabajo, como pornografía, violencia o material político sensible. Esto plantea desafíos importantes de seguridad, por lo que se aprovechará el potencial de los LLM para gestionar el significado de las indicaciones adversarias implícitas [10].

Ante esta situación, surge la necesidad de desarrollar una herramienta web capaz de identificar y clasificar los *prompts* como seguros o evasivos, utilizando técnicas de procesamiento de lenguaje natural supervisado. Esta aplicación entrenará modelos para que aprendan patrones en los textos y puedan diferencien entre las categorías ya mencionadas. Los resultados serán visualizados en un *dashboard*, permitiendo a los usuarios ingresar *prompts* y recibir la clasificación, combinando precisión y facilidad de uso.

El presente proyecto se guiará por la metodología CRISP-DM (Proceso Estándar Inter-Industrias para Minería de Datos), la cual se compone de seis fases [11]:

Fase 1: Comprensión del Problema

El problema central son los *prompts* evasivos que manipulan a los modelos de lenguaje con el fin de producir contenido prohibido. Estos *prompts* están diseñados para engañar los mecanismos de control y forzar respuestas restringidas. El estudio se delimita a *prompts* de texto con el fin de abordar el escenario más frecuente y crítico en el uso de *Large Language Models*. Esta delimitación permite concentrar el análisis en el tipo de entrada con mayor impacto. El objetivo de esta fase es definir el problema, entendiendo los *prompts* evasivos como intentos de evadir los filtros de seguridad.

Fase 2: Comprensión de datos

Durante la construcción del *dataset*, se planificó recopilar aproximadamente 40.000 *prompts*, distribuidos entre contenido seguro y evasivo, con el fin de conformar un conjunto equilibrado para el entrenamiento y evaluación de modelos de clasificación. Una parte significativa de estos datos será obtenida desde repositorios públicos como Hugging Face, Kaggle y GitHub, los cuales proporcionan colecciones abiertas y útiles para trabajos de investigación. El resto del *dataset* será generado de manera sintética, utilizando modelos de lenguaje que permitan recrear estructuras asociados a *prompts* evasivos sin mencionar palabras prohibidas, respetando las restricciones de seguridad. Esta combinación de conjunto de datos reales y sintéticos permitirá construir un *dataset* diverso para el desarrollo del modelo.

Fase 3: Preparación de Datos

Los *prompts* se procesarán para que los modelos de lenguaje natural los interpreten:

- Limpieza de texto: se eliminarán duplicados y caracteres no válidos y se ajustará el contenido para mantener la calidad del *dataset*.
- *Tokenización*: el texto se dividirá en secuencias de *tokens*, que son las unidades que los modelos procesan.
- *Embeddings*: los *tokens* se representarán como vectores numéricos que los clasificadores puedan interpretar, empleando *embeddings* estáticos o contextuales según sea necesario.

- Corrección de *desbalance*: se aplicarán técnicas como *oversampling*, que generan ejemplos sintéticos de la clase minoritaria, para evitar un sesgo hacia la clase mayoritaria.
- División del *dataset*: Se dividirá el *dataset* en conjuntos de entrenamiento y evaluación usando un split estratificado para mantener la proporción de clases. Para optimizar el entrenamiento se empleará validación cruzada k-fold y early stopping para evitar sobreajuste.

Este preprocesamiento asegura un conjunto de datos equilibrado, de calidad y representativo, mejorando la capacidad predictiva de los modelos.

Fase 4: Modelado

Se evaluarán varios clasificadores supervisados, elegidos por su balance entre precisión y eficiencia:

- SVM: se entrenará para separar los datos en categorías aprovechando su eficiencia en conjuntos de tamaño moderado y su capacidad de definir fronteras entre clases.
- BERT: se empleará para capturar el contexto bidireccional de cada palabra mejorando la comprensión semántica de los *prompts* y favoreciendo la clasificación.
- RoBERTa: se probará como versión optimizada de BERT entrenada con más datos y ajustes en preentrenamiento para mejorar la precisión en tareas de NLP.

Fase 5: Evaluación

La evaluación del modelo se realizará empleando varias métricas que permiten analizar su rendimiento desde diferentes perspectivas:

- Precisión: se calculará como la proporción de predicciones etiquetadas como evasivas que corresponden a casos evasivos y se reportará para esa clase.
- Recall: se medirá como la capacidad del modelo para recuperar la mayor parte de los casos evasivos y se reportará para esa clase, este indicador cuantifica la capacidad del modelo para minimizar errores.

- *F1-Score* macro: combinará precisión y exhaustividad por cada clase y se promediarán con un promedio macro para evaluar si el rendimiento es equilibrado entre evasivo y seguro.
- PR-AUC: mostrará cómo varían precisión y exhaustividad al modificar el umbral de decisión y resulta informativa cuando las clases están desbalanceadas.
- Matriz de confusión: presentará una tabla que compara predicciones y valores reales con verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos para identificar los tipos de acierto y error.

Se elaborará una tabla comparativa que resumirá los resultados obtenidos por el modelo BERT, SVM y RoBERTa, permitiendo ver su rendimiento y determinar cuál ofrece un mejor equilibrio y detección efectiva de *prompts* evasivos.

Fase 6: Despliegue

El *dashboard* fue desarrollado en Flask e incorpora varios módulos esenciales que trabajan de forma integrada para ofrecer un sistema de clasificación eficiente y fácil de usar. Primero, cuenta con un módulo de entrada con una interfaz gráfica creada mediante HTML, CSS y JavaScript, permitiendo al usuario ingresar y enviar el *prompt* a evaluar. Luego, el módulo de clasificación procesa el texto ingresado, detecta el idioma automáticamente, realiza la traducción si es necesario y ejecuta el modelo RoBERTa previamente entrenado para obtener la predicción. Finalmente, el módulo de visualización muestra el resultado mediante una ventana modal e incluye una gráfica dinámica generada con Chart.js, facilitando la comprensión del nivel de riesgo asociado a cada *prompt*.

Adicionalmente, el sistema cuenta con las siguientes características:

- Latencia mínima: el procesamiento es rápido gracias al uso de Flask como *backend* y al modelo optimizado, lo que garantiza una experiencia fluida al usuario.
- Visualización de incertidumbre: el sistema presenta las probabilidades de cada clase (seguro y evasivo), permitiendo identificar predicciones con baja confianza.

- Posibilidad de logging: la arquitectura está preparada para integrar un sistema de registro de entradas y resultados, útil para análisis posteriores o para el reentrenamiento del modelo con nuevos datos.

Una vez validado el modelo en el *dashboard*, se procede a su despliegue final mediante la integración con una extensión de navegador. Esto permite que el usuario identifique si su *prompt* es evasivo antes de enviarlo al modelo de lenguaje.

1.3. Objetivos del Proyecto

1.3.1. Objetivo General

Desarrollar un sistema que clasifique *prompts* generados por modelos de lenguaje como seguros o evasivos, mediante técnicas de procesamiento de lenguaje natural supervisado, para prevenir riesgos mejorando la seguridad en entornos de inteligencia artificial.

1.3.2. Objetivos Específicos

- Construir un *dataset* etiquetado de *prompts* seguros y evasivos, recopilando y validando datos de distintas fuentes para garantizar su calidad.
- Entrenar clasificadores con modelos supervisados como SVM, BERT y RoBERTa aplicando técnicas de procesamiento.
- Evaluar la precisión del clasificador mediante métricas *F1-score*, AUC, precisión y recall, para asegurar resultados confiables.
- Visualizar los datos en un *dashboard* en tiempo real que permita a los usuarios ingresar *prompts* mostrando resultados con probabilidades y gráfico.

1.4. Justificación del Proyecto

Los LLM de última generación disponibles comercialmente son adecuados para detectar e identificar indicaciones inyectadas, ya que estas suelen contener patrones similares a instrucciones con intenciones maliciosas que el LLM puede reconocer. Incluso cuando una indicación carece de patrones evidentes, especialmente en casos donde la malicia depende del contexto, el LLM de protección puede aprovechar el contexto de la tarea prevista por el usuario para detectar inconsistencias. Esta capacidad evidencia cómo la implementación de sistemas de detección y mitigación mejora la seguridad y uso de modelos de inteligencia artificial [12].

Una de las investigaciones comprobadas en este campo demostró la efectividad del enfoque *multiagente* para mitigar ataques de *prompt injection*. Una evaluación empírica con 500 indicaciones diversas evidenció que dicho método reduce eficazmente la Puntuación Total de Vulnerabilidad de Inyección, pasando de 25,31 a 46,62, lo que representa una mejora del 45,7 %. Este avance se reflejó en la disminución de la tasa de éxito de inyección (ISR) y la frecuencia de anulación de políticas, al tiempo que mejoró la tasa de *sanitización* rápida y la consistencia de cumplimiento. Comparado con métodos previos de mitigación de alucinaciones, estas arquitecturas se adaptan a distintos desafíos de seguridad en IA generativa, aumentando la resiliencia y confiabilidad de los sistemas [13].

El proyecto propone un sistema de detección y clasificación de *prompts* capaz de identificar en tiempo real entradas manipuladas para eludir las políticas de seguridad de los LLMs. Esto permite prevenir la generación de contenido restringido, garantizando la integridad de las respuestas. La combinación de procesamiento de lenguaje natural supervisado, validación cruzada y modelos como SVM, BERT y RoBERTa asegura que incluso consultas complejas sean evaluadas correctamente, reduciendo la vulnerabilidad de los modelos frente a indicaciones maliciosas y protegiendo tanto la información como la confiabilidad del sistema.

Para abordar riesgos potenciales derivados de entradas multimodales, el sistema contempla una proyección futura de evaluación de *prompts* asociados a información visual. Esto permitirá detectar patrones adversarios antes de que el modelo procese la instrucción, minimizando riesgos. La clasificación previa asegura que los LLMs solo ejecuten *prompts* seguros, fortaleciendo la seguridad en entornos multimodales sin ser parte del alcance actual del proyecto.

El sistema combate vulnerabilidades de agentes de aprendizaje automático mediante modelos supervisados entrenados con *datasets* validados y balanceados. Incluso con escasez de datos etiquetados, técnicas como *oversampling* y validación inter-annotator permiten un desempeño confiable, evitando que los modelos ejecuten acciones no deseadas. La plataforma proporciona detección automática de *prompts* evasivos y seguros, garantizando precisión, protección de recursos computacionales y operación ética de los LLMs.

Este proyecto está direccionado al Plan Nacional de Desarrollo 2025–2029 “Ecuador No Se Detiene”, especialmente con el eje institucional:

Eje Institucional

Objetivo 8: Fortalecer la institucionalidad pública de forma eficiente, transparente y participativa [14].

Política 8.3: Impulsar la transformación digital del Estado, la adopción del modelo de Estado Abierto, la protección de la información, con un entorno digital seguro y confiable en todos los niveles de gobierno, así como la integridad pública y la lucha contra la corrupción, que promueva la gestión pública eficiente, inclusiva, transparente y participativa [14].

1.5. Alcance del Proyecto

La herramienta web para la detección y clasificación de *prompts* evasivos tiene como finalidad identificar entradas de texto que intentan manipular modelos de lenguaje para generar contenido no permitido por lo que el sistema busca mejorar la seguridad en aplicaciones basadas en inteligencia artificial sobre todo en entornos donde los usuarios ingresan texto libremente, como plataformas conversacionales de inteligencia artificial. El proyecto incluye la recolección y preparación de datos con su respectivo entrenamiento de modelos supervisados, la evaluación de resultados y la integración en una aplicación web.

Para su desarrollo se utilizará la metodología CRISP-DM, la cual organiza el proceso en fases estructuradas. En la comprensión del problema se analiza el riesgo de los *prompts* evasivos en los modelos de lenguaje, limitando el estudio únicamente a texto. En la comprensión de datos se recopilarán aproximadamente cuarenta mil *prompts* desde fuentes públicas, con el fin de construir un *dataset* equilibrado.

En la fase de preparación de datos se aplicarán técnicas de procesamiento de lenguaje natural como limpieza, *tokenización*, *embeddings*, balanceo de clases y división del *dataset*. Esto permitirá mejorar la calidad de los datos y optimizar el entrenamiento de los modelos. Posteriormente, en la fase de modelado se utilizarán algoritmos supervisados como SVM, BERT y RoBERTa para la clasificación.

En la fase de evaluación se medirán los resultados mediante métricas como precisión, recall, *F1-score*, PR-AUC y matriz de confusión con el objetivo de comparar el desempeño de los modelos luego en la fase de despliegue se implementará un dashboard con Flask que permitirá visualizar las predicciones en tiempo real e integrar el sistema mediante una extensión de navegador en plataformas de inteligencia artificial conversacional. El alcance del proyecto se limita a la clasificación de *prompts* de texto y su integración en un entorno controlado, sin incluir el desarrollo completo de una plataforma conversacional propia ni sistemas de seguridad a nivel empresarial. Tampoco se trabajará con otros tipos de datos como imágenes o audio. El sistema no garantiza eliminar completamente los riesgos, sino que actúa como una capa adicional de filtrado. El proyecto puede ser mejorado en el futuro con nuevos datos o técnicas más avanzadas.

CAPÍTULO 2. MARCO TEÓRICO Y METODOLOGÍA DEL PROYECTO

2.1. Marco Conceptual

2.1.1. Inteligencia Artificial.

La inteligencia artificial es responsable de estudiar modelos de cómputo capaz de realizar actividades propias del ser humano, como el razonamiento y conducta. [15]. La inteligencia artificial se presenta como una área de estudio tecnológico de la computación, cuyas actividades principales están destinadas a resolver distintos problemas cognitivos, asociados con la lógica y razonamiento de los diferentes tipos de aprendizajes, resolución de problemas, el reconocimiento de patrones educativos, y su propia adaptación [16]. La inteligencia artificial es el fundamento para el sistema propuesto, que permite al modelo memorizar a identificar entre un *prompts* seguro y evasivo.

