



**UNIVERSIDAD TECNOLÓGICA ECOTEC**

**FACULTAD:**

INGENIERÍAS, ARQUITECTURA Y CIENCIAS DE LA NATURALEZA

**TÍTULO:**

DISEÑO DE UN MODELO DE MACHINE LEARNING DESTINADO A  
PREDECIR CASOS DE VIOLENCIA DE GÉNERO EN ECUADOR.

**LÍNEA DE INVESTIGACIÓN:**

TECNOLOGÍAS DE LA INFORMACIÓN Y LA COMUNICACIÓN

**MODALIDAD DE TITULACIÓN:**

TRABAJO DE INTEGRACIÓN CURRICULAR

**CARRERA:**

INGENIERÍA EN SOFTWARE

**TÍTULO A OBTENER:**

INGENIERO DE SOFTWARE

**AUTOR:**

ADRIÁN ANDRÉS ALARCÓN ARÉVALO

**TUTOR:**

ING. ALEJANDRA MERCEDES COLINA VARGAS, PHD.

**GUAYAQUIL 2024**



ANEXO No. 9

**PROCESO DE TITULACIÓN  
CERTIFICADO DE APROBACIÓN DEL TUTOR**

Samborondón, 19 de diciembre de 2024.

Magíster

**Erika del Pilar Ascencio Jordán**

**Unidad Académica: Facultad de Ingenierías, Arquitectura y Ciencias de la Naturaleza**  
Universidad Tecnológica ECOTEC

De mis consideraciones:

Por medio de la presente comunico a usted que el trabajo de titulación TITULADO: **DISEÑO DE UN MODELO DE MACHINE LEARNING DESTINADO A PREDECIR CASOS DE VIOLENCIA DE GÉNERO EN ECUADOR**, fue revisado, siendo su contenido original en su totalidad, así como el cumplimiento de los requerimientos establecidos en la guía para su elaboración, por lo que se autoriza al estudiante: **Adrián Andrés Alarcón Arévalo** para que proceda con la presentación oral del mismo.

**ATENTAMENTE,**



Presente el autenticado por:  
**ALEJANDRA MERCEDES  
COLINA VARGAS**

Firma

**Alejandra Mercedes Colina Vargas, PhD.**  
Tutora



## ANEXO No. 10

**PROCESO DE TITULACIÓN  
CERTIFICADO DEL PORCENTAJE DE COINCIDENCIAS  
DEL TRABAJO DE TITULACIÓN**

Habiendo sido revisado el trabajo de titulación TITULADO: DISEÑO DE UN MODELO DE MACHINE LEARNING DESTINADO A PREDECIR CASOS DE VIOLENCIA DE GÉNERO EN ECUADOR elaborado por ADRIÁN ANDRÉS ALARCÓN ARÉVALO fue remitido al sistema de coincidencias en todo su contenido el mismo que presentó un porcentaje del 6% mismo que cumple con el valor aceptado para su presentación que es inferior o igual al 10% sobre el total de hojas del documento. Adicional se adjunta print de pantalla de dicho resultado.



**ATENTAMENTE,**



Firma  
**Ing. Alejandra Mercedes Colina Vargas, PhD.**  
Tutora

**Dedicatoria**

Dedico este trabajo de titulación con el más profundo y sincero agradecimiento a mis padres, Pablo Alarcón y Graciela Arévalo, cuya guía, amor inquebrantable y ejemplos de fortaleza han sido el fundamento que me impulsó a lo largo de este arduo camino académico. A mis hermanos, Jeam, Marco, Kiara, Yazmin y Joselyn, por sostenerme con su apoyo incondicional, aliento constante y la certeza de que jamás estuve solo en este recorrido.

Extiendo también mi infinita gratitud a Luigi, Milena, Francesca, Nicole y Dayana, mis incondicionales del corazón, quienes, con su presencia generosa, empatía inagotable y confianza mutua, convirtieron cada desafío en una oportunidad para aprender, crecer y superar obstáculos juntos. A todos ustedes, gracias por encender la luz que ha iluminado este sendero hasta alcanzar la meta.

## **Agradecimiento**

Agradezco en primer lugar a Dios, cuya bendición y guía espiritual han iluminado cada paso de mi vida, dándome la fortaleza y perseverancia necesarias para alcanzar esta importante meta. A mi familia y amigos, quienes en todo momento depositaron su confianza en mis capacidades, y no escatimaron esfuerzos para alentarme, apoyarme y reconfortarme a lo largo de este arduo recorrido. Su presencia inquebrantable fue el aliento que me impulsó a superar las dificultades y a no desistir, incluso en las horas más inciertas.

Quiero también expresar mi profunda gratitud a mi tutora en este trabajo, Ing. Alejandra Colina, cuyo valioso acompañamiento, orientación y dedicación fueron pilares fundamentales para guiarme en este proceso académico.

Asimismo, extendiendo mi agradecimiento a mi querida mascota, Conny, quien, con su compañía silenciosa y fiel, me sostuvo en incontables noches de estudio y redacción. Su tranquilidad a mi lado fue un bálsamo que me ayudó a mantener la concentración y la motivación, recordándome que incluso en las horas más solitarias, no estaba realmente solo.

## Resumen

Este trabajo aborda el diseño de un modelo de Machine Learning (ML) orientado a predecir casos de violencia de género en Ecuador, una problemática social crítica que afecta significativamente a las mujeres del país. Utilizando la metodología CRISP-DM, se analizaron y modelaron datos provenientes de contextos familiares (ENVIGMU Dataset) y digitales (MeTwo Dataset), integrando técnicas avanzadas como procesamiento del lenguaje natural (NLP) y representación TF-IDF.

Los resultados muestran que el modelo desarrollado no solo permite identificar patrones de riesgo con alta precisión, sino que también ofrece una herramienta práctica para optimizar la prevención y respuesta ante la violencia de género. Este modelo contribuye al conocimiento al demostrar cómo la inteligencia artificial puede adaptarse para analizar datos en contextos locales, integrando factores culturales, sociales y tecnológicos específicos de Ecuador. Además, la solución propuesta aporta un enfoque innovador que complementa los métodos tradicionales, al permitir la detección temprana y más eficiente de situaciones de riesgo.

En el ámbito práctico, el modelo puede fortalecer la formulación de políticas públicas orientadas a la prevención de la violencia, así como mejorar la asignación de recursos en sectores clave como la seguridad y la justicia. Este estudio sienta las bases para futuras investigaciones que busquen integrar tecnologías avanzadas en la solución de problemáticas sociales, subrayando la importancia de enfoques interdisciplinarios y adaptaciones específicas al contexto.

Palabras clave: Machine Learning, Violencia De Género, CRISP-DM, Procesamiento Del Lenguaje Natural, TF-IDF, Modelos Predictivos.

**Abstract**

This study addresses the design of a Machine Learning (ML) model aimed at predicting cases of gender-based violence in Ecuador, a critical social issue that significantly impacts women across the country. Using the CRISP-DM methodology, data from family contexts (ENVIGMU Dataset) and digital environments (MeTwo Dataset) were analyzed and modeled, integrating advanced techniques such as Natural Language Processing (NLP) and TF-IDF representation.

The results demonstrate that the proposed model not only identifies risk patterns with high accuracy but also provides a practical tool to optimize prevention and response efforts against gender-based violence. This research contributes to knowledge by showcasing how artificial intelligence can be adapted to analyze local data, incorporating specific cultural, social, and technological factors in Ecuador. Additionally, the solution complements traditional methods by enabling early and more efficient risk detection.

In practice, the model can strengthen public policy development aimed at violence prevention and improve resource allocation in key sectors such as security and justice. This study lays the groundwork for future research integrating advanced technologies to address social issues, emphasizing the importance of interdisciplinary approaches and context-specific adaptations.

**Keywords:** Machine Learning, gender-based violence, Ecuador, CRISP-DM, Natural Language Processing, TF-IDF, predictive models.

## Índice

Anexo 9.....	¡Error! Marcador no definido.
Anexo 10.....	¡Error! Marcador no definido.
Dedicatoria.....	4
Agradecimiento.....	5
Resumen.....	6
Abstract.....	7
Tabla de Ilustraciones.....	13
Índice de figuras.....	14
1. Introducción.....	16
1.1 Contexto histórico social del objeto de estudio.....	16
1.2 Antecedentes.....	19
1.3 Planteamiento del Problema.....	23
1.3.1 Preguntas de investigación.....	26
1.4 Objetivos.....	27
1.4.1 Objetivo General.....	27
1.4.2 Objetivos Específicos.....	27
1.5 Justificación.....	28
2 Revisión de la literatura.....	31
2.1 Antecedentes de la Investigación.....	31
2.2 Referencias Teóricas.....	35
2.2.1 Definición de Violencia de Género.....	35
2.2.2 Tipos de Violencia de Género (VG) y Características.....	36



2.2.3 Impacto de la Violencia de Género.....	37
2.2.4 Importancia de la Prevención de la Violencia de Género.....	37
2.2.5 Definición de Machine Learning .....	38
2.2.6 Tipos de Algoritmos de Machine Learning .....	39
2.2.7 Machine Learning para Problemáticas Sociales .....	40
2.2.8 Machine Learning y su Aplicación en la Violencia de Género .....	40
2.3 Marco legal .....	41
2.3.1 Constitución De La República Del Ecuador 2008 .....	41
2.3.2 Tratados y Convenios Internacionales.....	43
2.3.3 Leyes Orgánicas .....	45
2.3.4 Leyes Ordinarias .....	45
2.4 Marco Conceptual.....	49
2.4.1 Machine Learning (ML).....	49
2.4.2 Random Forest.....	49
2.4.3 Regresión Logística.....	49
2.4.4 Máquinas de Vectores de Soporte (SVM).....	50
2.4.5 Naive Bayes .....	50
2.4.6 Árboles de Decisión .....	50
2.4.7 NLP (Procesamiento De Lenguaje Natural).....	50
2.4.8 Word2Vec.....	51
2.4.9 Tf-idf (Term Frequency-Inverse Document Frequency).....	51
2.4.10 KDD .....	51

2.4.11 Scrumban .....	52
2.4.12 Metodología CRISP-DM .....	52
2.4.13 Hiperparámetros de ML .....	54
2.4.14 Validación Cruzada.....	54
2.4.15 Exactitud (Accuracy).....	54
2.4.16 Precisión (Precision).....	54
2.4.17 Sensibilidad (Recall).....	55
2.4.18 Puntuación F1 (F1 Score).....	55
2.4.19 Matriz de confusión .....	55
2.4.20 Área Bajo la Curva ROC (AUC-ROC).....	55
2.4.21 Lenguaje Python .....	55
2.4.22 Dataset.....	56
2.4.23 Flask .....	56
2.4.24 Pickle .....	56
2.4.25 Joblib.....	56
2.4.26 HTML .....	57
3 Metodología del Proceso de Investigación.....	58
3.1 Enfoque de la Investigación.....	58
3.2 Alcance de la Investigación.....	59
3.3 Delimitación del Proyecto.....	60
3.3.1 Delimitación geográfica .....	60
3.3.2 Delimitación temporal.....	61