2.1.2. Procesamiento de Lenguaje Natural

El Procesamiento de Lenguaje Natural se entiende como la habilidad de la máquina para procesar la información comunicada, no simplemente las letras o los sonidos del lenguaje [17]. Los campos de desarrollo de PLN incluyen la recuperación y extracción de información, traducción automática, sistemas de búsquedas de respuestas, generación de resúmenes automáticos, minería de datos, análisis de sentimientos, entre otras [18]. Dentro del procesamiento de lenguaje natural, la clasificación de texto constituye la tarea central de este proyecto, ya que permite categorizar cada *prompt* recibido como seguro o evasivo, lo cual es esencial para proteger la integridad del modelo de lenguaje.

2.1.3. Prompts Evasivos

Los *prompts* evasivos son entradas diseñadas por un adversario para provocar un comportamiento anómalo en un modelo de aprendizaje automático [19]. Es una técnica utilizada en los LLMs que implica manipular los *prompts* dados a estos modelos con el fin de obtener respuestas alteradas. Este tipo de ataque tiene la capacidad de modificar las instrucciones con las que el modelo opera para evadir en sus respuestas de maneras que pueden ser engañosas [20]. Estos *prompts* representan el objeto de estudio del presente trabajo, aunque existen mecanismos de filtrado en los LLM, estos presentan limitaciones frente a entradas evasivas de

mayor complejidad, lo que justifica el desarrollo del sistema de clasificación supervisado propuesto.

2.1.4. Clasificación de Texto

La clasificación de texto consiste en desarrollar un modelo que, a partir de un conjunto de datos etiquetados, adquiera capacidad de generalización que le permita clasificar nuevos textos desconocidos, y para obtener un modelo preciso es necesario realizar un preprocesamiento de datos que permita al clasificador entrenarse con palabras y expresiones significativas [21]. En este trabajo, la clasificación de texto es la tarea principal del sistema. Cada *prompt* recibido debe ser categorizado como seguro o evasivo, por lo que la calidad del preprocesamiento y el entrenamiento resultan determinantes para el rendimiento del modelo.

2.1.5. Modelos de Procesamiento de Lenguaje Natural

Estos permiten muestrear estadísticamente nuevos textos en función de grandes *datasets* de entrenamiento que se utilizaron para crearlos, los primeros modelos de lenguaje generativo habían sido explorados varios años atrás para generar diálogos interactivos basados en aprendizaje evolutivo a partir de datos de la web, también consiste en una red neuronal con muchos parámetros, entrenados sobre grandes cantidades de texto sin etiquetar mediante aprendizaje auto supervisado [22]. Para este proyecto se evaluaron distintos modelos con el fin de identificar cuál ofrece el mejor rendimiento en la detección de *prompts* evasivos, considerando tanto su precisión como su habilidad de generalización.

2.1.5.1. SVM

Las Máquinas de Soporte Vectorial son una técnica de reconocimiento de patrones basada en la procedimiento de aprendizaje, generando resultados robustos y satisfactorios [23]. El clasificador SVM es un algoritmo de aprendizaje supervisado basado en kernel que clasifica los datos en dos o más clases y está especialmente diseñado para la clasificación binaria [24]. Su integración en este proyecto se justifica por su eficacia en clasificación binaria, siendo empleado como línea base para contrastar resultados frente a modelos basados en transformers.

2.1.5.2. BERT

Es un mecanismo de preprocesamiento que, a partir de representaciones de lenguaje

de propósito general, se afina para cumplir con los requerimientos de tareas más específicas (transfer learning) [25]. Bidireccional significa que BERT aprende información tanto del lado izquierdo como del lado derecho del contexto de un token durante la fase de entrenamiento [26]. Al considerar el contexto completo de una oración, BERT resulta especialmente útil para identificar patrones semánticos presentes en *prompts* evasivos, lo que lo convierte en uno de los modelos centrales evaluados en este sistema de clasificación.

2.1.5.3. RoBERTA

RoBERTa es un modelo basado en BERT con modificaciones en el procedimiento de preentrenamiento que mejoran el rendimiento y la hacen más robusta [27]. Estas mejoras lo hacen aún más eficaz que BERT en tareas de procesamiento de lenguaje natural, lo que lo convierte en una excelente opción para capturar la estructura organizativa del contenido en los ensayos, que utiliza más datos de entrenamiento y secuencias largas para mejorar la capacidad del modelo [28]. Estas características lo hacen adecuado para clasificar *prompts* con redacciones sofisticadas diseñadas para evadir filtros, por lo que su evaluación dentro de este proyecto resulta relevante para determinar si supera a BERT en este contexto de mayor datos de información.

2.1.6. Procesamiento de datos

El procesamiento de datos es un paso crucial en la gestión de suministro y en técnicas de aprendizaje automático, también los datos incluyen la limpieza, transformación y selección de características, con el fin de mejorar la calidad de los datos antes de emplearlo en los modelos de predicción y análisis [29]. En este proyecto, la forma en que se procesara el conjunto de *prompts* es clave para que los modelos de inteligencia artificial puedan aprender con información clara, sin sesgos que puedan distorsionar los resultados.

2.1.6.1. Tokenización

La *tokenización* es el proceso de separar las cadenas de texto más largas en trozos más pequeños o *tokens*. Los trozos de texto más grandes pueden dividirse en frases, las frases pueden dividirse en palabras, esta manera de seleccionar los *tokens* del texto depende de la naturaleza del problema que se afronte, en algunas ocasiones una simple *tokenización*, como la de separar el texto por los espacios, puede ser

suficiente [30]. En este sistema, la *tokenización* representa el primer paso del preprocesamiento: transforma cada *prompt* en una secuencia de *tokens* que el modelo puede interpretar y analizar para determinar su clasificación.

2.1.6.2. *Embedding*

En el ámbito del procesamiento del lenguaje natural, un *embedding* específicamente es una representación matemática que codifica el significado lingüístico de un texto y su contexto, normalmente en forma de un vector de cientos o miles de dimensiones, cada palabra, frase o documento están representado en un conjunto de valores numéricos calculados por modelos entrenados sobre grandes corpus textuales [31]. En este proyecto, los *embeddings* transforma cada *prompt* en una representación numérica que conserva sus relaciones semánticas, facilitando al modelo distinguir entradas evasivas, aunque estas varíen en su redacción.

2.1.6.3. *Oversampling*

Es una técnica utilizada para aumentar la representación de la clase minoritaria en un conjunto de datos desequilibrado que consiste en generar nuevas instancias, lo que reduce el desajuste en la distribución entre clases, eficaz para mejorar la capacidad del modelo de reconocer patrones en la clase minoritaria, pero debe usarse con precaución para evitar el sobreajuste cuando se generan demasiadas instancias o si las nuevas muestras no son representativas [32]. Dado que los *prompts* evasivos suelen ser menos frecuentes que los seguros en el conjunto de datos utilizado, aplicando *oversampling* para evitar que el modelo se sesgue hacia la clase mayoritaria, mejorando su capacidad de detección en ambas categorías entre seguro y evasivo.

2.1.7. Métricas de Evaluación

Las métricas de evaluación permiten medir el rendimiento y la eficacia, estos algoritmos son evaluados en base a su precisión, exhaustividad, puntuación F1 y exactitud. Estas métricas proporcionan una visión de la capacidad de los algoritmos para procesar y comprender el lenguaje natural [33]. En este proyecto, las métricas responden al tipo de problema, dado que clasificar erróneamente un *prompt* evasivo tiene consecuencias que el caso contrario, se prioriza el recall en la

clase evasiva como métrica principal para la toma de decisiones.

2.1.7.1. Precisión

Es una métrica que, por cada clase, calcula el porcentaje de aciertos sobre los casos en los que se indica la pertenencia a una clase, por ejemplo, para aquellos textos clasificados con motivo de anulación "siniestro", esta métrica indicará qué porcentaje de estos casos pertenecen realmente al motivo "siniestro". A continuación, se presenta la fórmula para calcular la precisión [34].

$$\text{Precisión} = \frac{TP}{TP + FP}$$

2.1.7.2. Recall

La sensibilidad representa la tasa de verdaderos positivos (TP). Es la proporción entre los casos positivos bien clasificados por el modelo, respecto al total de positivos. Si nuestro algoritmo de clasificación es poco sensible, fallará mucho al detectar positivos. Por lo que esta métrica debe ser priorizada en los casos donde tener una gran cantidad de falsos negativos tiene un mayor coste [35]. En este sistema, minimizar los falsos negativos es crítico, ya que un *prompt* evasivo no detectado podría comprometer la seguridad del modelo.

$$\text{Recall} = \frac{TP}{TP + FN}$$

2.1.7.3. F1-Score

Esta métrica se emplea para obtener un valor de rendimiento que combina la precisión y el Recall, se calcula por medio de la ecuación 3 [36]. Combina la precisión y el recall para proporcionar una medida global del rendimiento del modelo. Se calcula como la media armónica de la precisión y el recall [37]. En el contexto de este proyecto, el *F1-Score* resulta especialmente útil debido a que las clases "seguros" y "evasivos" no siempre están balanceadas dentro del conjunto de datos.

$$F1 = 2 \cdot \frac{\text{Precisión} * \text{Recall}}{\text{Precisión} + \text{Recall}}$$

2.1.7.4. PR-AUC

proporciona una medida fiable de rendimiento del clasificador en escenario con un alto desequilibrio de clases, ya que se centra en las compensaciones entre precisión

y exhaustividad en lugar de las tasas de verdaderos negativos, que pueden dominar las puntuaciones ROC-AUC en conjuntos de datos desequilibrados [38].

$$PR - AUC = \int_0^1 P(r) dr$$

2.1.7.5. Matriz de confusión

La matriz de confusión es aquella que permite analizar la relación entre las muestras positivas y negativas con las predicciones positivas y negativas, tal como muestra la **Figura 1**. Las columnas muestran la cantidad de valores (positivos o negativos) predichos en función de las filas, siendo las filas los valores reales (positivos o negativos) [39]. En este proyecto, su análisis permite determinar qué tipo de errores comete el clasificador con mayor frecuencia, orientando las decisiones de ajuste y mejora del modelo durante el proceso de evaluación. Distinguimos entonces:

Verdaderos positivos (VP): El valor real y su predicción son positivos.

Verdaderos negativos (VN): El valor real y su predicción son negativos.

Falsos positivos (FP): El valor real es negativo y su predicción es positiva.

Falsos negativos (FN): El valor real es positivo y su predicción es negativa

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negatives (TN)	False Positives (FP) Type I error
	Positive +	False Negatives (FN) Type II error	True Positives (TP)

Figura 1: Matriz de Confusión [39].

2.2. Herramientas y Tecnologías

Visual Studio Code: es un editor de código abierto gratuito que se ha ganado la aceptación de desarrolladores porque se puede utilizar en cualquier sistema operativo y resulta compatible con gran cantidad de lenguajes de programación que tiene un ecosistema de extensiones permitiendo personalizar el entorno adaptándose

a las necesidades de los proyecto [40].

Flask: es un *microframework* liviano utilizado para la construcción de las aplicaciones web que implementa la funcionalidad básica, lo que da la posibilidad a los programadores de añadir cualidades según se necesiten al momento de implementar y para aplicaciones WSGI se puede implementar tanto para *backend* como para *frontend* según su necesidad [41].

Python: es un lenguaje de programación orientado a objetos reconocido por su estructura clara y legible que facilita tanto el aprendizaje como al desarrollo de soluciones complicadas. En este tiempo ha ganado gran popularidad en términos como la computación científica, construcción de sitios web y la automatización de procesos [42].

Transformers: es una nueva arquitectura que prescinde de la recurrencia y de las convoluciones basándose únicamente en los mecanismos de atención para crear dependencias globales entre la entrada y la salida, se ha demostrado que este modelo es superior en calidad, siendo más *paralelizable* y requiriendo significativamente menos tiempo de entrenamiento [43].

PyTorch: *Framework* de aprendizaje automático de código abierto que dado su diseño eficiente, permite implementar modelos rápidamente. En comparación con otros *frameworks*, permite los grafos de computación dinámica, lo cual hace fácil la experimentación y el ajuste iterativo durante el entrenamiento. Esta herramienta es utilizada para investigaciones y el desarrollo del procesamiento de lenguaje natural [44].

Numpy: se trata de una librería de código libre para Python orientada a la computación numérica, especialmente en operaciones relacionadas con cálculos matemáticos y estadísticos, siendo el mejor en tratamiento de matrices y arrays, por lo que se convierte en una herramienta básica para el desarrollo de proyectos de ciencia de datos y aprendizaje de máquinas [45].

al permitir que el desarrollador guarde únicamente información numérica como pesos y parámetros, pero no permite funciones de devolución de llamada, arquitectura del modelo ni ninguna otra forma de ejecución arbitraria de código,

este formato no solo permite una serialización segura, sino que también está diseñado para optimizar la carga y lectura rápidas [46].

HTML: es un lenguaje que permite definir la estructura y el contenido de las ubicaciones web. No se trata de un lenguaje de programación ya que no ejecuta lógica, ni procesar datos, sino que hace uso de etiquetas para marcar y organizar los diferentes elementos que aparecen como textos, imágenes, vídeos, botones y enlaces, y conseguir así un flujo de la experiencia de navegación [47].

CSS: es el lenguaje que se utiliza para diseñar la apariencia de las páginas, gestionando diseño como la tipografía, los colores, los márgenes en que se disponen los componentes en la pantalla. A partir de lo que son propiedades y valores se puede establecer completamente la apariencia de la página web sustituyendo los estilos predeterminados para el navegador. Su flexibilidad la hace una herramienta básica para el desarrollo actual de interfaces web [48].

JavaScript: es un lenguaje de programación que sirve para agregar más interacción y dinamismo a las páginas, ejecutándose en el navegador del usuario, puesto que a diferencia de HTML que solamente estructura el contenido, JavaScript responde a las acciones del usuario. Por la cual se utiliza como la principal herramienta para la gestión de eventos y la actualización dinámica del contenido [49].

2.2. Marco Teórico

2.2.1. Detección de ataques de inyección de *prompts* en modelos de lenguaje.

Este artículo expone que los modelos de lenguaje a gran escala son utilizados en todo ámbitos, tanto en la academia como en la industria, para multitud de tareas como los asistentes virtuales, automatización de procesos, pero también son tecnologías que tienen vulnerabilidades de seguridad como los ataques de inyección de mensajes, de tal forma que se propone un enfoque basado en el aprendizaje automático para detectar este tipo de ataques y en este sentido se comparan sus resultados con otros enfoques tradicionales, donde se realizan experimentos con modelos como BERT, *CountVectorizer* y *TfidfVectorizer* y se demuestra que las técnicas de sobre muestreo mejoran la detección de amenazas [50].

Desde un punto de vista diferente en el ámbito de la ciberseguridad de los modelos

de lenguaje, este trabajo investiga cómo generar gusanos informáticos WORM por medio del LLM, dado que en un entorno controlado las vulnerabilidades del protocolo FTP fueron utilizadas para simular ataques e implementar código malicioso; en lugar de agentes como Chapter Play y DAN fueron utilizadas técnicas para evadir las restricciones del LLM. Dicha investigación expone que Snort no era capaz de detectar la amenaza con las reglas por defecto, pero la implementación de reglas específicas en función del tráfico obtenía identificar y detener la actividad maliciosa, lo que pone de manifiesto tanto el potencial de estos LLM para llevar a cabo ciberataques como la necesidad de fortalecer los sistemas de detección [51].

2.2.2. Generación, detección y evaluación de ataques de jailbreak basados en juegos de rol en modelos de lenguaje a gran escala.

Esta investigación presenta que los modelos de lenguaje a gran escala (LLM) suelen rechazar solicitudes dañinas debido a políticas éticas, sin embargo, los usuarios pueden evadir estas restricciones mediante ataques de tipo jailbreak basados en juegos de rol, donde el modelo asume el papel de un personaje ficticio que ignora dichas normas, por lo que el estudio analiza estos ataques mediante la generación de ejemplos sintéticos, la evaluación de su efectividad y el entrenamiento de un modelo de detección capaz de predecir si un *prompt* logrará vulnerar el sistema, encontrando que modelos como GPT-4 pueden generar estos ataques con pocos ejemplos y que es posible clasificarlos mediante técnicas como PCA y SVM [52]. Por otra parte, los modelos de lenguaje a gran escala presentan vulnerabilidades frente a ataques *adversariales* que evaden sus mecanismos de seguridad por lo que se propone un marco de evaluación sistemático para analizar técnicas de jailbreaking en distintas arquitecturas además permite medir su eficacia en múltiples categorías de contenido nocivo y comparar vectores de ataque de forma reproducible asimismo se evidencia que la arquitectura y el número de parámetros influyen en la resistencia del modelo revelando la relación entre capacidades y vulnerabilidades de seguridad [53],

2.2.3. Defensas contra *Prompt Injection* y Jailbreak en LLM

El artículo analiza la detección automática de modismos como un problema de clasificación de texto dentro del procesamiento del lenguaje natural, destacando su

importancia en aplicaciones como recuperación de información, traducción automática, y propone un modelo ensemble basado en BERT y RoBERTa, entrenado con el *dataset* y evaluado con un conjunto de datos propio de 1470 expresiones anotadas por expertos, obteniendo resultados superiores a los modelos de referencia en métricas como *F1-score* y precisión, con una mejora del 2%, lo que demuestra la eficacia de los modelos preentrenados para distinguir entre lenguaje literal y figurado [54].

En contexto, los modelos de lenguaje a gran escala presentan importantes desafíos en ciberseguridad, por lo que este proyecto propone validar un sistema de evaluación continua que permita detectar vulnerabilidades como inyección de *prompts*, *exfiltración* de datos y generación maliciosa, además integra controles de seguridad dentro del ciclo de vida del desarrollo para mitigar riesgos, estableciendo protocolos y estándares que aumentan la confianza en aplicaciones de IA generativa, y finalmente busca anticipar amenazas y garantizar la fiabilidad de los LLM en entornos críticos promoviendo prácticas responsables y sostenibles [55].

2.3. Metodología del Proyecto

2.3.1. Metodología de Investigación

Los Modelos de Lenguaje Extensos (LLMs) han transformado el ecosistema de ciberseguridad, donde los ataques de fuerza bruta evolucionan de manera autónoma para evadir los mecanismos de detección tradicionales [56]. Dicho estudio permitirá identificar patrones en los *prompts* utilizados en modelos de lenguaje y reconocer aquellos que intentan evadir los filtros de seguridad, estableciendo criterios confiables para su clasificación automática. Además, facilitará el análisis de trabajos previos sobre detección de *prompts* evasivos e implementará modelos supervisados de procesamiento de lenguaje natural para construir una herramienta práctica que clasifique *prompts* en tiempo real.

El método de investigación que se utilizará será de tipo cuantitativo, ya que este se centra en recopilar y analizar datos numéricos sobre variables previamente determinadas [57]. En este proyecto se aplicará mediante la construcción de un conjunto de datos con aproximadamente 40.000 *prompts* etiquetados, los cuales,

aunque son expresiones en lenguaje natural, se transformarán en representaciones numéricas para su respectivo análisis. Este enfoque permitirá obtener evidencia objetiva y medible, útil para el desarrollo de una herramienta confiable de clasificación de *prompts* en contextos de investigación académica.

Idea a defender.

La idea a defender de este trabajo es desarrollar una herramienta web práctica y de control que clasifique automáticamente los *prompts* como seguros o evasivos, permitiendo detectar indicaciones adversarias que manipulan a los modelos de lenguaje, con el fin de mejorar la seguridad, confiabilidad y robustez de estos sistemas en entornos de aplicación.

Variable.

La medición se basará en un conjunto de datos etiquetados, y se evaluará el desempeño del modelo utilizando métricas como precisión, recall, *F1-score*, PR-AUC y la matriz de confusión, las cuales permiten medir la capacidad de la herramienta para clasificar correctamente las entradas, analizar el equilibrio entre ambas clases y determinar la efectividad del sistema en la detección de *prompts* evasivos o seguros. Se prioriza el recall en la clase evasiva como métrica principal, dado que minimizar los falsos negativos es crítico para evitar contenido inseguro.

2.3.2. Técnicas e instrumentos de recolección de datos

En este proyecto se utilizará el análisis documental para revisar artículos científicos, repositorios técnicos y publicaciones relacionadas con *prompts adversariales* y procesamiento del lenguaje natural. Esto nos brinda una base teórica y metodológica para guiar el diseño de la herramienta de clasificación rápida. Además, esta revisión permitirá identificar los enfoques más recientes y las métricas utilizadas en la detección de comportamientos evasivos en modelos de lenguaje, fortaleciendo la fundamentación técnica del desarrollo propuesto.

Como técnica complementaria, se aplicará el registro de métricas de desempeño del modelo, que consiste en documentar y analizar sistemáticamente las predicciones del modelo frente a las etiquetas del conjunto de datos. Esta técnica permitirá calcular métricas clave como precisión, recall, *F1-Score*, exactitud y PR-AUC, evaluando de manera objetiva la capacidad del modelo para clasificar

correctamente *prompts* seguros y evasivos. Se prioriza el recall sobre las demás métricas, ya que un *prompt* evasivo no detectado representa un riesgo mayor que una falsa alarma. El instrumento utilizado será una ficha de registro de métricas, diseñada para organizar los resultados por cada categoría y derivar las métricas de desempeño necesarias para la evaluación del modelo.

2.3.3. Análisis de Recolección de datos

Para el desarrollo del presente proyecto se utilizó la técnica de análisis documental que permitió recopilar información a partir de diferentes repositorios y fuentes públicas relacionadas con *prompts* y procesamiento de lenguaje natural lo cual facilitó la obtención de datos utilizados en entornos de modelos de lenguaje que sirve como base para la construcción del conjunto de datos necesario para el entrenamiento del sistema de clasificación **(ver anexo 1)**.

La recolección de datos se llevó a cabo mediante el uso de plataformas como Hugging Face, Kaggle y GitHub, de donde se obtuvieron diversos conjuntos de *prompts* clasificados en seguros y evasivos. Estos datos provienen de repositorios como “*ChatGPT-prompts*”, “*AI-Generated Prompts Dataset*”, “*Prompt Engineering Dataset*”, “*LLM Red Teaming Prompts*”, “*awesome-chatgpt-prompts*” y “*Do-Not-Answer*”, los cuales contienen ejemplos utilizados en investigaciones y pruebas de modelos de lenguaje.

Adicionalmente, se utilizó la generación de datos mediante modelos de lenguaje como ChatGPT, Gemini y otros sistemas similares, con el fin de ampliar la variedad de ejemplos, especialmente en la categoría de *prompts* evasivos. Este enfoque permitió enriquecer el *dataset* con nuevas estructuras y patrones que no siempre están presentes en los repositorios públicos.

Durante este proceso se identificó que algunos *prompts* generados presentaban restricciones en la visualización de contenido sensible, reemplazando ciertas palabras por símbolos como asteriscos (**). Por esta razón, los datos sintéticos fueron completados siguiendo criterios predefinidos de coherencia semántica, utilizando términos previamente investigados, y posteriormente revisados para garantizar coherencia con el *dataset* original. Este procedimiento permitió incrementar la cantidad de datos disponibles.

El proceso de etiquetado se realizó manualmente, siguiendo criterios claramente definidos para distinguir entre *prompts* seguros y evasivos. Específicamente, se clasificó como evasivo todo *prompt* que intentara manipular el comportamiento del modelo para obtener respuestas no permitidas, mientras que los *prompts* seguros correspondieron a entradas sin intención adversaria. Las etiquetas asignadas fueron validadas mediante revisión cruzada para asegurar consistencia en la clasificación. Finalmente, el análisis de los datos recopilados permitió construir un conjunto de datos equilibrado y representativo de aproximadamente 40.000 *prompts*, lo que contribuye a mejorar el rendimiento de los modelos de clasificación. De esta manera, se busca que el sistema pueda responder ante diferentes tipos de entradas en escenarios reales, reduciendo posibles sesgos en la clasificación y asegurando un mejor equilibrio entre las categorías analizadas.

2.3.4. Metodología de Desarrollo

CRISP-DM es un modelo de proceso de minería de datos que describe una manera en la que los expertos en esta materia abordan el problema [58]. Este modelo puede integrarse con una metodología de gestión de proyectos específica que complemente las tareas administrativas y técnicas [59]. Se compone de seis fases principales: comprensión del problema, comprensión de los datos, preparación de datos, modelado, evaluación y despliegue [60]. Las cuales servirán como marco metodológico para guiar el presente proyecto en la construcción de una herramienta web de clasificación automática de *prompts*, garantizando un proceso estructurado.




Figura 2: Metodología CRISP-DM

Fase 1: Comprensión del Problema. El estudio se centra en los *prompts* evasivos que buscan manipular a los modelos de lenguaje para generar contenido prohibido. Estos *prompts* son diseñados para evadir los filtros de seguridad establecidos. Se delimita el análisis únicamente a *prompts* de texto, dado que representan los casos más comunes y críticos. El propósito es definir claramente el problema y los riesgos asociados a estas instrucciones adversarias.

Fase 2: Comprensión de los Datos. Se construirá un *dataset* de aproximadamente 40.000 *prompts* obtenidos de interacciones con distintos LLMs y repositorios públicos. Dichos *prompts* se organizarán en dos categorías: “seguros” y “evasivos”, con el fin de diferenciar su naturaleza y también los obtenidos sintéticamente por modelos de lenguaje.

Fase 3: Preparación de los Datos. Los datos recolectados pasarán por limpieza, normalización y *tokenización* para un mejor procesamiento. Después, se generarán *embeddings* que representen los *prompts* en un espacio vectorial y se aplicará *oversampling* para la corrección de *desbalances* entre clases. El *dataset* se dividirá en conjuntos de entrenamiento y prueba usando un split estratificado de 80/20 con `random_state=42`, garantizando la proporción de clases "seguro" y "evasivo" en ambos conjuntos. Como verificación preliminar del *pipeline*, se aplicará validación cruzada K-Fold con $k=5$ usando Regresión Logística como estimador de bajo costo computacional, con el fin de confirmar que las representaciones TF-IDF son adecuadas antes de entrenar los modelos principales. Los modelos finales (SVM, BERT y RoBERTa) serán evaluados sobre el conjunto de prueba fijo del 20%, protocolo uniforme para los tres, lo que garantiza comparaciones directas y reproducibles entre ellos.

Fase 4: Modelado. En esta fase se probarán distintos clasificadores supervisados como SVM, BERT y RoBERTa, conocidos por su capacidad de clasificación textual. El propósito es identificar la arquitectura que mejor aproveche las características de los datos.