3.3.3 Población y muestra .....	62
3.3.4 Sobre los datasets.....	62
3.4 Métodos Empleados .....	63
3.4.1 Revisión Literaria .....	64
3.4.2 Entrevista.....	65
3.5 Procesamiento y análisis de la Información .....	67
3.6 Elementos Metodológicos específicos para TI .....	67
3.6.1 CRISP-DM aplicado al Dataset ENVIGMU .....	67
3.6.2 CRISP-DM aplicado al Dataset MeTwo .....	70
4 Análisis De Resultados De La Investigación.....	72
4.1 Aspectos Generales de los Datasets y Requisitos del Sistema.....	72
4.2 ENVIGMU Dataset.....	73
4.2.1 Entendimiento del Negocio.....	73
4.2.2 Entendimiento de los datos .....	74
4.2.3 Preparación de los datos.....	78
4.2.4 Modelado .....	81
4.2.5 Evaluación.....	82
4.2.6 Implementación.....	84
4.2.7 Análisis Critico .....	86
4.3 MeTwo Dataset.....	86
4.3.1 Entendimiento del Negocio.....	86
4.3.2 Entendimiento de los datos .....	87

4.3.3 Preparación de los datos .....	89
4.3.4 Modelado .....	92
4.3.5 Evaluación.....	94
4.3.6 Implementación .....	98
4.3.7 Análisis Critico .....	100
4.4 Evaluaciones con expertos .....	100
4.5 Calificación del modelo por el experto en psicología.....	102
5. Conclusiones.....	105
6. Recomendaciones.....	107
7. Anexos .....	109
7.1 Comparativa de los Datasets Utilizados en el Estudio .....	109
7.2 Preguntas de Entrevista Psic. Diana Ramirez.....	110
7.2.1 Imagen de la entrevista .....	114
7.3 Preguntas de Entrevista Ing, Carlos Valle .....	114
7.2.3 Imagen de la entrevista .....	120
7.4 Diagrama de Gantt.....	120
7.5. Perfomance de Modelos .....	121
7.5.1 Envigmu Dataset.....	121
7.5.2 MeTwo Dataset .....	121
7.5 CV de los Expertos .....	122
8. Bibliografia.....	125

**Tabla de Ilustraciones**

<b>Tabla 1</b> .....	23
<b>Tabla 2</b> .....	95
<b>Tabla 3</b> .....	109

## Índice de figuras

Figura 1: Proceso para el desarrollo del modelo ML Envigmu .....	74
Figura 2: Subdatasets ENVIGMU.....	75
Figura 3: Lectura del CSV .....	75
Figura 4: Leer preguntas por ambito .....	76
Figura 5: Preguntas y ámbito .....	76
Figura 6: Normalización de texto.....	77
Figura 7: Creación de un diccionario .....	77
Figura 8: Identificar el ámbito predominante.....	78
Figura 9: Identificar valores faltantes.....	78
Figura 10: Manejo de valores faltantes.....	79
Figura 11: Imputación de la mediana.....	79
Figura 12: LabelEncoder convertir columnas categoricas .....	80
Figura 13: Muestras balanceadas .....	80
Figura 14: Preparación de los datos .....	81
Figura 15: Separar data de entrenamiento .....	81
Figura 16: RandomForest.....	82
Figura 17: Evaluación para Grupo.....	83
Figura 18; Evaluación para Ámbito.....	84
Figura 19: Formulario del aplicativo web .....	85
Figura 20: Resultados de la Predicción .....	85
Figura 21: Proceso para desarrollo de ML MeTwo.....	87
Figura 22: Primerias Librerías .....	87
Figura 23: Lectura del CSV .....	88
Figura 24: Contenido del Dataset.....	88
Figura 25: Gráfico de barras: Distribución de clases en el dataset .....	88
Figura 26: Identificar Valores Nulos .....	89

Figura 27: Eliminación de filas con valores nulos en la columna 'text' .....	89
Figura 28: Análisis y ajuste del balance en las clases del dataset .....	90
Figura 29: Balanceo del dataset.....	90
Figura 30: División del dataset en conjuntos de entrenamiento y prueba .....	91
Figura 31: Preparación de los datasets .....	92
Figura 32: Selección de modelos de Machine Learning para clasificación .....	93
Figura 33: Evaluación de modelos de Machine Learning mediante métricas de precisión .....	94
Figura 34: Cálculo del F1-Score por clase utilizando SVM .....	95
Figura 35: Reporte de Clasificación.....	95
Figura 36: Matriz de confusión .....	96
Figura 37: Optimización del modelo SVM usando GridSearchCV .....	97
Figura 38: Testeo.....	98
Figura 39: Frontend del formulario .....	99
Figura 40: Tweet Sexista o no Sexista.....	99
Figura 41: Resultado Pregunta 1.....	102
Figura 42: Resultado Pregunta 2.....	103
Figura 43: Resultado Pregunta 3.....	104
Figura 44: Imagen de Entrevista - Psic. Diana Ramirez .....	114
Figura 45: Figura 41: Imagen de Entrevista - Ing. Carlos Valle .....	120
Figura 46: Diagrama de Gantt.....	120
Figura 47: Envigmu Dataset Perfomance .....	121
Figura 48: MeTwo Perfomance.....	121

## 1. Introducción

### 1.1 Contexto histórico social del objeto de estudio

En los últimos años, la problemática relacionada con la violencia de género ha sido una preocupación central en América Latina y el Caribe. Según la Comisión Económica para América Latina y el Caribe (CEPAL, 2024), esta situación se manifiesta con alarmante magnitud a pesar de los esfuerzos estatales por implementar leyes y protocolos específicos para su combate. La persistencia de esta situación, evidenciada por el incremento de feminicidios y otras formas de violencia, subraya la necesidad de adoptar enfoques más efectivos y basados en datos. En Ecuador, el Instituto Nacional de Estadísticas y Censos (INEC, 2019) indica que el 65% de las mujeres ha experimentado algún tipo de violencia a lo largo de su vida, con tasas particularmente elevadas entre mujeres afroecuatorianas e indígenas. Esto resalta la urgencia de implementar estrategias más efectivas para la prevención y respuesta.

En este contexto, la Ingeniería de Software juega un papel en el desarrollo de soluciones tecnológicas avanzadas puede ofrecer nuevas herramientas para abordar esta situación (Alvaro Romero, 2023). Es aquí donde el machine learning (ML), una subdisciplina de la inteligencia artificial cobra relevancia. La persistencia de la violencia de género en Ecuador, evidenciada por estadísticas como las del INEC (2019), subraya la necesidad de enfoques más innovadores. Los métodos tradicionales, aunque fundamentales, a menudo se enfrentan a limitaciones en la capacidad para prever situaciones de riesgo, analizar grandes volúmenes de información, y responder con eficacia a contextos dinámicos y específicos.

El ML permite que las máquinas aprendan a realizar tareas sin ser programadas específicamente para ellas, empleando técnicas estadísticas para identificar y predecir patrones, lo cual mejora su desempeño con grandes volúmenes de datos (Ortega, 2024). Desde su concepción inicial en la década de 1950 con el "Test de Turing" de Alan



Turing, el ML ha evolucionado significativamente. Inicialmente enfocado en el reconocimiento de patrones y optimización, los avances tecnológicos y el crecimiento de la información digital han permitido su expansión a diversos campos, incluyendo la predicción de fenómenos sociales ((Victor Nalda, 2020);(Canle, 2022)). Por ejemplo, herramientas de ML podrían identificar comunidades en riesgo basándose en correlaciones entre factores económicos, demográficos y culturales, proporcionando a las autoridades una base sólida para priorizar recursos y diseñar intervenciones específicas.

Con el notable avance de las tecnologías relacionadas con la inteligencia artificial, el ML surge como un referente para predecir situaciones sociales, como la detección del riesgo de exclusión social, maltrato infantil, riesgo de suicidio, y soporte en el diagnóstico social y asignación de recursos (Fundación ISocial, 2022) Para aplicar las capacidades del Machine Learning (ML) al ámbito de la violencia de género, es posible analizar grandes volúmenes de datos provenientes de múltiples fuentes como registros policiales, informes médicos, redes sociales y encuestas para identificar patrones y correlaciones que los métodos tradicionales podrían pasar por alto (Luna, 2021).

Además, el uso de ML podría transformar la recopilación y el análisis de datos en tiempo real, facilitando la detección temprana de casos de violencia de género mediante sistemas automatizados que alerten sobre cambios en patrones de comportamiento o señales de riesgo. Este enfoque no solo optimizaría los recursos disponibles, sino que también permitiría una respuesta más inmediata y focalizada.

En Europa, diversos sistemas ya aprovechan el potencial del ML y la inteligencia artificial para la prevención y predicción de la violencia de género. En España<sup>3</sup>, el sistema VioGén y el modelo SAS Iberia destacan en la identificación y análisis de indicadores de reincidencia y factores de riesgo, permitiendo ajustar en tiempo real las

medidas de protección. Esta asignación dinámica de recursos de seguridad refuerza significativamente el apoyo y protección a las víctimas (Avella et al., 2023).

Asimismo, herramientas como ODARA (Ontario Domestic Assault Risk Assessment) es una herramienta de evaluación de riesgo desarrollada en Canadá para predecir la probabilidad de reincidencia en casos de violencia doméstica, junto con el modelo matemático de Erik-Leal Enríquez, aplican análisis actuariales para evaluar factores situacionales, proporcionando una evaluación de riesgo informada que contribuye a la toma de decisiones en políticas de protección y prevención de violencia (Benítez Baracaldo, 2024).

En América Latina, México ha adoptado iniciativas innovadoras en este ámbito, como el chatbot Violetta, desarrollado por mujeres mexicanas. Violetta utiliza inteligencia artificial para prevenir situaciones de violencia en relaciones de pareja y actúa como recurso educativo y de alerta sobre señales de violencia (Lagos, 2024). Además, ejemplos como Sophia, creado por Spring ACT en Suiza, tienen un alcance global y representan la capacidad de la tecnología para apoyar a las víctimas de violencia de género de manera confidencial y continua. Sophia permite a las víctimas recopilar evidencias y conocer sus derechos, proporcionándoles asistencia segura en cualquier momento y lugar (Cabrera, 2024).

A medida que estas herramientas se perfeccionan y se ajustan a los contextos locales, su integración en estrategias nacionales podría alinearse con iniciativas internacionales, como el sistema VioGén en España, adaptándolas a la realidad ecuatoriana. Esto no solo posicionaría a Ecuador como un referente en el uso de tecnología para problemáticas sociales, sino que también contribuiría a la construcción de una sociedad más equitativa y segura.

Estos sistemas subrayan cómo el ML y la inteligencia artificial pueden ofrecer apoyo directo y accesible, ampliando las herramientas para la prevención y la intervención en situaciones de violencia de género y optimizando los recursos de protección de manera efectiva en diferentes contextos.

A medida que estas herramientas se perfeccionan y se ajustan a los contextos locales, el potencial de transformar la manera en que se enfrentan los incidentes de violencia de género se hace más evidente, ofreciendo un enfoque más preciso, oportuno y basado en datos para proteger a las personas más vulnerables y promover una sociedad más segura y justa (A. Ramirez, 2022).