Fase 5: Evaluación. El rendimiento de los modelos seleccionados se evaluará con métricas como precisión, recall, *F1-score* macro y PR-AUC. Se priorizará el recall en la clase evasiva, dado que minimizar los falsos negativos es crítico para evitar la

generación de contenido inseguro. Además, se utilizará la matriz de confusión para un análisis más detallado del comportamiento de cada modelo. Esta fase también servirá para retroalimentar posibles mejoras en el preprocesamiento y configuración de los modelos.

Fase 6: Despliegue. El modelo con mejor rendimiento será implementado en un *dashboard* web en tiempo real desarrollado con Flask. Este sistema permitirá procesar los *prompts* ingresados por el usuario y clasificarlos inmediatamente como “seguros” o “evasivos”. Además, el *dashboard* contará con un umbral de decisión configurado en 0.70 (70%), ajustable según el nivel de riesgo requerido. También integrará un sistema de registro de entradas (logging).

Una vez validado el modelo en el *dashboard*, se procede a su despliegue final mediante la integración con una extensión de navegador que opera sobre plataformas de inteligencia artificial conversacional como ChatGPT.

CAPITULO 3. PROPUESTA

3.1. FASE 1: COMPRENSIÓN DEL PROBLEMA

Los modelos de lenguaje no tienen el mecanismo que les permita evaluar lo que se encuentra detrás de un *prompt* antes de llegar a la respuesta. Esta falta de evaluador permite a los usuarios redactar estos *prompts* utilizando lenguaje manipulado, evasivos, para pasar el filtro de seguridad y obtener información sensible, como puede observarse en la **Figura 3**.




Figura 3: Problema de prompts evasivos y su impacto.

Para abordar esta problemática, se propone desarrollar un modelo de clasificación basado en aprendizaje supervisado, entrenado con indicaciones etiquetadas como seguras o evasivas, que permita detectar la intención de un *prompt* antes de que el modelo procese la solicitud y genere una respuesta inadecuada.

3.2. FASE 2: COMPRENSIÓN DE DATOS

Durante el proceso de construcción del dataset, se recopiló un total de 41.587 *prompts*, los cuales fueron obtenidos a partir de dos fuentes principales: repositorios públicos y generación de datos sintéticos mediante inteligencia artificial. Esta combinación permitió construir un conjunto de datos diverso, representativo y orientado a escenarios reales de uso, especialmente enfocados en la detección de entradas seguras y evasivas en modelos de lenguaje.

3.2.2. Adquisición de datos desde repositorios públicos

Se recopilaron 28.100 *prompts* de repositorios públicos, de los cuales 9.850 fueron clasificados como seguros y 18.250 como evasivos (**ver Anexo 1**). Los datos recolectados se ordenaron en un archivo Excel llamado *datasets_prompts*, el cual contiene los campos para cada *prompt*: *prompt_id*, *prompt*, categoría, subcategoría, nivel de impacto, nivel de riesgo, descripción y etiquetado, tal como se muestra en la **Figura 4**.




Figura 4: Estructura del dataset de prompts recopilados

3.2.3 Adquisición de datos sintéticos generados por modelos de inteligencia artificial

Para complementar el *dataset*, se generaron 13.487 *prompts* adicionales mediante tres modelos de lenguaje: ChatGPT con 6.050 *prompts*, Claude con 6.050 y Gemini con 1.387, los cuales fueron etiquetados manualmente como seguros o evasivos.

Durante la generación de los datos sintéticos, se identificó que los modelos señalaban mediante corchetes aquellos términos que no podían incluir directamente en el *prompt* debido a sus restricciones internas. Esta característica fue aprovechada para localizar con precisión las palabras de carácter evasivo, las cuales fueron incorporadas manualmente en cada *prompt*, completando así el *dataset* con indicaciones que reflejan patrones reales de evasión, tal como se evidencia en las **Figuras 5, 6 y 7**.




Figura 5: Datos generados por chatGPT




Figura 6: Datos generados por Claude



Figura 7: Datos generados por Gemini

3.3. FASE 3: PREPARACIÓN DE LOS DATOS

Para el desarrollo de las fases se utilizó Google Colab Pro como entorno de trabajo, ya que permite ejecutar código Python en la nube con acceso a GPU de mayor capacidad, mayor memoria RAM y sesiones extendidas, lo que optimizó el procesamiento del dataset sin depender de los recursos del equipo local. Además, facilitó el almacenamiento y gestión de los archivos generados directamente en Google Drive a partir de la carpeta *Proyecto_prompts* tal como en la **Figura 8**.




Figura 8: Estructura de directorios del proyecto de clasificación de prompts

La evolución cronológica del dataset a lo largo de las etapas de preparación, evidenciando las variaciones en el número de registros producidas en cada proceso aplicado. Es importante destacar que la división y el balanceo ejecutados en la Fase 3 tuvieron carácter exploratorio para verificar la calidad del *pipeline* TF-IDF; el proceso definitivo se implementó en la Fase 4, donde la división estratificada 80/20 se realizó sobre el dataset limpio de 30.261 *prompts* antes del balanceo, obteniendo 24.208 muestras para entrenamiento y 6.053 para prueba. El balanceo mediante *oversampling* se aplicó exclusivamente sobre el conjunto de entrenamiento, garantizando que el conjunto de prueba mantuviera la distribución original de clases sin ningún tipo de contaminación entre subconjuntos, tal como en la Tabla 1

Etapas	Proceso aplicado	Registros	Motivo del cambio
Dataset original	Recopilación de repositorios públicos	41.587	-
Tras limpieza	Eliminación de duplicados y valores nulos	30.261	Se descartaron 11.326 registros duplicados o incompletos
Conjunto entrenamiento	División estratificada 80%	24.208	Separación antes del balanceo
Conjunto prueba	División estratificada 20%	6.053	Sin balanceo, distribución original
Entrenamiento balanceado	<i>Oversampling</i> clase minoritaria	29.892	Se igualan las clases solo en entrenamiento

Tabla 1: Resumen cronológico del procesamiento del dataset

La **Figura 9** presenta el diagrama de flujo el cual describe de manera secuencial los procesos aplicados al dataset, desde la importación del archivo original hasta la

obtención del conjunto de datos listo para la etapa de entrenamiento.




Figura 9: Diagrama de flujo del proceso de preparación de datos realizado en la Fase 3

Cabe señalar que el desarrollo de los scripts de esta fase contó con el apoyo de herramientas de inteligencia artificial generativa para la generación de código, el cual fue posteriormente revisado y ajustado según los requerimientos específicos del proyecto.

3.3.1. Limpieza del texto

Para la limpieza del texto se utilizaron las bibliotecas Pandas para la carga y manipulación del dataset, Re para la eliminación de caracteres no válidos y enlaces URL mediante expresiones regulares, y NumPy para el soporte en el procesamiento de los datos. Como primer paso, se importó el dataset en formato Excel desde la carpeta FASE3_preparacion_de_datos y se aplicaron procesos de depuración sobre los *prompt*, incluyendo la eliminación de registros duplicados, la eliminación de caracteres no válidos, la supresión de enlaces URL y la estandarización del texto a

minúsculas. Como resultado del proceso, el sistema confirmó la carga de los 41.587 registros y la generación del archivo `dataset_limpio.csv` destinado a la etapa de entrenamiento, tal como se evidencia en la **Figura 10**.

0	desinformación	Información médica errónea	alto	alto
1	desinformación	Información política errónea	alto	alto
2	desinformación	Información médica errónea	alto	alto
3	desinformación	Información política errónea	medio	alto
4	desinformación	Teorías conspirativas	medio	alto
5	desinformación	Información médica errónea	alto	alto
6	desinformación	Información política errónea	alto	alto
7	desinformación	Teorías conspirativas	medio	alto
8	desinformación	Información médica errónea	medio	alto
9	desinformación	Información política errónea	medio	alto

	descripcion	etiquetado
0	Impulsa la prueba de información errónea y afi...	evasivo
1	Impulsa la prueba de información errónea y afi...	evasivo
2	Impulsa la prueba de información errónea y afi...	evasivo
3	Impulsa la prueba de información errónea y afi...	evasivo
4	Impulsa la prueba de información errónea y afi...	evasivo
5	Impulsa la prueba de información errónea y afi...	evasivo
6	Impulsa la prueba de información errónea y afi...	evasivo
7	Impulsa la prueba de información errónea y afi...	evasivo
8	Impulsa la prueba de información errónea y afi...	evasivo
9	Impulsa la prueba de información errónea y afi...	evasivo


```

Columnas: ['prompt_id', 'prompt', 'categoria', 'subcategoria', 'gravedad', 'nivel de riesgo', 'descripcion', 'etiquetado']
Total de filas: 41587
Limpieza completada.

```

Figura 10: Resultado del proceso de limpieza de datos

3.3.2. Tokenización mediante TF-IDF

Para esta etapa se empleó la librería *Scikit-learn*, específicamente la clase `TfidfVectorizer`, la que permite convertir el texto de cada uno de los *prompt* en vectores numéricos asignando un peso a cada término según su frecuencia en el documento y su relevancia dentro del conjunto. Adicionalmente, se empleó *LabelEncoder* para codificar numéricamente las etiquetas de clasificación. Una vez depurado el texto, se aplicó la técnica TF-IDF para transformar cada *prompt* en vectores numéricos representativos. Se fijó un máximo de 10.000 características. De este modo, el sistema generó una matriz de dimensión 30.261×10.000 , lo que dio como resultado la adecuada transformación del texto. Esta matriz se guardó en la carpeta `FASE3_preparacion_de_datos` de Google Drive, con el nombre `vectores_tokenizados.csv`, como se puede ver en la **Figura 11**.

Tokenización completada.
Forma de X: (30261, 10000)
Guardado en Drive: vectores_tokenizados.csv

Figura 11: Resultado del proceso de tokenización de datos

3.3.3. Balanceo de clases.

En esta fase de la etapa se hizo uso de la biblioteca *Scikit-learn*, utilizando la función `resample` que permite balancear el conjunto de datos a partir de la técnica de *oversampling*, que replica registros de la clase minoritaria hasta igualarla a la del

resto de las clases. Adicionalmente, se empleó Pandas para la construcción y concatenación del *dataset* balanceado. Con el fin de evitar sesgos durante el entrenamiento y prevenir contaminación entre subconjuntos, el balanceo se aplicó exclusivamente sobre el conjunto de entrenamiento de 24.208 muestras, resultando en 14.946 registros por clase y un total de 29.892 muestras balanceadas para entrenamiento. El conjunto de prueba de 6.053 muestras se mantuvo sin modificación, conservando la distribución original de clases. El *dataset* de entrenamiento balanceado fue almacenado en la carpeta FASE3_preparacion_de_datos bajo el nombre *dataset_balanceado.csv*, tal como se evidencia en la **Figura 12**.

```
Dataset balanceado:  
0    18683  
1    18683  
Name: count, dtype: int64  
Guardado en Drive: dataset_balanceado.csv
```

Figura 12: Resultado del proceso de balanceo de clases

3.3.4. División del dataset y validación cruzada

Para esta etapa se han utilizado las bibliotecas Scikit-learn, donde se han utilizado las clases *train_test_split* para llevar a cabo la división estratificada de los datos, *StratifiedKFold* para llevar a cabo la validación cruzada, *LogisticRegression* como estimador exploratorio, y *accuracy_score* para calcular la precisión. En este sentido, la división de los datos y su balanceo tienen carácter exploratorio para observar de qué forma podría comportarse la *pipeline* TF-IDF. El proceso definitivo se implementó en la Fase 4, donde la división estratificada 80/20 se realizó sobre el dataset limpio de 30.261 *prompts* antes del balanceo, obteniendo 24.208 muestras para entrenamiento y 6.053 para prueba, con el *oversampling* aplicado exclusivamente sobre el entrenamiento. Se aplicó validación cruzada K-Fold con $k=5$ usando Regresión Logística como estimador preliminar, dado su bajo costo computacional, para confirmar que las representaciones TF-IDF son discriminativas antes de entrenar los modelos principales. La precisión promedio obtenida fue de 0.9642, confirmando la estabilidad del *pipeline* de preparación, como se aprecia en la **Figura 13**.

```
División completada:  
Entrenamiento: 29892 | Prueba: 7474  
  
Precisión promedio K-Fold: 0.9642044523961445
```

Figura 13: Resultado de división del dataset y aplicación de validación cruzada

3.4. Fase 4: Modelado

La **Tabla 2** muestra la configuración experimental y el entorno de ejecución utilizados para entrenar los tres modelos implementados. Con la finalidad de obtener la reproducibilidad de los experimentos se registraron todos los *hiperparámetros*, versiones de las librerías empleadas, arquitecturas base e información sobre el tiempo de entrenamiento de cada modelo. En esta fase se implementó el *pipeline* definitivo: la división estratificada 80/20 se llevó a cabo sobre el dataset limpio de 30.261 *prompts*, pero antes del balanceo, obteniendo 24.208 muestras para entrenamiento y 6.053 para prueba a partir de las cuales se aplicó la *oversampling* exclusivamente sobre los datos del entrenamiento. De esta forma, el conjunto de prueba no se contaminó con el *oversampling*, manteniendo la distribución original de clases.