## **1.2 Antecedentes**

En Ecuador, la problemática de la violencia de género presenta cifras alarmantes. De acuerdo con la Encuesta Nacional sobre Relaciones Familiares y Violencia de Género contra las Mujeres (ENVIGMU) del INEC, una proporción significativa de mujeres ha experimentado algún tipo de violencia a lo largo de su vida. Estos datos evidencian la necesidad de herramientas tecnológicas que permitan detectar, prevenir y responder eficazmente a situaciones de riesgo. Si bien no se han desarrollado ampliamente modelos de Machine Learning aplicados directamente al contexto ecuatoriano, estudios como el de Caisa Coyago y Rosero Espinosa (2023) han demostrado la factibilidad del análisis de datos locales para identificar patrones de violencia, abriendo el camino para la adaptación de soluciones tecnológicas a la realidad nacional.

El desarrollo de modelos de Machine Learning (ML) para predecir casos de violencia de género (VG) en Ecuador se enmarca en la evolución de la inteligencia artificial aplicada a problemas sociales críticos, con el objetivo de promover la creación de proyectos que contribuyan a resolver situaciones de riesgo social (Moreno, 2023). La implementación de ML permite identificar patrones de comportamiento que pueden

anticipar posibles situaciones de VG, demostrando su potencial para prevenir y mitigar estas situaciones.

Diversas investigaciones destacan el uso de ML en la detección de riesgos sociales mediante técnicas como el Procesamiento de Lenguaje Natural (NLP) y el aprendizaje supervisado. García Vergara y colaboradores aplicaron NLP en el análisis de documentos legales para predecir feminicidios en relaciones de pareja, utilizando algoritmos como Máquinas de Vectores de Soporte (SVM) y Árboles de Decisión para extraer y clasificar características relevantes de grandes conjuntos de datos textuales.

Los resultados de este estudio evidenciaron que el ML en este contexto permite obtener información clave para comprender patrones delictivos y mejorar los esfuerzos de prevención (García-Vergara et al., 2023). Sin embargo, una posible limitación de este enfoque en Ecuador es la disponibilidad de datos legales digitalizados y estructurados. Muchas instituciones en el país aún no cuentan con sistemas integrados que permitan un acceso rápido y confiable a estos registros, lo que plantea un reto para replicar este tipo de análisis.

En el ámbito digital, el Programa de las Naciones Unidas para el Desarrollo (PNUD) implementó eMonitor+, una herramienta avanzada de inteligencia artificial utilizada en Perú para identificar de manera automática discursos de odio y violencia de género en entornos digitales. eMonitor+ analiza grandes volúmenes de datos en tiempo real, empleando técnicas de análisis de sentimientos y clasificación de texto para detectar y categorizar contenido perjudicial, proporcionando hallazgos valiosos para la formulación de políticas y estrategias de intervención efectivas (UNDP, 2024). Aunque este sistema demuestra ser eficaz en entornos con alta conectividad y acceso a redes sociales, en Ecuador su implementación podría enfrentarse a desafíos como la brecha digital, especialmente en zonas rurales, donde la penetración de internet es limitada.

Adaptar estas tecnologías a contextos de menor conectividad requeriría soluciones descentralizadas y accesibles.

Además, en el contexto de la detección de violencia en videos de vigilancia, se han utilizado técnicas avanzadas de visión computacional como el descriptor Local Histogram of Oriented Gradient (LHOG) y el Local Histogram of Optical Flow (LHOF) para capturar características de violencia a nivel de flujo de movimiento y apariencias en secuencias de video. Estos descriptores se integran en un modelo Bag of Words (BoW) y se clasifican mediante SVM para distinguir secuencias violentas, alcanzando precisión en la detección en diversos escenarios (Zhou et al., 2018). Si bien esta tecnología podría ser útil en áreas urbanas de Ecuador donde existen sistemas de videovigilancia instalados, sería crucial considerar el costo y la infraestructura necesaria para implementarla en todo el país, así como las posibles preocupaciones éticas relacionadas con la privacidad.

En el desarrollo de un marco eficiente para la detección de violencia en áreas sensibles, como cajeros automáticos y hospitales, utiliza técnicas avanzadas de visión computacional y Machine Learning (ML) para analizar flujos de video en tiempo real. Este sistema Kuldeep Singh con sus colaboradores identifica eventos violentos mediante descriptores de flujo óptico, que rastrean el movimiento en cada píxel de los cuadros de video. Al integrar técnicas de fusión de datos, el marco optimiza la precisión y reduce los errores, permitiendo generar alertas automáticas y oportunas para una intervención rápida en situaciones de violencia (Singh et al., 2018). En Ecuador, este tipo de tecnologías podrían aplicarse en entornos de alta afluencia, como mercados o terminales de transporte público, siempre que se priorice la capacitación técnica y se establezcan protocolos claros para su operación.

La aplicación de modelos de ML en la prevención de la VG ha avanzado también en el ámbito de la seguridad pública, mediante sistemas que apoyan a las fuerzas

policiales en la identificación y anticipación de casos de VG. Christian Pinto junto con sus colaboradores utilizaron Redes Neuronales Artificiales (ANN) y técnicas de Ensamblado de Modelos (Ensemble Learning), integrando datos históricos y variables socioeconómicas para mejorar la precisión de las predicciones y generar alertas tempranas. La implementación de estos modelos predictivos ha demostrado que el ML puede adaptarse y responder a los desafíos cambiantes de la VG, ayudando a las autoridades en la prevención de incidentes (Pinto-Muñoz et al., 2023a).

El uso de Python y de bibliotecas especializadas como Pandas, Gensim, NLTK, spaCy y Matplotlib ha sido fundamental en la implementación de modelos para el análisis de situaciones de violencia de género. Un estudio reciente desarrolló un programa de ML que utiliza estas herramientas para procesar un gran volumen de información textual, aplicando técnicas de procesamiento de lenguaje natural y modelado de tópicos (LDA) para identificar patrones relevantes en los testimonios de las víctimas. Este enfoque permitió el manejo eficiente de grandes volúmenes de datos y la obtención de representaciones de temas que facilitan la detección de situaciones de riesgo de VG y la adaptación del modelo a nuevos datos (Chávez et al., 2022).

Aunque las iniciativas tecnológicas descritas han demostrado ser efectivas en diversos contextos, es fundamental adaptarlas a las necesidades y limitaciones específicas del Ecuador. Esto incluye trabajar en la recopilación de datos locales confiables, garantizar la conectividad en áreas rurales, y abordar los desafíos éticos y de privacidad inherentes al uso de inteligencia artificial en situaciones sensibles.

La relevancia de desarrollar modelos de ML específicos para detectar casos de VG es clara, dada la urgencia de proteger a las potenciales víctimas y salvaguardar el bienestar social. La VG tiene consecuencias devastadoras tanto en términos de daño físico y psicológico como en la confianza y seguridad pública.

### 1.3 Planteamiento del Problema

La violencia de género en Ecuador ha alcanzado niveles alarmantes, con el 64,9% de las mujeres experimentando alguna forma de violencia a lo largo de su vida (INEC, 2019). Esta situación demanda un abordaje preventivo más sofisticado que las iniciativas vigentes, las cuales, en su mayoría, se focalizan en la atención posterior a los hechos y no en la identificación temprana de riesgos. A pesar de que proyectos como la aplicación Junt@s (UNFPA Ecuador, 2023) y otros esfuerzos internacionales como eMonitor+ en Perú (UNDP, 2024) ofrecen apoyo, información y análisis de discursos agresivos en el entorno digital, su alcance se limita a la respuesta reactiva o al contexto urbano y altamente conectado.

**Tabla 1**

Indicadores nacionales de violencia de género a lo largo de la vida (en %)

<b>Tipo de violencia</b>	<b>Nacional</b>	<b>Urbano</b>	<b>Rural</b>
<b>Violencia total</b>	64,9%	65,7%	62,8%
<b>Violencia psicológica</b>	56,9%	56,7%	57,4%
<b>Violencia física</b>	35,4%	34,4%	38,2%
<b>Violencia sexual</b>	32,7%	36,6%	22,9%
<b>Violencia económica y patrimonial</b>	16,4%	17,0%	14,9%
<b>Violencia gineco-obstétrica</b>	47,5%	44,7%	54,8%

Nota: La violencia total incluye violencia psicológica, física, sexual, económica y patrimonial y la gineco-obstétrica en Ecuador (2019)

Además, el Consejo Nacional para la Igualdad de Género (CNIG) ha revelado una preocupante tendencia en el uso de plataformas digitales para ejercer violencia de género (CNIG, 2021). La creciente digitalización de la sociedad ha expuesto patrones

de comportamiento, interacciones sociales y datos personales en diversas plataformas digitales, aumentando el riesgo de violencia en estos entornos (Rivoir & Morales, 2019).

La psicóloga Diana Ramírez, experta en apoyo psicológico a víctimas de violencia de género, ha trabajado en diversos entornos terapéuticos ofreciendo tanto terapias individualizadas como grupales que promueven la recuperación emocional y la reintegración social de las personas afectadas. A lo largo de su carrera, Ramírez ha enfatizado la importancia de involucrar tecnología en la prevención y detección de este problema social.

En una entrevista realizada el 19 de septiembre de 2024, Ramírez destacó la importancia de que tanto las instituciones como la sociedad comprendan la gravedad de la violencia de género y adopten medidas proactivas para prevenirla. Según Ramírez, la incorporación de tecnologías avanzadas, como el Machine Learning, constituye una herramienta invaluable para anticipar situaciones de riesgo y proteger a las potenciales víctimas, enfatizando así el papel que estas tecnologías pueden desempeñar en la mejora de las estrategias preventivas (D. Ramirez, comunicación personal, 19 de septiembre de 2024)

La necesidad de una herramienta predictiva es aún más relevante si consideramos las dinámicas culturales y socioeconómicas del Ecuador, un país marcado por una diversidad geográfica que incluye zonas rurales con menor conectividad y grupos vulnerables con escaso acceso a la justicia o a canales de denuncia formales. Las soluciones actuales no siempre contemplan las diferencias lingüísticas, las barreras de acceso a la tecnología, o la compleja interacción de factores socioeconómicos (como desempleo, migración interna, y estructuras familiares tradicionales) que pueden exacerbar las condiciones propicias para la violencia. Esta variabilidad contextual dificulta la generalización de las aproximaciones tecnológicas



diseñadas en otros países o bajo supuestos distintos, evidenciando la necesidad de adaptar y refinar los modelos a la realidad local.

La adopción de un enfoque basado en Machine Learning (ML) ofrece ventajas significativas frente a las estrategias convencionales. A diferencia de las metodologías reactivas (basadas en denuncias posteriores o en análisis manual de casos) ML permite analizar grandes volúmenes de datos complejos y heterogéneos, tanto estructurados como no estructurados. Esto es crucial en un escenario donde la violencia se manifiesta no solo en el ámbito físico, sino también en el digital (Rivoir & Morales, 2019);(EFE / Redacción Primicias, 2024). Herramientas de procesamiento de lenguaje natural (NLP) pueden detectar patrones en redes sociales, mensajes anónimos o testimonios, mientras que enfoques multimodales integran datos textuales con otros tipos de información, incrementando la capacidad de anticipar comportamientos y situaciones de riesgo.