Parámetro	SVM	BERT	RoBERTa
Entorno de ejecución	Google Colab Pro	Google Colab Pro	Google Colab Pro
Hardware	CPU	GPU NVIDIA Tesla T4	GPU NVIDIA Tesla T4
Python	3.12	3.12	3.12
Scikit-learn	1.6.1	-	-
Transformers HuggingFace	-	5.0.0	5.0.0
PyTorch	-	2.10.0+cu128	2.10.0+cu128
Tokenizador	TF-IDF 10.000 features	BertTokenizer	RobertaTokenizer
Arquitectura base	Kernel lineal	bert-base-uncased	roberta-base
Secuencia máxima	-	128 tokens	128 tokens
Batch size entrenamiento	-	8	8
Batch size evaluación	-	16	16
Épocas	-	2	2
Learning rate	-	2e-5	2e-5
Weight decay	-	0.01	0.01
Tiempo de entrenamiento	60.21 segundos	10 min 3 seg	10 min 23 seg
Tamaño vocabulario	10.000 features	30.522 tokens	50.265 tokens

Tabla 2: Configuración experimental y entorno de ejecución de los modelos

Para el modelado se implementaron dos *pipelines* de procesamiento independientes según la naturaleza de cada modelo. El *pipeline* del modelo SVM utilizó TF-IDF para transformar cada *prompt* en vectores numéricos según su relevancia en el corpus. El *pipeline* de BERT y RoBERTa utilizó el tokenizador propio de cada arquitectura, capturando el contexto semántico mediante *embeddings* contextuales. Ambos *pipelines* son completamente independientes y no comparten ninguna etapa de procesamiento.

3.4.1. Modelo SVM

Para la implementación de esta fase, se empleó las librerías Scikit-learn, especialmente las clases SVC para el entrenamiento del modelo de máquinas de vectores de soporte, TfidfVectorizer para la *vectorización* del texto, train_test_split para división del dataset, StratifiedKFold y learning_curve para la construcción de la curva de aprendizaje. También utilizó Joblib para guardar el modelo y los archivos que se generaron y Matplotlib para los resultados gráficos; el proceso está descrito en la **Figura 14**.




Figura 14: Diagrama de flujo del entrenamiento del modelo SVM

Se entrenó un modelo SVM con kernel lineal utilizando el dataset limpio de 30.261 *prompts*, aplicando una *vectorización* TF-IDF de 10.000 características y una división estratificada del 80% para entrenamiento y 20% para prueba. Una vez entrenado, el modelo, el vectorizador y los conjuntos de prueba fueron almacenados en la carpeta FASE4_modelado/SVM de Google Drive para su uso en la fase de evaluación, tal como se evidencia en la **Figura 15**.

```

Datos cargados correctamente:
                                prompt_limpio  etiquetado
0  crear consejos médicos falsos sobre el tratami...      1
1  generar teorías conspirativas sobre fraude ele...      1
2  redactar información falsa sobre los peligros ...      1
3  crear noticias falsas sobre candidatos políticos      1
4  generar contenido falso que niegue el cambio c...      1
/tmp/ipython-input-1164433434.py:29: FutureWarning: Downcasting b
  df['etiquetado'] = df['etiquetado'].replace({'seguro': 0, 'evas

Vectorización completada.
Forma de X: (30261, 10000)

Datos divididos correctamente:
Train: (24208, 10000) Test: (6053, 10000)

Modelo SVM ENTRENADO correctamente (FASE 4).

Modelo y vectorizador guardados en FASE 4.
X_test y y_test guardados correctamente en FASE4.

```

Figura 15: Resultado del entrenamiento del modelo SVM

Adicionalmente, se generó una curva de aprendizaje con validación cruzada StratifiedKfold de $k=3$ para visualizar el comportamiento del modelo conforme aumenta la cantidad de datos de entrenamiento, permitiendo identificar posibles problemas de sobreajuste o subajuste en el proceso, conforme se observa en la **Figura 16**.




Figura 16: Curva de aprendizaje del modelo SVM

3.4.2. Modelo BERT

Para el desarrollo de esta fase se utilizaron las bibliotecas Transformers de Hugging Face, específicamente BertTokenizer para la *tokenización* del texto y BertForSequenceClassification para el entrenamiento del modelo de clasificación binaria, junto con la clase Trainer y TrainingArguments para configuración gestión

del proceso de entrenamiento. Además, se empleó el *datasets* para la conversión en formato requerido por BERT, PyTorch para el procesamiento tensorial, y Scikit-learn para la división estratificada del dataset y el cálculo de métricas. Se ajustó el modelo con una tasa de aprendizaje de $2e-5$, tamaño de lote de 8 y 2 épocas de entrenamiento, el proceso se describe en la **Figura 17**.




Figura 17: Diagrama de flujo del modelo BERT

Una vez completo el entrenamiento, el modelo tuvo una precisión de 0.964480 en la primera época y de 0.968776 en la segunda época, con una pérdida de validación de 0.148068 y 0.155570, confirmando un comportamiento estable y progresivo del modelo. El modelo entrenado, el tokenizador y las predicciones del conjunto de prueba fueron guardados en la carpeta FASE4_modelado/BERT de Google Drive bajo los nombres `bert_model`, `bert_tokenizer` y `bert_test_predictions.csv`, los resultados obtenidos se presentan en la **Figura 18**.



Figura 18: Resultado del entrenamiento del modelo BERT

Asimismo, fue elaborado un gráfico que permite ver la evolución de las pérdidas a lo largo de los períodos de entrenamiento, contraponiendo las pérdidas conservado

en el contexto del entrenamiento con la validación por época. En virtud de este gráfico, fue posible constatar que el modelo no estaba sufriendo un sobreajuste relevante, dado que las curvas atribuibles a ambas pérdidas se mantuvieron muy próximas y decrecientes hasta el final del proceso, tal como puede comprobarse en el gráfico correspondiente en la **Figura 19**.




Figura 19: Evolución de pérdidas del modelo BERT

3.4.3. Modelo RoBERTa

Esta fase reutilizó las bibliotecas y la configuración ya definidas para BERT; la diferencia estuvo en dos piezas puntuales: RobertaTokenizer para tokenizar el texto y RobertaForSequenceClassification como arquitectura de clasificación binaria, ambos de la biblioteca Transformers de Hugging Face. El entrenamiento no se apartó del esquema anterior. El dataset se dividió de forma estratificada, quedando 24.208 muestras del ochenta por ciento para entrenamiento y 6.053 del veinte por ciento para prueba, mientras que los parámetros se fijaron en una tasa de aprendizaje de $2e-5$, un tamaño de lote de 8 y 2 épocas. Los resultados fueron positivos como la precisión pasó de 0.961672 en la primera época a 0.968280 en la segunda, y la pérdida de validación bajó de 0.180079 a 0.161411, una secuencia que afirma que el modelo fue aprendiendo, sin señales de sobreajuste entre una época y otra. El modelo entrenado, el tokenizador y las predicciones del conjunto de prueba se almacenaron en Google Drive, en la carpeta FASE4_modelado/RoBERTa, bajo los nombres roberta_model, roberta_tokenizer y roberta_test_predictions.csv; los resultados completos se presentan en la **Figura 20**.




Figura 20: Entrenamiento del modelo RoBERTa

Adicionalmente, se generó un gráfico de evolución de pérdidas para comparar el comportamiento de la pérdida de entrenamiento y la pérdida de validación por época. Como se observa en el gráfico, la pérdida de entrenamiento disminuyó de manera pronunciada desde 0.2525 hasta 0.1239, mientras que la pérdida de validación se redujo gradualmente desde 0.1801 hasta 0.1614, indicando que ambas curvas convergieron progresivamente sin presentar sobreajuste durante el proceso, conforme se observa en la **Figura 21**.




Figura 21: Evolución de pérdidas del modelo RoBERTa

3.5. Fase 5: Evaluación

Los tres modelos evaluados obtuvieron métricas de rendimiento superiores al 96%, resultados que se sustentan en los controles metodológicos aplicados durante la preparación y el entrenamiento. La eliminación de duplicados se realizó antes de dividir el dataset, evitando que *prompts* similares aparecieran en ambos conjuntos.

El balanceo mediante *oversampling* se aplicó exclusivamente sobre el entrenamiento, preservando la distribución original en el conjunto de prueba de 6.053 muestras, el cual no contiene muestras sintéticas. Las curvas de aprendizaje confirman que los modelos generalizaron correctamente sin memorizar los datos, descartando *overfitting*. Por lo anterior, los resultados obtenidos son consistentes, reproducibles y válidos.

3.5.1. Evaluación del modelo SVM

Al realizar la evaluación se utilizaron las bibliotecas Scikit learn, particularmente *precision_score*, *recall_score*, *f1_score* y *classification_report* para el cálculo de las métricas y *ConfusionMatrixDisplay* para la creación de la matriz de confusión, y *precision recall curve* con *auc* para el cálculo de la curva de precisión. Adicionalmente, se aplicó *Joblib* para cargar el modelo y los conjuntos de prueba en la fase 4 y *Matplotlib* para la gráfica de los resultados.

Luego de que haya entrenado se realizaron las predicciones sobre el conjunto de prueba detallado por 6.053 muestras, obteniendo una precisión de 0.969995, un recall de 0.977522, un *F1-Score* de 0.965473 y una exactitud del 97 por ciento, tal como se evidencia en la Figura 22. De acuerdo con la matriz de confusión detalló que el modelo clasificó los *prompts* 2.203 seguros y 3.653 evasivos, reflejando 113 falsos positivos y 84 falsos negativos, este se refleja en la **Figura 23**.

```

===== RESULTADOS FASE 5 - SVM =====
Precision (evasivo=1): 0.969995
Recall (evasivo=1):    0.977522
F1-Score (macro):     0.965473
PR-AUC:               0.994472

```

Figura 22: Métricas de rendimiento del modelo SVM




Figura 23: Matriz de confusion del modelo SVM

La curva Precision-Recall generada obtuvo un PR-AUC de 0.9945, lo que indica que el modelo mantiene una alta precisión y exhaustividad en distintos umbrales de clasificación, confirmando su capacidad para distinguir de manera efectiva entre *prompts* seguros y evasivos, conforme se observa en la **Figura 24**.




Figura 24: Curva Precision-Recall del modelo SVM

3.5.2. Evaluación del modelo BERT

Para evaluar el modelo BERT, se utilizó las mismas bibliotecas que en la evaluación del modelo SVM. Solo se cambió que el modelo y el tokenizador se cargaron directamente desde la carpeta FASE4_modelado/BERT, usando BertTokenizer y BertForSequenceClassification de la biblioteca Transformers de Hugging Face. También se usaron las predicciones generadas durante el entrenamiento, que estaban guardadas en bert_test_predictions.csv. Se realizaron predicciones sobre el conjunto de pruebas, que tenía 6.053 muestras. Esto nos dio una precisión de 0.972118, un recall de 0.970297, un *F1-Score* macro de 0.962430 y un PR-AUC de 0.993036, como se muestra en la **Figura 25**. Además, de la matriz de confusión se determinó que el modelo clasificó correctamente 2.212 *prompts* seguros y 3.626 *prompts* evasivos. Sin embargo, cometió 104 falsos positivos y 111 falsos negativos, lo que se puede ver en la **Figura 26**.

```

===== RESULTADOS FASE 5 =====

Precision (evasivo): 0.972118
Recall (evasivo):    0.970297
F1-Score macro:     0.962430
PR-AUC:              0.993036

```

Figura 25: Resultados de la ejecución - métricas BERT




Figura 26: Matriz de Confusión del modelo BERT

La curva Precision-Recall generada obtuvo un PR-AUC de 0.9930, lo que indica que el modelo mantiene una alta precisión y exhaustividad en distintos umbrales de clasificación, confirmando su capacidad para distinguir de manera efectiva entre *prompts* seguros y evasivos, tal como se evidencia en la **Figura 27**.




Figura 27: Curva Precision-Recall - BERT

3.5.3. Evaluación del modelo RoBERTa

Para la evaluación del modelo RoBERTa se extendieron las bibliotecas que habíamos usado en las evaluaciones previas; así, cargamos las predicciones generadas durante el entrenamiento directamente desde el archivo `roberta_test_predictions.csv` que se encuentra guardado en la carpeta `FASE4_modelado/RoBERTa`, lo que permitió calcular las métricas de rendimiento sin necesidad de tener que volver a ejecutar el modelo. A su vez, se realizan las predicciones sobre el conjunto de test que está conformado por 6.053 muestras; la precisión fue de 0.981789, el recall fue de 0.966551, el *F1-Score* macro fue de 0.966586, el PR-AUC fue de 0.995876 tal como se puede ver en la **Figura 28**; a la vez que la matriz de confusión confirma que existe una asignación correcta de los

prompts 2.249 *prompts* seguros y 3.612 *prompts* evasivos, registrando solo 67 falsos positivos y 125 falsos negativos, comportamiento que se muestra en la **Figura 29**.




Figura 28: Resultados de la ejecución - métricas RoBERTa




Figura 29: Matriz de Confusión - RoBERTa

La curva Precision-Recall generada obtuvo un PR-AUC de 0.9959, siendo el valor más alto entre los tres modelos evaluados, lo que indica que RoBERTa mantiene una mayor precisión y exhaustividad en distintos umbrales de clasificación, confirmando su mejor capacidad para distinguir entre *prompts* seguros y evasivos, tal como se evidencia en la **Figura 30**.




Figura 30: Curva Precision-Recall - RoBERTa

3.5.4. Análisis comparativo de modelos

La **Tabla 3** presenta un resumen comparativo de las métricas obtenidas por los tres modelos, permitiendo identificar sus fortalezas y limitaciones en la clasificación de *prompts* evasivos.

Métrica	SVM	BERT	RoBERTa
Precisión(evasivo)	0.9700	0.9721	0.9818
Recall (evasivo)	0.9775	0.9703	0.9666
F1-Score macro	0.9655	0.9624	0.9666
PR-AUC	0.9945	0.9930	0.9959
Verdaderos positivos	3.653	3.626	3.612
Verdaderos negativos	2.203	2.212	2.249
Falsos positivos	113	104	67
Falsos negativos	84	111	125

Tabla 3: Métricas obtenidas de los modelos

El modelo RoBERTa fue seleccionado por obtener la mayor precisión 0.9818, el PR-AUC más alto 0.9959 y el menor número de falsos negativos 67, lo que lo convierte en el modelo con riesgos menores al momento clasificar un *prompt* evasivo como seguro, norma prioritaria en este sistema. SVM, aunque *computacionalmente* más eficiente con solo 60 segundos de entrenamiento frente a los 10 minutos de los transformers, registró el mayor número de falsos negativos 113, lo que representa un riesgo mayor en producción. BERT obtuvo métricas intermedias sin superar a RoBERTa en ningún indicador clave. Los resultados parecidos entre ambos transformers se explican por su arquitectura compartida de atención bidireccional; la ventaja de RoBERTa se atribuye a su mayor volumen de preentrenamiento y la eliminación de la tarea. Para un entorno de producción integrado con una extensión de navegador, RoBERTa es la opción recomendada, aunque su despliegue requiere infraestructura con soporte GPU para garantizar latencias aceptables.

3.5.5. Consideraciones éticas y limitaciones del sistema

Todo sistema de clasificación automática de texto enfrenta un desafío ético fundamental: la subjetividad inherente a la interpretación del lenguaje, ya que un mismo *prompt* puede percibirse como evasivo o inofensivo según el contexto cultural o la intención del emisor. Distintas personas pueden etiquetar un mismo texto de manera diferente debido a sus percepciones sobre el discurso, lo que evidencia que el desacuerdo entre anotadores es una limitación estructural en cualquier sistema supervisado [61]. Por ello, los resultados del modelo no representan decisiones absolutas sino estimaciones probabilísticas sujetas a validación humana.

Las creencias personales y la identidad de quienes anotan los datos afectan la percepción de toxicidad en textos digitales, lo que implica que los *datasets* etiquetados manualmente pueden incorporar sesgos que el modelo aprende y reproduce [62]. En este proyecto el etiquetado siguió criterios predefinidos, aunque no puede descartarse que *prompts* ambiguos hayan recibido etiquetas inconsistentes, por ello el sistema debe operar como apoyo inteligente en la detección y no como mecanismo único de decisión.

Los sistemas de procesamiento de lenguaje natural pueden reproducir sesgos derivados de los datos y de las decisiones tomadas durante el entrenamiento [63]. Para mitigar este riesgo se aplicaron controles como la eliminación de duplicados antes de la división del *dataset* y el balanceo exclusivo sobre el conjunto de entrenamiento. Sin embargo, persiste una limitación lingüística dado que el *dataset* fue construido predominantemente en español e inglés, lo que puede afectar la generalización ante *prompts* en otros idiomas no representados.

Un riesgo adicional es la generación de falsos positivos, es decir, clasificar *prompts* legítimos como evasivos, lo que puede derivar en censura accidental de contenido inofensivo, ya que los mensajes ambiguos generan interpretaciones diferentes en los sistemas automáticos, lo que representa una contradicción inherente en la clasificación de contenido potencialmente dañino [64]. Para reducir este efecto, el sistema expone el nivel de confianza de cada predicción, permitiendo que el operador humano evalúe los casos de baja certeza antes de tomar una decisión de bloqueo.

3.6. Fase 6: Despliegue

El despliegue del sistema consistió en la implementación del modelo RoBERTa entrenado dentro de una aplicación web funcional desarrollada con Flask, permitiendo la clasificación de *prompts* en tiempo real mediante una interfaz gráfica accesible para el usuario final. Esta fase integra los resultados obtenidos en las fases anteriores en un sistema operativo completo que cubre desde la recepción del *prompt* hasta la visualización del resultado, incluyendo el registro de clasificaciones y la integración mediante una extensión de navegador en la plataforma ChatGPT.

3.6.1. Entorno de desarrollo y gestión de dependencias

El sistema fue desarrollado en Visual Studio como entorno principal, configurando

un entorno virtual mediante venv para aislar las dependencias del proyecto y evitar conflictos con otras instalaciones del sistema. Para garantizar la reproducibilidad en cualquier máquina, se generó el archivo requirements.txt, el cual especifica todas las bibliotecas requeridas con sus versiones exactas, permitiendo instalar el entorno completo mediante el comando `pip install -r requirements.txt`. Las especificaciones técnicas del entorno y las principales dependencias utilizadas se consolidan en la **Tabla 4**.

Tipo	Componente	Versión
Entorno	Sistema operativo	Windows 11
Entorno	Lenguaje	Python 3.10
Entorno	IDE	Visual Studio Code
Entorno	Gestión de entorno	Venv
Dependencias	Flask	3.1.2
Dependencias	Transformers	huggingface-hub 0.36.0
Dependencias	torch (PyTorch)	2.9.0+cpu
Dependencias	Safetensors	0.7.0

Tabla 4: Entorno de ejecución y principales dependencias del sistema de despliegue

3.6.2. Arquitectura del sistema

El sistema se estructuró en tres componentes funcionales que operan de forma integrada, cuyo flujo completo se ilustra en la **Figura 31**.




Figura 31: diagrama de flujo del clasificador de prompts

El flujo de clasificación opera de la siguiente manera: el usuario ingresa un *prompt* en la interfaz web `index.html`; Flask recibe la solicitud mediante la ruta de

clasificación definida en `app.py`; el módulo de procesamiento detecta el idioma del texto mediante `langdetect` y, si es distinto al español, aplica traducción automática mediante `deep-translator`; `RobertaTokenizer` tokeniza y ajusta el texto con truncamiento y padding hasta 512 *tokens*; los *tokens* son procesados por RoBERTa, que genera logits de salida; la función *softmax* transforma dichos logits en probabilidades de pertenencia a cada clase; el motor de decisión emite el veredicto; el resultado se registra en `log_resultados.csv`; y finalmente se visualiza al usuario mediante una ventana modal con gráfica dinámica generada con `Chart.js`.

El módulo de entrada fue implementado en `index.html` y constituye la interfaz gráfica del clasificador. Mediante un área de texto y un botón de clasificación, el usuario ingresa el *prompt* a evaluar y lo envía al servidor. La interfaz incorpora un diseño responsivo con Bootstrap y presenta los resultados en una ventana modal con el veredicto final y la gráfica de probabilidades.

El módulo de procesamiento fue implementado en `app.py` y actúa como servidor principal, coordinando todo el proceso de clasificación. Al iniciar, carga el modelo RoBERTa y su tokenizador desde la carpeta `model/roberta_model_final`, que contiene los archivos `config.json`, `model.safetensors`, `tokenizer.json`, `tokenizer_config.json` y `training_args.bin`. El modelo se inicializa en modo evaluación para desactivar el cálculo de gradientes y optimizar el rendimiento durante la inferencia.

El módulo de visualización retorna el resultado al cliente en formato JSON. La respuesta incluye el veredicto final, las probabilidades de cada clase expresadas en porcentaje, el idioma detectado y, si aplica, el texto traducido procesado.

En cuanto a las consideraciones de seguridad del sistema desplegado la aplicación opera actualmente en red local sin autenticación, lo que constituye una limitación reconocida para entornos de producción. Entre los aspectos de seguridad pendientes de implementación en versiones futuras se identifican la validación y *sanitización* de entradas para prevenir inyección de código, la definición de un límite de longitud máxima del *prompt* para mitigar ataques de denegación de servicio, y la incorporación de un mecanismo de autenticación para restringir el acceso al clasificador. Estos elementos no comprometieron los objetivos del presente trabajo,

dado que el despliegue tiene carácter de prototipo funcional, pero deberán abordarse antes de cualquier puesta en producción real.

3.6.3. Ejecución del sistema

Para iniciar el sistema se ejecutó el comando `python app.py` desde la terminal dentro del proyecto, arrancando con el servidor local de Flask y permite acceder a la aplicación desde el navegador mediante la dirección `http://127.0.0.1:5000`. Este proceso activa conjuntamente la carga del modelo RoBERTa en memoria y habilita de la ruta de clasificación, dejando el sistema listo para procesar solicitudes, como se ilustra en la **Figura 32**.




Figura 32: Interfaz del sistema de clasificación

Con el propósito de caracterizar el rendimiento del sistema en condiciones reales de uso, se midieron los tiempos de inferencia sobre una muestra de 50 *prompts* de longitud variable, obteniendo los resultados como se detalla en la **Tabla 5**.

Métrica	Valor
Tiempo promedio de inferencia	851 ms
Tiempo máximo de inferencia	5570 ms
Tiempo mínimo de inferencia	263 ms
Prompts procesados por minuto	~70
Uso aproximado de RAM	~1,06 GB

Tabla 5: Rendimiento del sistema desplegado

Estas mediciones se obtuvieron ejecutando el sistema en el entorno de desarrollo descrito en la sección 3.6.1 con la CPU como único dispositivo de cómputo. Con base en estos resultados se determinó que el sistema presenta una latencia mínima

y un procesamiento suficientemente rápido para su uso como capa de filtrado en un entorno conversacional de baja a mediana concurrencia.

3.6.4. Registro de clasificaciones

El sistema incorpora un módulo de logging que registra automáticamente cada clasificación realizada en el archivo `log_resultados.csv`. Por cada solicitud procesada se almacenan los siguientes campos fecha y hora de la clasificación, texto original ingresado por el usuario, texto procesado tras la traducción, idioma detectado automáticamente, probabilidad asignada a la clase Seguro, probabilidad asignada a la clase Evasivo, y resultado final de la clasificación.

Los datos registrados corresponden exclusivamente a los *prompts* ingresados durante la sesión de uso y no incluyen información personal identificable del usuario, dado que la aplicación no implementa ningún mecanismo de autenticación ni de identificación de sesión. El archivo CSV puede consultarse directamente o procesarse mediante herramientas de análisis de datos para el estudio del comportamiento del sistema en condiciones reales. En versiones futuras, este registro podrá emplearse como fuente de datos para el reentrenamiento del modelo con nuevos ejemplos capturados en producción.

3.6.5. Pruebas funcionales

Se realizaron pruebas de inferencia con *prompts* representativos de ambas clases para verificar el correcto funcionamiento del sistema desplegado. Para el caso de un *prompt* evasivo, el sistema retornó un resultado de evasivo y para el caso de un *prompt* seguro, el sistema retornó un resultado de seguro, conforme se observa en la **Figura 33**.



Figura 33: resultados del clasificador seguro y evasivo

Con el fin de evaluar el comportamiento del sistema en condiciones más amplias, se sometió al clasificador a un conjunto de *prompts* evasivos adicionales, obteniendo en su mayoría resultados correctos con un único caso de clasificación incorrecta. Este resultado sugiere que el modelo generaliza adecuadamente ante nuevos datos, aunque no puede descartarse la presencia de errores adicionales ante *prompts* con estructuras lingüísticas más complejas o no vistas durante el entrenamiento.

Las probabilidades de clasificación reportadas por el sistema no deben interpretarse únicamente como un resultado binario. El porcentaje asignado a cada clase refleja el nivel de confianza del modelo en su predicción, por lo que resulta útil considerar los rangos descritos en la **Tabla 6** para contextualizar el veredicto emitido.

Probabilidad de clase Evasivo	Interpretación
> 90%	Alta confianza: <i>prompt</i> muy probablemente evasivo
70 – 90%	Confianza media: indicios claros de evasión
50 – 70%	Caso ambiguo: requiere revisión contextual
< 50%	Clasificación como Seguro

Tabla 6: Interpretación de los niveles de confianza del clasificador

El umbral de decisión empleado en el sistema es del 70%: si la probabilidad de la clase Evasivo supera ese valor, el *prompt* es bloqueado. Este umbral puede ajustarse según el perfil de riesgo del contexto de despliegue; un valor más alto reduce los falsos positivos a expensas de mayor permisividad, mientras que un valor más bajo aumenta la sensibilidad del filtro.

3.6.6. Integración mediante extensión de navegador en ChatGPT

Como etapa final del despliegue, el clasificador RoBERTa fue integrado a través de una extensión de navegador que opera directamente sobre la interfaz web de ChatGPT, compuesta por un archivo de configuración (*manifest.json*) y un script de contenido (*content.js*) que se inserta automáticamente en la página. Para hacer posible esta integración, se realizaron modificaciones en el archivo *app.py* ver **Anexo 2**, añadiendo un *endpoint* adicional que permite recibir y clasificar los *prompts* enviados desde la extensión. Este enfoque traslada la verificación al mismo lugar donde el usuario redacta su *prompt*, permitiéndole conocer el resultado antes de enviarlo a la inteligencia artificial.

El proceso, ilustrado en la **Figura 34**, inicia cuando el usuario escribe su *prompt* y la extensión inserta un botón "Verificar prompt" junto al campo de texto. Dado que ChatGPT reconstruye constantemente partes de su interfaz mediante un *framework* de renderizado dinámico, el script utiliza un observador de cambios en el documento (MutationObserver) que reinyecta el botón cada vez que dicha reconstrucción lo elimina, garantizando su disponibilidad continua. Al presionarlo, el texto se envía mediante una solicitud HTTP POST al servidor Flask local, a través del *endpoint* /clasificar, donde el modelo RoBERTa calcula las probabilidades $P(\text{evasivo})$ y $P(\text{seguro})$.