Sin embargo, las experiencias internacionales citadas, como la detección de violencia en videos de vigilancia (Zhou et al., 2018) o el análisis legal automatizado (Garcia-Vergara et al., 2023), plantean limitaciones cuando se trasladan a Ecuador. La disponibilidad de datos legales digitalizados sigue siendo escasa, la infraestructura para el análisis de video puede ser costosa y centralizada, y las metodologías diseñadas para entornos altamente conectados no se adaptan fácilmente a regiones con brechas digitales. Estas carencias influyen directamente en el diseño del presente modelo, obligando a seleccionar algoritmos e insumos de datos compatibles con la realidad local. Por ejemplo, si el acceso a datos estructurados es limitado, el modelo deberá enfocarse en fuentes que sí estén disponibles, como encuestas nacionales (ENVIGMU) o datos textuales de denuncias en línea, garantizando la representatividad y robustez ante condiciones de datos incompletos o ruidosos.

Asimismo, la efectividad del ML en este contexto depende del reconocimiento de factores psicosociales y culturales que influyen en el fenómeno. Más allá de los datos duros, el modelo deberá considerar la variabilidad lingüística del español ecuatoriano, las formas sutiles de violencia psicológica arraigadas en tradiciones culturales, y la posible desconfianza hacia las instituciones. Estos aspectos son fundamentales para asegurar que el modelo no solo identifique patrones de riesgo, sino que sus resultados sean significativos para los actores locales, desde ONG hasta fuerzas de seguridad, y que se traduzcan en estrategias preventivas culturalmente pertinentes.

En conclusión, el desarrollo de un modelo predictivo de ML orientado al contexto ecuatoriano no se limita a replicar soluciones diseñadas en otros países o bajo otras condiciones. La justificación de su uso radica en la capacidad del ML para analizar datos complejos y multiformato, anticipar comportamientos y adaptarse a un entorno socioeconómico y cultural diverso. Esta aproximación, más que sustituir las respuestas existentes, busca complementarlas, brindando una perspectiva proactiva que permita intervenir antes de que el daño ocurra. Con ello, se propone una solución más integral y contextualizada a la crisis de violencia de género en el Ecuador, allanando el camino hacia un entorno más seguro y equitativo.

### **1.3.1 Preguntas de investigación**

#### **1.3.1.1 Pregunta de investigación general:**

¿Cómo se puede desarrollar un modelo de Machine Learning eficaz para predecir casos de violencia de género en Ecuador?

#### **1.3.1.2 Preguntas de investigación específicas:**

1. ¿Qué revelan la literatura científica y los informes técnicos sobre la violencia de género en relación con los factores predictivos y los modelos de Machine Learning?

2. ¿Cuáles son las características del conjunto de datos que permiten identificar patrones y correlaciones relevantes para la detección de casos de violencia de género?
3. ¿Cómo se puede diseñar un modelo de Machine Learning que optimice la identificación temprana de patrones de riesgo de violencia de género en Ecuador?
4. ¿Qué nivel de precisión, sensibilidad y especificidad puede alcanzar el modelo propuesto en la predicción de casos de violencia de género?

## **1.4 Objetivos**

### **1.4.1 Objetivo General**

Desarrollar un modelo de machine learning destinado a predecir casos de violencia de género en Ecuador, mejorando la identificación temprana de situaciones de riesgo mediante una arquitectura eficiente, escalable y usable, optimizando así las respuestas de los actores involucrados.

### **1.4.2 Objetivos Específicos**

- Realizar una revisión exhaustiva de las investigaciones académicas y estudios técnicos relacionados con la violencia de género y la Inteligencia Artificial, identificando enfoques replicables y adaptables al contexto ecuatoriano.
- Diseñar una arquitectura de software eficiente y escalable, asegurando que los componentes del modelo de Machine Learning sean modulares y replicables para facilitar su adaptación y uso en diferentes entornos y regiones.
- Implementar un modelo de Machine Learning optimizado mediante técnicas avanzadas de procesamiento de datos y selección de

características, evaluando métricas clave como precisión, sensibilidad y especificidad para garantizar su éxito.

- Evaluar el rendimiento del modelo a través de pruebas específicas de replicabilidad, escalabilidad, precisión, sensibilidad y especificidad, garantizando que cumpla con estándares de Ingeniería de Software y sea fácilmente adaptable a nuevos conjuntos de datos.

### **1.5 Justificación**

La incorporación de tecnologías avanzadas, como el machine learning, ha demostrado ser una herramienta efectiva para abordar problemáticas sociales complejas, como la violencia de género. En Ecuador, esta problemática ha alcanzado niveles alarmantes, afectando al 64.9% de las mujeres a lo largo de sus vidas, según datos del Instituto Nacional de Estadística y Censos (INEC, 2019). Este escenario subraya la necesidad de implementar soluciones tecnológicas que permitan optimizar los recursos y la eficacia en la identificación y prevención de situaciones de riesgo.

Desde un enfoque tecnológico, el desarrollo de un modelo predictivo basado en machine learning ofrece la capacidad de analizar grandes volúmenes de datos provenientes de diversas fuentes, como registros policiales, encuestas y redes sociales. Esto permite identificar patrones de violencia que de otra forma podrían pasar desapercibidos, garantizando una detección temprana de casos de riesgo. Experiencias internacionales, como las de España con el sistema VioGén, han demostrado que la inteligencia artificial puede mejorar significativamente la asignación de recursos y la protección de las víctimas (Avella et al., 2023). En el contexto ecuatoriano, una herramienta similar podría complementarse con las bases de datos nacionales existentes para priorizar intervenciones y mejorar la eficiencia del sistema judicial y policial.

En el ámbito social, esta herramienta tecnológica tiene el potencial de optimizar las políticas públicas destinadas a la prevención de la violencia de género. Al proporcionar información precisa y en tiempo real sobre zonas y perfiles de riesgo, las autoridades pueden diseñar estrategias más efectivas y focalizadas, reduciendo la incidencia de violencia y maximizando el impacto de los recursos disponibles (Pinto-Muñoz et al., 2023b). Esto se alinea con los objetivos de la Ley Orgánica Integral para Prevenir y Erradicar la Violencia contra las Mujeres (LOIPEVM), complementando el marco legal con una solución innovadora y eficiente.

En el aspecto cultural, las normas y discursos culturales en Ecuador han perpetuado la violencia de género, influyendo en las identidades femeninas y en la aceptación social de estas conductas. Estudios señalan que las construcciones culturales tradicionales refuerzan roles de género desiguales, lo que dificulta la erradicación de la violencia contra las mujeres (Reina Barreto, Johanna Alexandra et al., 2021)

Desde una perspectiva psicológica, la implementación de un modelo predictivo no solo ayuda a prevenir la violencia, sino que también contribuye a disminuir el impacto emocional y el trauma asociado a estas situaciones. Herramientas similares en América Latina, como el chatbot Violetta en México, han demostrado cómo la tecnología puede empoderar a las potenciales víctimas, brindándoles recursos y apoyo para tomar decisiones informadas y proteger su bienestar (Lagos, 2024). En Ecuador, este tipo de iniciativas puede transformar la manera en que las víctimas acceden a ayuda, fortaleciendo el tejido social y promoviendo una mayor equidad.

La integración de soluciones tecnológicas basadas en machine learning en programas obstétricos y de organizaciones no gubernamentales (ONG) ha demostrado ser efectiva para ampliar el alcance e impacto de las intervenciones en zonas rurales con acceso limitado a servicios. Por ejemplo, el programa MURU: Mujeres Rurales

Diversas y Gestión Local para Erradicar las Violencias Basadas en Género en 3 provincias del Ecuador aborda los altos niveles de violencia de género que enfrentan las mujeres y niñas rurales, así como las carencias de las entidades locales para enfrentarlos (Paz y Desarrollo, 2022). Este programa destaca la importancia de identificar factores de riesgo específicos en comunidades rurales, permitiendo intervenciones oportunas y adaptadas a las necesidades locales.

Por lo tanto, la implementación de modelos de machine learning en entornos obstétricos y ONG puede integrarse con programas existentes para identificar factores de riesgo específicos en zonas rurales, permitiendo intervenciones más efectivas y adaptadas a las necesidades locales. Asimismo, las ONG pueden utilizar los datos generados por estos modelos para monitorear y mejorar la efectividad de sus programas, priorizando áreas que requieren mayor atención y recursos.

El desarrollo de estos modelos predictivos tiene el potencial de transformar el abordaje de la violencia de género en Ecuador. No solo aporta innovaciones tecnológicas aplicadas a un problema crítico, sino que también ofrece beneficios sociales, psicológicos y económicos, optimizando las respuestas de los actores involucrados y contribuyendo a una sociedad más segura, equitativa y resiliente.

## 2 Revisión de la literatura

### 2.1 Antecedentes de la Investigación

En 2020, Prieto Cruz y Montoya Vázquez desarrollaron un modelo experimental para detectar la violencia contra la mujer en redes sociales en español, usando técnicas de Opinion Mining. Su propósito fue abordar la carencia de modelos en español aplicados a la detección de violencia de género en redes. Utilizaron algoritmos de Naive Bayes, Árboles de Decisión y Support Vector Machine, y validaron sus resultados con un especialista en lingüística para garantizar precisión en el análisis de texto. Los resultados demostraron efectividad en la identificación de textos con contenido de violencia de género, sugiriendo que el modelo podría ser una herramienta útil para monitorear y combatir la violencia de género en línea, proporcionando una base importante para el monitoreo en español (Prieto Cruz & Montoya Vasquez, 2020).

Este antecedente evidencia la eficacia de utilizar técnicas de *Machine Learning* y procesamiento del lenguaje natural para detectar violencia de género en redes sociales en español. Por consiguiente, respalda la viabilidad de desarrollar un modelo predictivo que identifique patrones de violencia en entornos digitales, tal como se propone en esta investigación para el contexto ecuatoriano.

En 2023, Javier Plo Moreno desarrolló una arquitectura de sistema para prevenir la violencia de género en España, diseñó una arquitectura de sistema para prevenir la violencia de género mediante Machine Learning y análisis de datos históricos. Su propósito fue mejorar la precisión en la predicción de casos de violencia de género usando informes policiales, expedientes judiciales y bases de datos de sistemas como Servicio Telefónico de Atención y Protección para víctimas de la violencia de género (ATENPRO) y el Sistema de Seguimiento Integral en los casos de Violencia de Género (VIOGEN). Como resultado, el sistema logró un 60% de mejora en la detección de

posibles casos de violencia, demostrando que los modelos de ML son eficaces para intervenciones preventivas (Moreno, 2023).

Los resultados demostraron una identificación efectiva de patrones que podrían predecir situaciones de riesgo, logrando una mejora del 60% en la precisión de detección de posibles casos de violencia. El autor concluyó que la implementación de un sistema integral puede mejorar significativamente las capacidades preventivas de las fuerzas de seguridad y los organismos estatales, permitiendo una intervención más adecuada en áreas y momentos críticos.

Este estudio resulta significativo para el desarrollo del actual trabajo de integración curricular, puesto que demuestra la aplicabilidad de modelos de Machine Learning en la predicción de casos de violencia de género utilizando datos oficiales. Este antecedente refuerza la viabilidad de aplicar técnicas similares en Ecuador, ajustándolas a los contextos y datos locales para optimizar la respuesta ante situaciones de riesgo

Asimismo, en 2023, Caisa Coyago y Rosero Espinoza en su estudio descriptivo, analizaron la violencia de género en Ecuador aplicando técnicas de minería de datos. El propósito fue comprender mejor los patrones de violencia en el país. Los datos se obtuvieron del repositorio de violencia de género del INEC y se dividieron en cinco subconjuntos de diferentes ámbitos de violencia. La metodología incluyó el uso del algoritmo de *árbol de decisión*, particularmente efectivo en el análisis de violencia psicológica en entornos educativos, logrando una precisión significativa (Caisa Coyago & Rosero Espinosa, 2023).

Los datos se dividieron en cinco subconjuntos representativos de diversos ámbitos de violencia. Un hallazgo destacado fue la aplicación del algoritmo de árbol de decisión en el conjunto de datos sobre violencia psicológica en el entorno educativo,



donde el modelo alcanzó una puntuación de 1, indicando una predicción precisa de situaciones de violencia. Los autores concluyeron que estos resultados proporcionan una base sólida para futuras investigaciones y una comprensión más profunda de la violencia de género en el país.

Este estudio es particularmente relevante para la investigación actual, ya que se enfoca en el contexto ecuatoriano y demuestra la efectividad de las técnicas de minería de datos en la predicción de violencia de género. Por lo tanto, respalda la posibilidad de desarrollar modelos precisos basados en datos locales, alineándose con el objetivo de esta tesis de crear un modelo adaptado a las realidades y necesidades de Ecuador.

De igual manera, en 2023, Roa Avella y colaboradores, enfocados en la predicción de violencia de género y femicidio, exploraron herramientas de IA que combinan métodos de derecho y ciencias computacionales en Colombia. Analizaron factores de riesgo a partir de datos de la víctima, el perpetrador y la relación entre ellos, concluyendo que, aunque la precisión varía, la IA ofrece una ventaja significativa en la prevención de violencia de género (Avella et al., 2023)

Los resultados indicaron que los algoritmos y herramientas de IA son capaces de evaluar y ponderar factores relacionados con el perpetrador, la víctima y la relación familiar. Sin embargo, también se observó que la precisión y confiabilidad de estos modelos pueden variar considerablemente. A pesar de las críticas, los autores concluyeron que la inteligencia artificial ofrece ventajas significativas para la predicción y prevención de la violencia de género.

Este antecedente resalta la importancia de considerar aspectos éticos y legales en el uso de inteligencia artificial para predecir la violencia de género, lo cual es fundamental para la presente investigación. La combinación de disciplinas en su

enfoque subraya la necesidad de un abordaje multidisciplinario, tal como se propone en esta tesis, y enfatiza la relevancia de desarrollar modelos confiables y precisos.

Finalmente, mirando hacia 2024, con un diseño experimental, Luvini investigó la violencia de género digital en redes sociales mediante análisis de sentimientos en Twitter, en un proyecto entre el PNUD, el Instituto Nacional de las Mujeres y la Embajada Británica en Uruguay. Usando *Robertuito*, un modelo preentrenado, lograron detectar de manera precisa contenido abusivo hacia mujeres en política. (Luvini, 2024).

El proceso de anotación involucró a anotadores que clasificaron los tweets en categorías como abusivos, críticos, neutrales, positivos o de contra-abuso. Se emplearon varios modelos de lenguaje preentrenados, siendo Robertuito el que mostró mejor rendimiento. Los resultados indicaron que este modelo alcanzó un alto nivel de precisión en la detección de tweets abusivos dirigidos a mujeres en la política. El estudio concluyó que la inteligencia artificial puede ser una herramienta eficaz para identificar y combatir la violencia digital.

Este estudio evidencia que es posible aplicar modelos similares en Ecuador, aprovechando la IA para identificar y mitigar la violencia en entornos digitales, y adaptando estas metodologías al contexto nacional para mejorar la prevención de violencia digital

El uso de Machine Learning en soluciones de carácter social ha ganado mayor relevancia en la comunidad científica y tecnológica. Los modelos de aprendizaje automático brindan capacidades avanzadas para la detección y mitigación de amenazas al identificar patrones y anomalías en los datos recopilados que podrían indicar casos de violencia de género.

La relevancia de desarrollar modelos específicos de ML para la detección de casos de VG radica en la necesidad urgente de proteger a las potenciales víctimas y a

la sociedad en general. La investigación en esta área está enfocada en crear modelos precisos y eficientes que puedan detectar y prever situaciones de riesgo, minimizando el daño y buscando el bienestar de las personas afectadas.

## **2.2 Referencias Teóricas**

### **2.2.1 Definición de Violencia de Género**

La violencia de género se refiere a cualquier acto de violencia que resulta en daño o sufrimiento físico, sexual, psicológico o económico hacia una persona debido a su género. Esta violencia suele estar dirigida principalmente hacia mujeres y minorías de género, quienes enfrentan una vulnerabilidad exacerbada en contextos de desigualdad estructural y normas patriarcales que legitiman su subordinación (Alba Moreira & Zita Santos, 2023)

Investigaciones recientes también han revelado que la violencia de género (VG) se entiende como aquella dirigida hacia una persona por su género o que afecta más a ciertos géneros debido a desigualdades estructurales. Esta incluye violencia física, emocional y sexual, acoso tecnológico, matrimonios forzados, trata de personas y otros abusos que, en muchos casos, impactan principalmente a mujeres, niñas y minorías de género. Estas últimas abarcan a quienes poseen identidades o expresiones de género diversas, como personas que se identifican como queer, lesbianas, gays, bisexuales, transgénero, entre otros. (van Daalen et al., 2022)

La violencia de género no es solo un problema interpersonal, sino también un fenómeno estructural que refleja y reproduce las desigualdades inherentes en las sociedades patriarcales. Estas dinámicas incluyen prácticas de control y opresión que históricamente han limitado las oportunidades y derechos de las mujeres, especialmente en zonas rurales o en comunidades con escaso acceso a la justicia. (Alba Moreira & Zita Santos, 2023)

## 2.2.2 Tipos de Violencia de Género (VG) y Características

La violencia de género es un fenómeno multidimensional que afecta a mujeres en diversas formas y contextos. Se manifiesta a través de diferentes tipos, cada uno con características específicas que requieren una comprensión profunda para su prevención y erradicación. Entre los tipos más comunes se encuentran la violencia física, psicológica, sexual, económica y simbólica (Psicología y Mente, 2017).

- **Violencia Física:** Implica cualquier acto que cause daño corporal a la víctima, como golpes, empujones o agresiones con objetos. Es una de las formas más visibles de violencia y puede dejar secuelas físicas y emocionales.
- **Violencia Psicológica:** Se caracteriza por acciones que afectan la estabilidad emocional de la persona, como insultos, humillaciones, manipulación y aislamiento social. Aunque no deja marcas físicas, su impacto puede ser profundo y duradero.
- **Violencia Sexual:** Comprende cualquier acto sexual no consentido, incluyendo violación, abuso y explotación sexual. Este tipo de violencia vulnera la integridad y autonomía sexual de la víctima.
- **Violencia Económica:** Consiste en el control y limitación de los recursos económicos de la persona, impidiendo su independencia financiera y acceso a bienes básicos.
- **Violencia Simbólica:** Se refiere a la reproducción de estereotipos y roles de género que perpetúan la desigualdad y subordinación de las mujeres en la sociedad.

Entender estas tipologías es esencial para diseñar estrategias efectivas de intervención y apoyo a las víctimas, así como para promover cambios culturales que erradiquen la violencia de género en todas sus formas.

### **2.2.3 Impacto de la Violencia de Género**

La violencia de género es un problema crítico y persistente que afecta de manera desproporcionada a mujeres y niñas en múltiples dimensiones, impactando tanto su bienestar físico como emocional y social. Según Pérez Martínez y Rodríguez Fernández (2024), este fenómeno no solo constituye una violación a los derechos humanos, sino también un problema de salud pública de alta magnitud, cuyas implicaciones se han intensificado en el contexto de la pandemia. En Ecuador, al igual que en otras partes del mundo, la violencia de género se manifiesta de manera compleja y multidimensional, afectando a las mujeres desde edades tempranas y limitando sus oportunidades de desarrollo en diversas esferas (Pérez-Martínez & Rodríguez-Fernández, 2024)

Entre las principales dificultades en la atención a las mujeres víctimas de violencia de género se encuentran la infradetección y la falta de coordinación entre los distintos organismos implicados. Los profesionales sanitarios juegan un papel fundamental en la prevención, detección y tratamiento, siendo necesario potenciar una formación específica y articular mecanismos y protocolos de coordinación entre los distintos servicios socio-sanitarios para garantizar una atención integral (SMC España, 2023).

### **2.2.4 Importancia de la Prevención de la Violencia de Género**

La prevención de la violencia de género es esencial para garantizar la seguridad y el bienestar de las mujeres. ONU Mujeres destaca que la prevención implica abordar las causas fundamentales de la violencia, como la desigualdad de género, las normas sociales y los estereotipos que perpetúan la discriminación (Organización Mundial de la Salud, 2021)

Las estrategias de prevención incluyen la implementación de programas educativos que promuevan la igualdad de género, campañas de sensibilización,

fortalecimiento de marcos legales y políticas públicas, y la creación de servicios de apoyo accesibles para las víctimas. La colaboración intersectorial y el compromiso de toda la sociedad son cruciales para poner fin a la violencia contra las mujeres.

La violencia de género en redes sociales es un problema creciente, afectando particularmente a jóvenes y adolescentes que son vulnerables al acoso y la violencia digital. Según estudios recientes, estas plataformas, aunque útiles para la comunicación, facilitan conductas sexistas y violentas hacia las mujeres (Núñez Gómez, Patricia, 2021). Promover un uso responsable de las redes sociales mediante la educación y la sensibilización es esencial para crear espacios digitales seguros y equitativos.

### **2.2.5 Definición de Machine Learning**

Según Pedrero et al. (2021), el Machine Learning es un conjunto de herramientas analíticas destinadas a desarrollar algoritmos que permiten extraer información de los datos para fines de explicación, clasificación o predicción. Este enfoque ha demostrado ser particularmente útil en el ámbito de la gestión de servicios de salud, donde facilita la toma de decisiones al permitir analizar grandes volúmenes de datos clínicos y administrativos, sin depender de hipótesis previas.

Por su parte, Lanzagorta Ortega, Carrillo Pérez y Carrillo Esper (2022) describen el *Machine Learning* como una técnica dentro de la inteligencia artificial que emplea algoritmos y software complejos para emular ciertos procesos cognitivos humanos, particularmente en el análisis y diagnóstico de datos médicos. En medicina, el Machine Learning ayuda a automatizar tareas de interpretación y análisis, mejorando la precisión diagnóstica y optimizando la atención al paciente mediante el reconocimiento de patrones y la generación de modelos predictivos a partir de grandes cantidades de datos.