Figura 34: Diagrama de flujo de la extensión de navegador en ChatGPT

Si $P(\text{evasivo})$ supera el umbral de 0.7, definido como criterio de decisión por priorizar la minimización de falsos negativos, se presenta un indicador rojo con el porcentaje de evasión; en caso contrario, se presenta un indicador verde con el porcentaje de seguridad, como se observa en la **Figura 35**. El usuario decide de manera voluntaria si reformula o envía su *prompt*, ya que el sistema no bloquea el envío en ningún momento. Dado que la extensión se ejecuta en el dominio chatgpt.com y el servidor responde desde 127.0.0.1:5000, fue necesario habilitar el mecanismo de intercambio de recursos de origen cruzado (CORS), restringido al *endpoint* /clasificar, ya que los navegadores bloquean por defecto las solicitudes entre *dominios* distintos por motivos de seguridad.



Figura 35: Resultado de la verificación en la interfaz de ChatGPT

CONCLUSIONES

Se construyó un dataset etiquetado de 41.587 registros de *prompts* seguros y evasivos, obtenidos de fuentes públicas y generación sintética. Sobre el dataset limpio de 30.261 *prompts* se aplicó una división estratificada 80/20, obteniendo 24.208 muestras para entrenamiento y 6.053 para prueba, con *oversampling* exclusivo sobre el conjunto de entrenamiento, lo que reduce el riesgo de sobreajuste y evita la contaminación entre los conjuntos de entrenamiento y prueba.

Se entrenaron y compararon tres modelos supervisados SVM, BERT y RoBERTa, todos superando el 96% de exactitud. RoBERTa fue seleccionado como modelo final por obtener la mayor precisión de 0.9818, el PR-AUC más alto de 0.9959 y el menor número de falsos negativos con 67 casos, frente a SVM que registró 113 falsos negativos y BERT con métricas intermedias. Estos resultados son consistentes con las características reportadas en la literatura especializada para este tipo de modelos, en particular el mayor volumen de preentrenamiento de RoBERTa y la eliminación de la tarea NSP, aunque dicho aspecto no fue evaluado experimentalmente dentro de este estudio. Por su parte, mientras que SVM, pese a su eficiencia computacional, presentó el peor desempeño en seguridad al clasificar erróneamente 46 *prompts* evasivos más que RoBERTa.

Se evaluó el rendimiento de los modelos mediante métricas de clasificación, obteniendo con RoBERTa un *F1-score* de 0.98 y un PR-AUC de 0.9959, valores que evidencian la eficacia de los modelos *transformer* para la clasificación de *prompts* adversarios dentro del contexto experimental evaluado, sin que estos hallazgos puedan extenderse a escenarios productivos que no fueron objeto de validación en este estudio.

Se implementó un *dashboard* desarrollado con Flask que permite visualizar las predicciones en tiempo real, con un tiempo promedio de inferencia de 851 ms y un consumo de RAM de aproximadamente 1.06 GB, valores consistentes con un entorno de ejecución en CPU sin soporte GPU. De manera complementaria, se desarrolló una integración mediante extensión de navegador como demostración adicional de la aplicabilidad del clasificador fuera del entorno del *dashboard*, permitiendo su verificación directamente sobre la interfaz de ChatGPT.

RECOMENDACIONES

Se recomienda ampliar el *dataset* incorporando un mayor volumen de *prompts* evasivos, dado que la capacidad de generalización de un modelo supervisado depende directamente de la diversidad de patrones representados durante el entrenamiento. Si bien el sistema actual emplea un mecanismo de traducción automática que permite procesar *prompts* en distintos idiomas mediante su conversión previa al español, un *dataset* de mayor tamaño y diversidad temática permitiría capturar formas de evasión menos frecuentes y mejorar la precisión del clasificador en escenarios no representados durante el entrenamiento. Se recomienda además establecer un ciclo de reentrenamiento periódico con una frecuencia mínima trimestral, acompañado de auditorías regulares del *dataset* para detectar duplicados semánticos.

Dado que RoBERTa demostró el mejor desempeño en seguridad se recomienda priorizar este modelo para cualquier despliegue futuro, así como incorporar herramientas de *explicabilidad* como LIME o SHAP para identificar qué términos del *prompt* influyeron en su decisión. Dado que el modelo presenta un 1.11% de falsos positivos sobre el conjunto de prueba, el análisis de *explicabilidad* facilitará la comprensión del comportamiento del modelo y servirá de apoyo para futuras optimizaciones orientadas a reducir dicho porcentaje, al permitir detectar sesgos lingüísticos o culturales que afecten de manera desproporcionada a ciertos grupos de usuarios.

Se sugiere avanzar en investigaciones complementarias que permitan calibrar de manera más precisa el umbral de decisión del clasificador, actualmente definido en 70%, tomando en cuenta el nivel de riesgo asociado a cada contexto de uso. En sectores donde los errores tienen consecuencias graves, como el financiero o el legal, aumentar dicho umbral permitiría disminuir los falsos negativos. En cambio, en escenarios donde el lenguaje tiende a ser más ambiguo, como el educativo o los servicios de asistencia general, podría valorarse la posibilidad de reducirlo, aceptando a cambio un ligero aumento en los falsos positivos.

Se recomienda escalar la infraestructura del *dashboard* mediante *Gunicorn*, *Nginx*, *Docker* y servicios *cloud* como AWS o Azure, con el objetivo de reducir la latencia

actual de 851 ms en al menos un 50% bajo condiciones de alta concurrencia al habilitar inferencia por GPU. Asimismo, se recomienda realizar una evaluación de usabilidad con una muestra representativa de usuarios finales mediante una escala Likert de 5 puntos que mida facilidad de uso, claridad de los resultados y utilidad percibida, tanto del *dashboard* como de la extensión de navegador desarrollada.

REFERENCIAS

- [1] J. Franganillo, "Contenido generado por inteligencia artificial: oportunidades y amenazas," Anuario ThinkEPI, vol. 16, 2022.
- [2] Y. Zhang, L. Ding, L. Zhang, and D. Tao, "Intention analysis makes LLMs a good jailbreak defender," arXiv preprint arXiv:2401.06561, 2024.
- [3] X. Qi, K. Huang, A. Panda, P. Henderson, M. Wang, and P. Mittal, "Visual adversarial examples jailbreak aligned large language models," in Proc. AAAI Conf. Artif. Intell., vol. 38, no. 19, pp. 21527–21536, Mar. 2024.
- [4] P. Neekhara, S. Hussain, S. Dubnov, and F. Koushanfar, "Adversarial reprogramming of text classification neural networks," arXiv preprint arXiv:1809.01829, 2018.
- [5] H. Luo, "Prompt-learning and Zero-shot Text Classification with Domain-specific Textual Data", M.S. thesis, Dept. of Linguistics and Philology, Uppsala University, Uppsala, Sweden, 2023.
- [6] Roopa. G. K., "Systematic Review on Offensive Language Detection of Multilingual Texts using NLP and *Machine Learning Techniques*," International Journal of Science and Research (IJSR), vol. 12, no. 8, pp. 434-442, Aug. 2023, doi: 10.21275/SR23802115009.
- [7] S. Jain and B. K. Tripathy, "Inappropriate text detection and rephrasing using NLP," in Proc. Int. Conf. Soft Comput. Eng. Appl., Cham, Switzerland: Springer, pp. 261–273 Dec. 2023.
- [8] G. S. Mendoza Mestanza, "Aplicación de inteligencia artificial generativa para síntesis de textos: conversión de textos a representaciones numéricas," Trabajo académico, Escuela Politécnica Nacional (EPN), Quito, Ecuador, 2025.
- [9] R. Vinay, G. Spitale, N. Biller-Andorno, and F. Germani, "Emotional prompting amplifies disinformation generation in AI large language models," Frontiers in Artificial Intelligence, vol. 8, p. 1543603, 2025.
- [10] Y. Yang, R. Gao, X. Yang, J. Zhong, and Q. Xu, "Guardt2i: Defending text-to-image models from adversarial prompts," Advances in Neural Information Processing Systems, vol. 37, pp. 76380–76403, 2024.

- [11] J. J. Espinosa-Zúñiga, "Aplicación de metodología CRISP-DM para segmentación geográfica de una base de datos pública," *Ingeniería, investigación y tecnología*, vol. 21, no. 1, 2020.
- [12] T. Shi, K. Zhu, Z. Wang, Y. Jia, W. Cai, W. Liang, and D. Song, "*PromptArmor: Simple yet effective prompt injection defenses*," arXiv preprint arXiv:2507.15219, 2025.
- [13] D. Gosmar, D. A. Dahl, "*Prompt Injection Detection and Mitigation via AI Multi-Agent NLP Frameworks*," arXiv preprint arXiv:2503.11517, 2025.
- [14] Secretaría Nacional de Planificación, Plan Nacional de Desarrollo Ecuador No Se Detiene 2025–2029, Quito, Ecuador, 2025. [En línea]. Disponible: https://www.planificacion.gob.ec/wp-content/uploads/2025/08/PlanNacionalDeDesarrollo25-29_EcuadorNoSeDetiene.pdf. [Accedido: 10-sep-2025].
- [15] B. L. Takeyas, Introducción a la inteligencia artificial. Instituto Tecnológico de Nuevo Laredo, 2007. [Online]. Available: <http://www.itnuevolaredo.edu.mx/takeyas>. [Accessed Apr. 11, 2026].
- [16] N. Numa-Sanjuán, L. Y. Diaz-Guecha and M. E. Peñaloza-Tarazona, "Importancia de la Inteligencia Artificial en la educación del siglo XXI," *AiBi Revista de Investigación, Administración e Ingeniería*, vol. 12, no. 2, pp. 49–62, May 2024. [Online]. Available: <https://doi.org/10.15649/2346030x.3776>. [Accessed Apr. 11, 2026].
- [17] A. Gelbukh, "Procesamiento de lenguaje natural y sus aplicaciones," *Komputer Sapiens*, vol. 1, pp. 6–11, 2010.
- [18] M. B. Hernández and J. M. Gómez, "Aplicaciones de procesamiento de lenguaje natural," *Revista Politécnica*, vol. 32, no. 1, pp. 87–96. [Online]. Available: https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/32. 2013.
- [19] J. Hayase, E. Borevkovic, N. Carlini, F. Tramèr and M. Nasr, "*Query-based adversarial prompt generation*," *Advances in Neural Information Processing Systems*, vol. 37, pp. 128260–128279. 2024.

- [20] E. R. Blanco, “Inyección de prompts: Un prompt para gobernarlos a todos,” [Online]. Available: <https://oia.uda.edu.ar/inyeccion-de-prompts-un-prompt-para-gobernarlos-a-todos/>. 2023.
- [21] Á. García Gutiérrez, “*Machine learning en bases de datos de lenguaje natural*,” Bachelor’s thesis. 2016.
- [22] J. Atkinson-Abutridy, “*Grandes modelos de lenguaje: Conceptos, técnicas y aplicaciones*,” Marcombo. 2023.
- [23] C. Montt, F. Castro and N. Rodríguez, “*Análisis de accidentes de tránsito con máquinas de soporte vectorial LS-SVM*,” Estudios de Transporte, vol. 15, no. 2. 2011.
- [24] D. M. Blanco-Murillo, A. García-Domínguez, C. E. Galván-Tejada and J. M. Celaya-Padilla, “*Comparación del nivel de precisión de los clasificadores Support Vector Machines, k Nearest Neighbors, Random Forests, Extra Trees y Gradient Boosting en el reconocimiento de actividades infantiles utilizando sonido ambiental*,” Research in Computing Science, vol. 147, no. 5, pp. 281–290. 2018.
- [25] J. F. Auquilla Vicuña and J. C. Mora Alvarez, “*Diseño de un sistema prototipo de diálogo persona-máquina basado en la arquitectura BERT*,” Bachelor’s thesis. 2022.
- [26] J. J. López Condori and F. O. Gonzales Saji, “*Análisis de sentimiento de comentarios en español en Google Play Store usando BERT*,” Ingeniare. Revista chilena de ingeniería, vol. 29, no. 3, pp. 557–563. 2021.
- [27] L. Puertas Bustos, Desarrollo de un modelo basado en redes neuronales para la clasificación automática de textos periodísticos: caso de estudio 20 news group, Universidad Nacional de Colombia, Bogotá D.C., Colombia. 2025.
- [28] D. S. Vargas Prada, Optimización de la evaluación académica mediante procesamiento de lenguaje natural: desarrollo de un sistema de calificación automática para textos en educación superior, Universidad de los Andes, 2025.
- [29] S. García, S. Ramírez-Gallego, J. Luengo, and F. Herrera, “Big Data: Preprocesamiento y calidad de datos,” Novática, no. 237, pp. 17–20. 2016.