## 2.2.6 Tipos de Algoritmos de Machine Learning

. Los algoritmos de Machine Learning (ML) se dividen en cuatro categorías principales basadas en el estilo de aprendizaje y el tipo de datos utilizados: supervisados, no supervisados, semi-supervisados y de aprendizaje por refuerzo. Los algoritmos supervisados, como los de clasificación y regresión, trabajan con datos etiquetados para realizar predicciones precisas. Por otro lado, los algoritmos no supervisados se enfocan en descubrir patrones o agrupaciones en datos no etiquetados. Este enfoque diverso permite a los algoritmos adaptarse a una amplia gama de aplicaciones y características específicas (Sarker, 2021).

**Aprendizaje Supervisado:** Los algoritmos de aprendizaje supervisado se entrenan utilizando datos de entrenamiento etiquetados. Los científicos de datos proporcionan al algoritmo entradas y salidas conocidas, lo que permite al modelo aprender las relaciones entre ellas. Este enfoque es útil para tareas como la clasificación y la regresión, donde se busca predecir resultados basados en datos históricos.

- **Aprendizaje No Supervisado:** En este caso, los algoritmos trabajan con datos no etiquetados y buscan encontrar estructuras o patrones ocultos en los datos. El aprendizaje no supervisado es útil para el reconocimiento de patrones, la detección de anomalías y la agrupación de datos en categorías sin una guía previa.
- **Aprendizaje Semisupervisado:** Combina elementos del aprendizaje supervisado y no supervisado. Se utiliza una pequeña cantidad de datos etiquetados junto con una gran cantidad de datos no etiquetados. Este enfoque es beneficioso cuando el etiquetado de datos es costoso o requiere mucho tiempo, permitiendo al modelo aprender de manera más eficiente.
- **Aprendizaje por Refuerzo:** En este enfoque, un agente aprende a tomar decisiones en un entorno con el objetivo de maximizar una recompensa

acumulada. El agente recibe retroalimentación en forma de recompensas o castigos y aprende a través del ensayo y error. El aprendizaje por refuerzo es útil en áreas como la robótica, los juegos y los sistemas de recomendación.

### **2.2.7 Machine Learning para Problemáticas Sociales**

El ML ha comenzado a desempeñar un papel significativo en la resolución de problemas sociales, ofreciendo nuevas perspectivas y herramientas para abordar desafíos complejos (María José Moreno, s. f.). En el ámbito de los servicios sociales, el ML se utiliza para mejorar la asignación de recursos, predecir necesidades futuras y diseñar intervenciones más efectivas (Fundación ISocial, 2022).

En el contexto de la violencia de género, el ML puede ayudar a identificar patrones de riesgo, mejorar la detección temprana y personalizar las estrategias de prevención. Sin embargo, es fundamental abordar consideraciones éticas, como la privacidad de los datos y el sesgo algorítmico, para garantizar que estas herramientas beneficien a las poblaciones vulnerables sin causar daño.

### **2.2.8 Machine Learning y su Aplicación en la Violencia de Género**

El Machine Learning es una rama de la inteligencia artificial que se centra en la creación de modelos capaces de aprender y mejorar sus predicciones basándose en datos históricos (AWS, s. f.). En este contexto, el ML ha sido ampliamente adoptado en sistemas de justicia y seguridad, especialmente para evaluar riesgos y patrones en situaciones de violencia, permitiendo una toma de decisiones más informada y rápida. Según Lima y De Oliveira (2024), el uso de algoritmos como Long Short-Term Memory (LSTM) ha demostrado ser eficaz en la identificación de patrones de riesgo en casos de violencia doméstica en Brasil, contribuyendo significativamente a la prevención de actos de violencia extrema, como el feminicidio (Lima & de Oliveira, 2024).



La aplicación de ML en la violencia de género se ha expandido en diversos sistemas de prevención policial en Europa y América Latina. En el caso del sistema VioGén en España, el aprendizaje automático se ha incorporado para mejorar la eficiencia de la intervención policial, evaluando el riesgo de reincidencia y facilitando una respuesta adaptada a cada caso (San Martín Segura, 2023). Esta tecnología permite que los organismos de seguridad cuenten con herramientas que analicen grandes volúmenes de datos, generando predicciones que contribuyan a una asignación más precisa de los recursos, optimizando la protección de las víctimas en un contexto de escasez de recursos.

## **2.3 Marco legal**

### **2.3.1 Constitución De La República Del Ecuador 2008**

La Constitución de la República del Ecuador de 2008 establece un marco normativo integral que garantiza la protección de los derechos fundamentales y fomenta la innovación tecnológica en el país. Este marco normativo es fundamental para el desarrollo de tecnologías como el machine learning, ya que proporciona directrices claras sobre la supremacía de los derechos humanos y la jerarquía normativa.

El artículo 425 señala el orden jerárquico de aplicación de las normas en el Ecuador. Este orden establece que la Constitución ocupa el primer lugar, seguida por los tratados y convenios internacionales, las leyes orgánicas, las leyes ordinarias, las normas regionales, las ordenanzas distritales, los reglamentos, las ordenanzas y, finalmente, las demás normas y actos de los órganos del poder público. (Constitución de la República del Ecuador, 2008)

#### **Título II: Derechos**

Aborda la protección de los derechos individuales en el ámbito de los datos personales, un aspecto fundamental para el desarrollo e implementación de tecnologías

como el machine learning. En el artículo 66, numeral 19, se reconoce y garantiza el derecho de las personas a la protección de sus datos personales. Este derecho incluye la facultad de acceder a su información y tomar decisiones sobre esta, así como asegurar su correspondiente protección frente a posibles vulneraciones (Constitución de la República del Ecuador, 2008).

La Constitución garantiza a las personas el derecho a la protección de sus datos personales, lo que incluye la capacidad de acceder y decidir sobre la información que les concierne. Este artículo es esencial para cualquier iniciativa que implique la recolección y tratamiento de datos personales, asegurando que se respeten los derechos de privacidad en el desarrollo de modelos predictivos.

#### **Sección quinta: Cultura y ciencia**

La Constitución de la República del Ecuador de 2008 establece principios clave relacionados con la cultura y la ciencia, los cuales son esenciales para fomentar el desarrollo tecnológico y la innovación. Según lo dispuesto en el artículo 17, el Estado tiene la responsabilidad de garantizar la soberanía informática, promoviendo la producción, difusión y acceso al conocimiento científico y tecnológico. Asimismo, se establece que el Estado promulgará leyes orientadas a incentivar la creación de software libre y el uso de estándares abiertos en las administraciones públicas, siempre que estos no comprometan la seguridad y defensa del país (Constitución de la República del Ecuador, 2008).

El Estado fomenta la producción y difusión del conocimiento científico y tecnológico, con un énfasis en la creación de software libre y el uso de estándares abiertos. Este enfoque es vital para garantizar la soberanía tecnológica en proyectos de machine learning, facilitando la independencia de tecnologías propietarias.

En la misma sección se resalta la importancia de la innovación tecnológica en el desarrollo del país. En el artículo 388, se establece que el Estado promoverá la

creación y producción de tecnologías libres, fundamentadas en estándares abiertos. Estas tecnologías deben estar orientadas a satisfacer las necesidades de los sectores estratégicos del desarrollo nacional y garantizar la soberanía tecnológica, asegurando así un enfoque independiente y sostenible en el ámbito tecnológico (Constitución de la República del Ecuador, 2008). Este artículo refuerza la necesidad de que las tecnologías desarrolladas sean accesibles y sostenibles, alineadas con los objetivos de desarrollo nacional.

### **2.3.2 Tratados y Convenios Internacionales**

#### **Convención Interamericana para Prevenir, Sancionar y Erradicar la Violencia contra la Mujer (Convención de Belém do Pará) – 1994**

La Convención Interamericana para Prevenir, Sancionar y Erradicar la Violencia contra la Mujer, conocida como la Convención de Belém do Pará de 1994, establece en su Capítulo III las obligaciones de los Estados Parte. Según el artículo 7, los Estados condenan todas las formas de violencia contra la mujer y se comprometen a adoptar políticas orientadas a prevenir, sancionar y erradicar dicha violencia (Convención Interamericana para Prevenir, Sancionar y Erradicar la Violencia contra la Mujer, 1994). Estas acciones deben llevarse a cabo sin dilaciones y utilizando todos los medios apropiados, garantizando así un enfoque integral para abordar esta problemática.

Los involucrados se comprometen a adoptar políticas integrales para prevenir, sancionar y erradicar la violencia contra la mujer. Un modelo de ML que predice casos de violencia de género puede considerarse una herramienta clave en la implementación de estas políticas.

#### **Declaración de Beijing y Plataforma de Acción (1995)**

La Declaración de Beijing y Plataforma de Acción de 1995 identifica áreas críticas de preocupación, entre las cuales se encuentra la violencia contra la mujer, descrita en la Sección D del Capítulo IV. En el párrafo 129, se establece que los gobiernos y otras

partes interesadas tienen la responsabilidad de apoyar la investigación sobre la violencia contra las mujeres. Además, se enfatiza la importancia de utilizar la información y los datos estadísticos generados para la formulación de políticas públicas orientadas a prevenir y abordar esta problemática de manera efectiva (Declaración de Beijing y Plataforma de Acción, 1995).

Este párrafo es particularmente relevante para el desarrollo del modelo, puesto que refuerza la importancia de la investigación basada en datos para abordar la violencia de género. La utilización de información y estadísticas es clave para crear políticas públicas efectivas y diseñar modelos predictivos que puedan identificar patrones de violencia, permitiendo una respuesta más rápida y eficaz.

#### **Directrices de Ética para la Inteligencia Artificial de la UNESCO (2021)**

Las Directrices de Ética para la Inteligencia Artificial de la UNESCO, publicadas en 2021, destacan valores éticos y principios fundamentales en su Sección B. Dentro de la Subsección IV, sobre igualdad, no discriminación y equidad, se establece que las tecnologías de inteligencia artificial deben ser utilizadas para promover la igualdad y evitar la discriminación. Además, se enfatiza la importancia de prestar especial atención a la equidad de género y la inclusión de grupos desfavorecidos, garantizando que estas tecnologías contribuyan al desarrollo inclusivo y justo (Directrices de Ética para la Inteligencia Artificial, 2021).

Las tecnologías de inteligencia artificial deben promover la igualdad y no la discriminación, prestando especial atención a la equidad de género. Este principio es fundamental para asegurar que los modelos predictivos desarrollados no perpetúen sesgos y se utilicen de manera ética.

### **2.3.3 Leyes Orgánicas**

#### **Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación**

El Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación establece principios fundamentales para el acceso al conocimiento en su Capítulo II. En el artículo 3, numeral 2, se señala que el Estado tiene la responsabilidad de promover el acceso a la información pública con el objetivo de fomentar la innovación y el desarrollo de nuevas tecnologías. Asimismo, se garantiza la transparencia y la libre circulación de la información, asegurando que estas acciones contribuyan al avance tecnológico y social (Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, 2016).

Este artículo apoya la reutilización de datos abiertos, como los proporcionados por el INEC, para la creación de modelos predictivos que puedan ayudar a prevenir la violencia de género.