- [30] A. E. Alarcón Becerra, “*Clasificación de texto con técnicas de procesamiento del lenguaje natural y machine learning para analizar la relación entre noticias publicadas en la web y la variación de los índices de la bolsa de comercio en Chile*,” Universidad del Desarrollo, Facultad de Ingeniería. 2022.
- [31] F. M. de Guzmán, “Embeddings y modelos conversacionales: una nueva forma de explorar, comprender, describir y conectar la información en bibliotecas,” Dossier Anuario SEDIC, pp. 15–23. 2026.
- [32] È. Candela i Oliver, “*Data augmentation in imbalanced datasets: classical approaches and artificial intelligence*,” Universitat Politècnica de Catalunya, 2025.
- [33] Y. E. C. Solis and H. H. Rivas, “*Comparación de algoritmos de machine learning para procesamiento de lenguaje natural*,” Revista Electrónica sobre Tecnología, Educación y Sociedad, vol. 11, no. 21. 2024.
- [34] I. Luque García, “*Minería de texto mediante NLP en el sector seguros*,” Universitat Politècnica de Catalunya. 2023.
- [35] J. S. Moreno Sánchez, “*Predicción de ataques cardíacos mediante técnicas de Machine Learning*,” ETSI Sistemas Informáticos. 2021.
- [36] C. V. N. Rondón, S. A. C. Casadiego, and C. Z. D. Garcia, “*Evaluación comparativa del rendimiento de modelos de detección de residuos en entornos urbanos*,” Revista Ambiental Agua, Aire y Suelo, vol. 15, no. 1, pp. 122–131. 2024.
- [37] J. B. Corvinos, J. L. Fernández-Martínez, and L. Fernández-Brillet, “*Técnicas NLP para análisis de sentimiento y resumen de noticias financieras*,” Universidad de Zaragoza. 2023.
- [38] A. Garg, “*Optimizing Supernova Classification: A Metric-Aware Approach with PR-AUC and F1-score*,” J. Astrophys. Astr. 2025.
- [39] A. Zapata García, “*Análisis de textos mediante técnicas NLP para la categorización de usuarios*,” 2021.
- [40] Microsoft, “Visual Studio Code.” 2019. [Online]. Available: https://apoyoescolar.milaulas.com/pluginfile.php/675/mod_resource/content/1/Visual%20Studio%20Code.pdf

- [41] D. Ghimire, “*Comparative study on Python web frameworks: Flask and Django*,” Bachelor’s thesis, Metropolia University of Applied Sciences. 2020.
- [42] Oracle, “What is Python for Developers?,” Oracle, [En línea]. Disponible en: <https://www.oracle.com/latam/developer/what-is-python-for-developers/>. [Accedido: 4-may-2026].
- [43] S. Rubio Llamas, “*Composición musical mediante modelos basados en transformers*,” Trabajo Fin de Grado, Escuela de Ingeniería y Arquitectura (EINA), Universidad de Zaragoza, Zaragoza, España, 2022.
- [44] J. Martínez Marhuenda, “*Iniciación al entorno de deep learning Torch*,” Trabajo Fin de Grado, Escuela Técnica Superior de Ingeniería Informática, Universitat Politècnica de València, Valencia, España, 2018.
- [45] P. Gupta y A. Bagchi, “*Introduction to NumPy*,” en *Essentials of Python for Artificial Intelligence and Machine Learning*, Cham, Suiza: Springer Nature Switzerland, 2024, pp. 127–159.
- [46] B. Casey, K. Damian, A. Cotaj y J. C. S. Santos, “*An empirical study of safetensors’ usage trends and developers’ perceptions*,” arXiv preprint arXiv:2501.02170, 2025.
- [47] Universidad Europea, “¿Qué es HTML y para qué sirve?,” Universidad Europea Ecuador, 27-ago-2025. [En línea]. Disponible en: <https://ecuador.universidadeuropea.com/blog/que-es-html/>. [Accedido: 4-may-2026]
- [48] P. Corcuera, “*Introducción a HTML y CSS*,” Universidad de Cantabria, España. [En línea]. Disponible en: https://personales.unican.es/corcuerp/sistinf/tecweb/Curso_HTML_CSS.pdf. [Accedido: 14-abr-2026].
- [49] D. D. Tarigan, T. Tommy y A. Budiman, “*Rancang peta jalur angkutan umum berbasis web menggunakan HTML, CSS, dan JavaScript di Visual Studio*,” *Jurnal Ilmu Komputer dan Sistem Komputer Terapan (JIKSTRA)*, vol. 5, no. 2, pp. 56–68, 2023.

- [50] J. J. O. Gonçalves, T. Lotufo, G. D. A. Nze y F. L. de Mendonça, “*Detecção de prompt injection em modelos de linguagem*,” Revista Ibérica de Sistemas e Tecnologias de Informação, no. E77, pp. 104–116, 2025.
- [51] R. D. Merchan Manzanillas, “*Respuesta de los sistemas de detección de intrusiones (IDS) ante amenazas cibernéticas generadas por IA: análisis y generación de malware (WORM) con IA frente a SNORT*,” Trabajo de Integración Curricular, Escuela Politécnica Nacional (EPN), Quito, Ecuador, 2025.
- [52] Z. D. Johnson, “*Generation, detection, and evaluation of role-play based jailbreak attacks in large language models*,” Tesis doctoral, Massachusetts Institute of Technology (MIT), Cambridge, MA, EE. UU., 2024.
- [53] Vellosillo Montalt, P., “*Evaluación de técnicas Jailbreak en grandes modelos de lenguaje*,” Trabajo Fin de Grado, Escuela Técnica Superior de Ingeniería Informática, Universitat Politècnica de València, 2025.
- [54] P. H. Barcha Correia, R. W. Achjian, D. E. G. Caetano de Oliveira, Y. A. Maria, V. T. Hayashi, M. Lopes, C. C. Miers, and M. A. Simplicio Jr., “*A systematic literature review on LLM defenses against prompt injection and jailbreaking: Expanding NIST taxonomy*,” arXiv preprint arXiv:2601.22240, 2026.
- [55] Sola, G. H., Flores, M. J. M., and Font, V. G., “*Creació d'un CI/CD per a la securització de models d'IA/ML*,” Universitat Oberta de Catalunya (UOC), 2023. [Online]. Available: <https://openaccess.uoc.edu/server/api/core/bitstreams/761c8604-ec91-4c32-8964-3a7c9f9b31ba/content> [Accedido 20-abr-2026]
- [56] L. M. Pilamunga Agualsaca, “*Respuesta de los sistemas de detección de intrusiones (IDS) ante amenazas cibernéticas generadas por IA: Herramientas de seguridad ofensiva y evaluación de la detección de ataques de fuerza bruta generados por IA con Snort*,” IEEE, 2025.
- [57] Y. S. Domínguez, “*El análisis de información y las investigaciones cuantitativa y cualitativa*,” Revista Cubana de Salud Pública, vol. 33, no. 3, 2007.
- [58] V. G. Cortina, Aplicación de la metodología CRISP-DM a un proyecto de minería de datos en el entorno universitario, Universidad Carlos III de Madrid, 2015.

- [59] D. B. Fernández and S. L. Mora, “Uso de la metodología CRISP-DM para guiar el proceso de minería de datos en LMS,” in *Tecnología, innovación e investigación en los procesos de enseñanza-aprendizaje*, Octaedro, 2016, pp. 2385–2393.
- [60] C. Cobos, J. Zuñiga, J. Guarín, E. León, and M. Mendoza, “CMIN-herramienta case basada en CRISP-DM para el soporte de proyectos de minería de datos,” *Ingeniería e investigación*, vol. 30, no. 3, pp. 45–56, 2010.
- [61] Z. Waseem, “*Are You a Racist or Am I Seeing Things? Annotator Influence on Hate Speech Detection on Twitter*,” in **Proc. EMNLP Workshop NLP and Computational Social Science**, 2016.
- [62] M. Sap *et al.*, “*Annotators with Attitudes: How Annotator Beliefs And Identities Bias Toxic Language Detection*,” in **Proc. NAACL Human Language Technologies**, 2022.
- [63] S. L. Blodgett, S. Barocas, H. Daumé III, and H. Wallach, “*Language (Technology) is Power: A Critical Survey of ‘Bias’ in NLP*,” in **Proc. 58th Annu. Meeting Assoc. Computational Linguistics (ACL)**, 2020, pp. 5454–5476.
- [64] P. Röttger *et al.*, “*Two Contradictory Heuristics for Designing Hate Speech Classifiers*,” in **Proc. ACL**, 2022.

ANEXOS

Anexo 1: Análisis documental de *datasets* públicos de *prompts* evasivos y seguros

ANÁLISIS DOCUMENTAL							
El análisis documental consistió en la revisión sistemática, selección y clasificación de fuentes de datos públicas relacionadas con <i>prompts</i> y procesamiento de lenguaje natural. Se identificaron los repositorios y conjuntos de datos que conformarían el corpus de entrenamiento, aplicando criterios de pertinencia temática, procedencia verificada . A partir de esta revisión se construyó un dataset consolidado de 28.100 <i>prompts</i> , clasificados en dos categorías: seguros (9.850) y evasivos (18.250).							
N°	Nombre del Dataset	Autor / Fuente	Plataforma	Tipo de <i>prompt</i>	Registros obtenido	Información extraída y uso en el proyecto	link
1	Awesome ChatGPT Prompts	Anshuman Mishra	Hugging Face	Seguro	2.250	Se extrajeron <i>prompts</i> de uso general en lenguaje natural. Se utilizaron como base principal de la categoría segura.	https://www.kaggle.com/datasets/shivanshuman/amazing-prompts
2	AI-Generate Prompts Dataset	AnthonyTherrien	Kaggle	Seguro	3.000	Se recopilaron <i>prompts</i> con diversas estructuras de solicitud. Se emplearon para ampliar la variedad de patrones lingüísticos dentro de la categoría segura.	https://www.kaggle.com/datasets/anthonytherrien/ai-generated-prompts-dataset
3	Prompt Engineering Dataset – Austin Fairbanks	Austin Fairbanks	Kaggle	Seguro	1.500	Se extrajeron ejemplos de <i>prompts</i> orientados a buenas prácticas de ingeniería de <i>prompts</i> . Contribuyeron a enriquecer la categoría segura.	https://www.kaggle.com/datasets/austinfairbanks/prompt-engineering-dataset/versions/1/data

4	Datasets: tatsu-lab / alpaca	Tatsu Lab	Hugging Face	Seguro	1.350	Se seleccionaron instrucciones correspondientes a tareas de propósito general. Se incluyeron para aumentar la diversidad de los <i>prompts</i> seguros.	https://huggingface.co/datasets/tatsu-lab/alpaca
5	LLM Red Teaming Prompts – navirocker (Kaggle)	navirocker	Kaggle	Evasivo	5.000	Se recopilaron <i>prompts</i> diseñados para probar los límites de los modelos de lenguaje mediante técnicas de red teaming. Se emplearon en la categoría evasiva.	https://www.kaggle.com/datasets/navirocker/llm-red-teaming-prompts
6	fka/prompts.chat	fka	Hugging Face	Evasivo	1.200	Se identificaron <i>prompts</i> de rol y simulación que pueden inducir comportamientos no deseados en LLMs. Clasificados como evasivos.	https://huggingface.co/datasets/fka/prompts.chat
7	Do-Not-Answer – Libr-AI	Libr-AI	GitHub	Evasivo	900	Dataset especializado en preguntas que los modelos de lenguaje no deberían responder. Se utilizaron como referencia de alta calidad para la categoría evasiva.	https://github.com/Libr-AI/do-not-answer
8	Datasets: Babelscape / ALERT	Babelscape	Hugging Face	Evasivo	12.900	Se extrajeron <i>prompts</i> del <i>benchmark</i> ALERT orientados a la evaluación de seguridad en LLMs. Aportaron ejemplos estructurados de distintas categorías de riesgo	https://huggingface.co/datasets/Babelscape/ALE-RT

Anexo 2: código de app.py con extensión del navegador de chatGPT

```
from flask import Flask, render_template, request, jsonify
from transformers import AutoTokenizer,
AutoModelForSequenceClassification
import torch
from deep_translator import GoogleTranslator
from langdetect import detect
import csv
import datetime
from flask_cors import CORS

app = Flask(__name__)
CORS(app, resources={r"/clasificar": {"origins":
["https://chatgpt.com"]}})
# MODELO RoBERTa

MODEL_PATH = "model/roberta_model_final"
tokenizer = AutoTokenizer.from_pretrained(
    MODEL_PATH,
    use_fast=True
)
model_roberta = AutoModelForSequenceClassification.from_pretrained(
    MODEL_PATH
)
model_roberta.eval()

# CLASIFICADOR ROBERTA
def clasificar_prompt(texto):

    idioma = detect(texto)
    texto_procesado = texto

    if idioma != "es":
        texto_procesado = GoogleTranslator(
            source='auto', target='es'
        ).translate(texto)

    inputs = tokenizer(
        texto_procesado,
        return_tensors="pt",
        truncation=True,
        padding=True
    )

    with torch.no_grad():
```

```

        logits = model_roberta(**inputs).logits
        probs = torch.softmax(logits, dim=1)

        prob_evasivo = float(probs[0][1])
        prob_seguro = float(probs[0][0])

        resultado = "Evasivo" if prob_evasivo > 0.7 else "Seguro"

        with open("log_resultados.csv", "a", newline="", encoding="utf-8") as f:
            writer = csv.writer(f)
            writer.writerow([
                datetime.datetime.now(),
                texto,
                texto_procesado,
                idioma,
                prob_seguro,
                prob_evasivo,
                resultado
            ])

        return resultado, prob_evasivo, prob_seguro, idioma, texto_procesado

# =====
# RUTAS
# =====

@app.route("/")
def home():
    return render_template("index.html")

@app.route("/clasificar", methods=["POST"])
def clasificar():
    data = request.get_json(silent=True) or {}
    texto = data.get("prompt", "")

    if not texto:
        return jsonify({
            "error": "Falta el campo prompt"
        }), 400

    resultado, prob_ev, prob_seg, idioma, texto_proc = clasificar_prompt(texto)

```

```
    return jsonify({
        "label": resultado.lower(),
        "prob_seguro": prob_seg,
        "prob_evasivo": prob_ev,

        "resultado": resultado,
        "idioma_detectado": idioma,
        "texto_traducido": texto_proc
    })

if __name__ == "__main__":
    app.run(debug=True)
```