### **2.3.4 Leyes Ordinarias**

#### **Ley Orgánica de Transparencia y Acceso a la Información Pública (LOTAIP)**

El Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación establece en su Título I, Capítulo I, los principios generales que rigen esta normativa. Según el artículo 1, el objetivo principal de esta ley es garantizar el acceso a la información pública y fortalecer la transparencia en la gestión estatal. Este principio busca promover una gestión más abierta y accesible, en línea con el desarrollo de una sociedad basada en el conocimiento y la innovación (Ley Orgánica de Transparencia y Acceso a la Información Pública, 2004a).

En su Título II, Capítulo I, las bases para el ejercicio del derecho de acceso a la información. En el artículo 3, se dispone que todas las personas, ya sea de forma

individual o colectiva, tienen el derecho de acceder a la información pública conforme a los términos establecidos en esta ley. Este principio fortalece la transparencia y la participación ciudadana (Ley Orgánica de Transparencia y Acceso a la Información Pública, 2004b).

En el Título III, relacionado con los derechos de los titulares, se destaca en el Capítulo I el derecho al acceso a la información. Según el artículo 2, las entidades de la administración pública están obligadas a poner a disposición del público datos abiertos en formatos reutilizables, promoviendo el libre acceso y uso de dicha información, lo que fomenta la innovación y la participación en la gestión pública (Ley Orgánica de Transparencia y Acceso a la Información Pública, 2004c).

Por otra parte, el artículo 11 establece el derecho de toda persona a acceder a sus datos personales. Esto incluye el conocimiento sobre si sus datos están siendo tratados y el acceso a estos de manera clara, concisa y comprensible, garantizando así la protección de los derechos individuales en el manejo de la información personal (Ley Orgánica de Transparencia y Acceso a la Información Pública, 2004d).

Los ciudadanos tienen derecho a conocer cómo se utilizan sus datos personales y a acceder a ellos de manera clara. Este artículo asegura que los proyectos que manejan datos sensibles, como los relacionados con la violencia de género, respeten la privacidad de las personas.

### **Ley Orgánica de Protección de Datos Personales**

El artículo 1 de la Ley Orgánica de Protección de Datos Personales establece como objeto y finalidad garantizar el ejercicio del derecho a la protección de datos personales. Este derecho incluye el acceso y la decisión sobre información de este carácter, así como su correspondiente protección (Ley Orgánica de Protección de Datos Personales, 2021). Para cumplir con este propósito, la ley regula, prevé y desarrolla

principios, derechos, obligaciones y mecanismos de tutela, asegurando un marco normativo integral para la gestión ética y responsable de los datos personales.

El artículo 11 de la Ley Orgánica de Protección de Datos Personales establece que los datos personales cuyo tratamiento esté regulado por normativas especializadas, como aquellas relacionadas con el ejercicio de la libertad de expresión, sectores regulados, gestión de riesgos, desastres naturales, seguridad nacional y defensa del Estado, así como los datos proporcionados a autoridades administrativas o judiciales bajo órdenes legales, estarán sujetos a los principios de sus normativas específicas. Adicionalmente, se aplicarán los principios establecidos en esta ley cuando corresponda y resulte favorable. En todos los casos, se debe garantizar el cumplimiento de los estándares internacionales en derechos humanos y los principios mínimos de legalidad, proporcionalidad y necesidad (Ley Orgánica de Protección de Datos Personales, 2021).

El artículo 31 de la Ley Orgánica de Protección de Datos Personales regula el tratamiento de datos relativos a la salud, estableciendo parámetros mínimos para su manejo y protección, los cuales deberán ser cumplidos según las disposiciones de la Autoridad de Protección de Datos Personales (Ley Orgánica de Protección de Datos Personales, 2021). Entre los principales lineamientos se destacan:

1. Los datos de salud generados en establecimientos públicos o privados deben ser tratados bajo los principios de confidencialidad y secreto profesional. El consentimiento previo del titular es obligatorio, salvo en circunstancias específicas, como la protección de intereses vitales cuando el titular no pueda otorgar consentimiento, la medicina preventiva o laboral, la evaluación de la capacidad laboral, el diagnóstico médico, o la gestión de sistemas y servicios de asistencia sanitaria y social. En estos casos, el tratamiento solo puede ser realizado por profesionales sujetos a la obligación de secreto profesional o bajo

su supervisión, conforme a la legislación especializada y las normativas aplicables.

2. Siempre que sea posible, los datos de salud deben ser anonimizados o seudonimizados para evitar la identificación de los titulares.
3. El tratamiento de datos anonimizados requiere autorización previa de la Autoridad de Protección de Datos Personales. Para obtener esta autorización, el interesado debe presentar un protocolo técnico que garantice la protección de los datos, junto con un informe previo favorable emitido por la Autoridad Sanitaria.

El tratamiento de datos sensibles (como información sobre agresiones, contexto socioeconómico u otros detalles que puedan identificar a víctimas o agresores) está regulado por la Ley Orgánica de Protección de Datos Personales (LOPDP), publicada en el Registro Oficial Suplemento 459 el 26 de mayo de 2021. Esta ley establece que el procesamiento de datos personales, en especial aquellos considerados sensibles, debe realizarse bajo los principios de legalidad, necesidad, proporcionalidad y finalidad, exigiendo la anonimización o seudonimización cuando sea posible y el consentimiento previo del titular para su uso, salvo excepciones legalmente justificadas.

En el caso del presente modelo, no se utilizan datos personales que permitan identificar directamente a las personas involucradas. Por un lado, la información proveniente de encuestas, como la del ENVIGMU Dataset, se presenta de forma agregada y anónima, sin incluir nombres, direcciones o datos que individualicen a las participantes. Por otro lado, en el análisis de datos textuales (como tweets), se emplean únicamente contenidos sin referencia explícita a cuentas o usuarios específicos, preservando así el anonimato de los emisores. Este enfoque cumple con el mandato de



la LOPDP, al no emplear información personal identificable sin el consentimiento del titular, y protege a las personas al evitar su exposición o posible revictimización.

Con esta medida, la investigación garantiza el respeto a la privacidad y a la dignidad humana, conforme lo dispone la LOPDP, brindando a los actores involucrados (instituciones, ONG, fuerzas de seguridad) una herramienta preventiva contra la violencia de género sin vulnerar derechos fundamentales.

## **2.4 Marco Conceptual**

### **2.4.1 Machine Learning (ML)**

El aprendizaje automático o Machine Learning es una rama de la inteligencia artificial que permite a las máquinas aprender y mejorar a partir de la experiencia sin ser programadas explícitamente para ello. Utiliza algoritmos que analizan grandes volúmenes de datos para identificar patrones y hacer predicciones o decisiones informadas (SAP, s. f.).

### **2.4.2 Random Forest**

Un random forest, o bosque aleatorio, es un algoritmo de Machine Learning que combina varios árboles de decisión para mejorar la precisión y la estabilidad en tareas de clasificación y regresión. Es versátil, fácil de interpretar y genera predicciones confiables al integrar los resultados de los árboles (DataScientest, 2022).

### **2.4.3 Regresión Logística**

La regresión logística es un método estadístico utilizado para modelar la probabilidad de un resultado binario, es decir, cuando la variable dependiente es categórica y tiene dos posibles valores, como "sí" o "no" (DATAtab, s. f.). Este modelo es útil para predecir la ocurrencia de un evento basándose en una o varias variables independientes.

#### **2.4.4 Máquinas de Vectores de Soporte (SVM)**

Las *Support Vector Machines* (SVM) son algoritmos de aprendizaje supervisado utilizados tanto para clasificación como para regresión. Funcionan encontrando el hiperplano que mejor separa las clases de datos en el espacio multidimensional de las variables (MathWorks, s. f.).

#### **2.4.5 Naive Bayes**

El algoritmo Naïve Bayes es un clasificador probabilístico basado en el Teorema de Bayes, que asume independencia entre las variables predictoras (Roman, 2019). A pesar de esta suposición simplista, ha demostrado ser eficaz en diversas aplicaciones, como filtrado de spam y análisis de sentimientos.

#### **2.4.6 Árboles de Decisión**

Los árboles de decisión son modelos predictivos que representan decisiones y sus posibles consecuencias en forma de un árbol gráfico (scikit-learn, 2019). Cada nodo interno representa una prueba sobre una variable, las ramas representan el resultado de la prueba, y las hojas finales representan las decisiones tomadas.

#### **2.4.7 NLP (Procesamiento De Lenguaje Natural)**

El Procesamiento del Lenguaje Natural (PLN), o Natural Language Processing (NLP) en inglés, es una disciplina de la inteligencia artificial enfocada en facilitar la interacción entre las máquinas y el lenguaje humano. Su propósito fundamental es capacitar a las computadoras para que puedan entender, interpretar y generar el lenguaje utilizado por las personas. Para lograr esto, se emplea una combinación de técnicas de lingüística computacional y aprendizaje automático, lo cual permite que las computadoras analicen y gestionen grandes cantidades de datos textuales y de audio (Cole Stryker & Jim Holdsworth, 2024).

#### 2.4.8 Word2Vec

Word2vec es una técnica de inteligencia artificial que permite el análisis algorítmico de textos mediante la conversión de palabras en vectores numéricos. Este principio básico se denomina incrustación de palabras y es un medio probado de poner el texto en una forma matemáticamente detectable (Filzinger, 2023) .

#### 2.4.9 Tf-idf (Term Frequency-Inverse Document Frequency)

El término Tf-idf (Frecuencia de Término - Frecuencia Inversa de Documento) es una técnica empleada en recuperación de información y análisis de texto para determinar la relevancia de una palabra específica dentro de un documento en relación con el resto de la colección o corpus (Anirudha, 2021).

Esta técnica combina dos estadísticas:

- **Frecuencia de término (Tf):** Número de veces que un término aparece en un documento.
- **Frecuencia inversa de documento (Idf):** Medida de cuán común o raro es un término en todos los documentos.

Al multiplicar ambas, se resalta términos que son importantes para un documento específico pero que no son comunes en el corpus, lo cual es útil para tareas de clasificación y análisis de texto relacionadas con la violencia de género.

TF-IDF es más interpretable y sencillo de implementar, lo cual puede ser adecuado para un primer modelo en el contexto ecuatoriano, y que ha demostrado buenos resultados en problemas similares en la literatura.

#### 2.4.10 KDD

El Descubrimiento de Conocimiento en Bases de Datos (KDD, por sus siglas en inglés) es un proceso integral que busca identificar patrones válidos, novedosos,

potencialmente útiles y comprensibles a partir de grandes conjuntos de datos. Este enfoque es esencial en la era actual, donde las organizaciones acumulan vastas cantidades de información y requieren métodos eficientes para extraer valor de estos datos. (Timarán Pereira et al., 2016)

#### **2.4.11 Scrumban**

Scrumban es una metodología híbrida que combina elementos de Scrum y Kanban, dos enfoques ágiles ampliamente utilizados en la gestión de proyectos. El término fue acuñado por Corey Ladas en su libro "Scrumban: Essays on Kanban Systems for Lean Software Development" (Sarah Laoyan, 2024)

Scrumban integra la estructura iterativa y las ceremonias de Scrum con la flexibilidad y el enfoque en el flujo de trabajo de Kanban. Esta combinación permite a los equipos beneficiarse de la planificación estructurada de Scrum y, al mismo tiempo, adaptarse a cambios y optimizar procesos mediante las prácticas de Kanban. Según Atlassian, Scrumban utiliza la estructura estable de Scrum (sprints, reuniones rápidas y retrospectivas) e incorpora el flujo de trabajo visual y las limitaciones del trabajo en curso de Kanban.

#### **2.4.12 Metodología CRISP-DM**

La metodología CRISP-DM (Cross Industry Standard Process for Data Mining) es un estándar ampliamente utilizado en proyectos de ciencia de datos y minería de datos. Proporciona una estructura robusta y flexible para guiar el proceso de análisis desde la comprensión del negocio hasta la implementación y mantenimiento del modelo (Haya, 2021).

CRISP-DM se compone de seis fases interrelacionadas:

1. **Comprensión del Negocio:** Implica definir los objetivos y requisitos del proyecto desde una perspectiva empresarial, y convertir este conocimiento en un problema de minería de datos bien definido.
2. **Comprensión de los Datos:** Consiste en recopilar datos iniciales, familiarizarse con ellos, identificar problemas de calidad y descubrir patrones o subconjuntos interesantes.
3. **Preparación de los Datos:** En esta etapa se realizan todas las tareas necesarias para construir el dataset final a partir de los datos iniciales brutos. Incluye selección, limpieza, construcción y formateo de datos.
4. **Modelado:** Se seleccionan y aplican técnicas de modelado apropiadas, calibrando los parámetros para valores óptimos. A menudo, esta fase requiere regresar a la preparación de datos para ajustar variables.
5. **Evaluación:** Antes de la implementación final, es crucial evaluar el modelo para asegurar que cumple con los objetivos empresariales establecidos. Se revisa exhaustivamente el proceso y se determina si hay necesidades adicionales.
6. **Despliegue:** Los resultados se organizan y presentan de manera que el cliente pueda utilizarlos. Esto puede implicar generar reportes, implementar sistemas de scoring en tiempo real o procedimientos periódicos de análisis.

La elección de CRISP-DM frente a otras metodologías como KDD o SCRUMBAN se fundamenta en su amplio reconocimiento y adopción en la industria, lo que facilita una comunicación clara entre equipos multidisciplinarios.

Además, su estructura iterativa permite revisar y ajustar cada fase conforme se identifican nuevas necesidades o limitaciones, manteniendo así la flexibilidad necesaria en proyectos complejos. Esta cualidad es especialmente valiosa en el presente trabajo,

donde la comprensión del negocio (en este caso, la problemática social de la violencia de género) es tan importante como la técnica misma.

CRISP-DM no solo guía el proceso desde la identificación del problema hasta el despliegue del modelo, sino que también garantiza que las decisiones técnicas estén alineadas con los objetivos sociales y éticos del proyecto.

#### **2.4.13 Hiperparámetros de ML**

Los hiperparámetros son configuraciones externas al modelo que no se aprenden a partir de los datos durante el entrenamiento, pero que afectan significativamente su rendimiento (Amazon Web Services, Inc., s. f.). Incluyen aspectos como la tasa de aprendizaje, el número de vecinos en KNN, o la profundidad máxima de un árbol de decisión.

#### **2.4.14 Validación Cruzada**

La validación cruzada es una técnica utilizada para evaluar la capacidad de generalización de un modelo, es decir, su rendimiento en datos no vistos durante el entrenamiento (Daniel, 2022). Consiste en dividir el conjunto de datos en múltiples subconjuntos, entrenando y validando el modelo en diferentes combinaciones de estos.

#### **2.4.15 Exactitud (Accuracy)**

Representa el porcentaje de predicciones correctas que realiza el modelo sobre el total de predicciones, siendo especialmente relevante en problemas de clasificación (Bejarano, 2024).

#### **2.4.16 Precisión (Precision)**

Evalúa la exactitud de las predicciones positivas, es decir, la proporción de verdaderos positivos entre todas las predicciones positivas realizadas. Es particularmente importante cuando el costo de los falsos positivos es elevado (Google For Developers, s. f.).

#### **2.4.17 Sensibilidad (Recall)**

También llamada *recall*, mide la capacidad del modelo para identificar todas las instancias positivas correctamente, calculando la proporción de verdaderos positivos sobre el total de casos reales positivos. Es una métrica clave cuando es necesario minimizar los falsos negativos (FOQUM, 2023).

#### **2.4.18 Puntuación F1 (F1 Score)**

Es la media armónica entre la precisión y la sensibilidad, proporcionando un balance entre ambas métricas. Es útil en escenarios con conjuntos de datos desbalanceados (Jimenez Miguel, 2024).

#### **2.4.19 Matriz de confusión**

La matriz de confusión es una herramienta muy útil para valorar cómo de bueno es un modelo clasificación basado en aprendizaje automático. En particular, sirve para mostrar de forma explícita cuándo una clase es confundida con otra, lo cual nos permite trabajar de forma separada con distintos tipos de error. (Santos, 2021)

#### **2.4.20 Área Bajo la Curva ROC (AUC-ROC)**

Mide la habilidad del modelo para distinguir entre diferentes clases. La curva ROC muestra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos, y un valor de AUC más cercano a 1 indica un rendimiento superior del modelo (Ramírez, 2018).

#### **2.4.21 Lenguaje Python**

Python es un lenguaje de programación de alto nivel, interpretado y de propósito general, conocido por su legibilidad y simplicidad (Alura, 2023). Es ampliamente utilizado en el desarrollo de aplicaciones de ML debido a sus extensas bibliotecas y comunidades de apoyo.

Bibliotecas como scikit-learn, TensorFlow y PyTorch proporcionan herramientas poderosas para implementar algoritmos de ML, facilitando el desarrollo y la experimentación. Además, Python es accesible para principiantes, lo que promueve su uso en educación e investigación.

#### **2.4.22 Dataset**

Un dataset es un conjunto estructurado de datos que se utiliza para entrenar y evaluar modelos de ML (OpenWebinars, 2023). Los datasets pueden contener diversos tipos de información, como texto, números, imágenes o combinaciones de estos.

#### **2.4.23 Flask**

Flask es un framework web de Python que se destaca por su simplicidad, siendo ideal tanto para principiantes como para desarrolladores experimentados. Ofrece solo las características básicas, permitiendo a los usuarios agregar funcionalidades adicionales mediante bibliotecas externas (IONOS, 2023).

#### **2.4.24 Pickle**

Pickle es una biblioteca integrada en Python diseñada para realizar la serialización y deserialización de objetos. Este proceso transforma un objeto de Python, como listas, diccionarios, conjuntos o clases, en una secuencia de bytes que puede almacenarse en un archivo o enviarse a través de una red. La deserialización permite revertir esta conversión, recuperando el objeto original a partir de dicha secuencia de bytes (datacamp, 2024).

#### **2.4.25 Joblib**

Joblib es una biblioteca de Python diseñada para facilitar la ejecución eficiente de funciones y la gestión de grandes volúmenes de datos (Escudero, 2023).

En comparación con el módulo estándar pickle, Joblib ofrece ventajas significativas al trabajar con grandes arrays de NumPy, ya que maneja de manera más



eficiente los búferes de estas estructuras de datos, resultando en tiempos de carga y almacenamiento más rápidos.

#### **2.4.26 HTML**

HTML, o HyperText Markup Language, es un lenguaje de marcado que se emplea para organizar y mostrar contenido en la mayoría de las páginas web y aplicaciones en línea. Utiliza etiquetas que especifican la estructura y el formato de un documento, facilitando la conexión entre recursos mediante hipertextos y la interacción con servidores web para mostrar la información (Gustavo B., 2018).

### **3 Metodología del Proceso de Investigación**

#### **3.1 Enfoque de la Investigación**

La complejidad del fenómeno de la violencia de género en Ecuador, influida por factores socioeconómicos, culturales y políticos, demanda una aproximación que permita captar tanto la dimensión cuantitativa (por ejemplo, la incidencia y prevalencia de casos) o como la cualitativa (relacionada con las percepciones, contextos y factores subyacentes que no se reflejan adecuadamente en las métricas numéricas). En este sentido, el enfoque de métodos mixtos ofrece una comprensión más integral del problema, ya que la combinación de datos cuantitativos con análisis cualitativos profundos no solo potencia la validez de los hallazgos, sino que también enriquece su interpretación, mejorando con ello la pertinencia y aplicabilidad de las estrategias resultantes.

De acuerdo con Bagur-Pons et al. (2021), la integración adecuada de métodos cualitativos y cuantitativos permite una comprensión más rica de fenómenos complejos, dotando a la investigación de la flexibilidad necesaria para ajustarse a las dinámicas cambiantes del entorno (Bagur Pons et al., 2021) . Esta mayor amplitud analítica contribuye a que el modelo de machine learning propuesto, dirigido a predecir casos de violencia de género, no se limite a una perspectiva meramente numérica.

Por el contrario, la incorporación de variables y contextos emergentes desde la óptica cualitativa facilita la adaptación del modelo a contextos específicos, mejorando su aplicabilidad práctica, su capacidad de transferencia a diferentes entornos regionales y su aceptación por parte de los actores involucrados.

Por otro lado, la elección de métodos mixtos responde a la necesidad de superar las limitaciones de una aproximación exclusivamente cuantitativa o cualitativa. Una metodología puramente cuantitativa podría reducir la complejidad del fenómeno a

indicadores numéricos, sin capturar las sutilezas culturales o las circunstancias individuales que inciden en la ocurrencia de la violencia.

Asimismo, un enfoque exclusivamente cualitativo podría dificultar la generalización de las conclusiones y la escalabilidad de las soluciones tecnológicas. Al integrar ambas perspectivas, se minimizan estas carencias y se fortalece la aplicabilidad de los resultados a nuevos conjuntos de datos y situaciones emergentes. Esta estrategia se alinea con el análisis de Forni y De Grande (2020), quienes destacan la evolución de la triangulación y los métodos mixtos como práctica habitual, proporcionando un camino sólido para abordar problemáticas complejas desde una perspectiva multidimensional (Pablo Forni & Pablo De Grande, 2020).

De este modo, la combinación de metodologías cualitativas y cuantitativas no es solo una elección metodológica, sino también una respuesta estratégica a las demandas de un contexto complejo, buscando soluciones más robustas, adaptables y efectivas.

### **3.2 Alcance de la Investigación**

El alcance de esta investigación es explicativo-predictivo, lo cual implica dos niveles de aporte: por un lado, contribuir a la comprensión profunda de los factores asociados a la violencia de género en Ecuador (incluyendo aspectos socioeconómicos y culturales) y, por otro, generar un modelo de machine learning capaz de predecir casos potenciales de violencia. Así, la investigación no solo describe correlaciones, sino que busca identificar patrones y dinámicas contextuales que fundamenten la toma de decisiones preventivas.

Este abordaje se vincula directamente con los objetivos del trabajo. Por una parte, el componente explicativo responde a la necesidad de “realizar una revisión exhaustiva” y “diseñar una arquitectura de software eficiente y escalable”, puesto que comprender el fenómeno y sus factores subyacentes permite seleccionar variables y

técnicas de modelado adecuadas. Por otra parte, el aspecto predictivo refuerza la “implementación de un modelo de Machine Learning optimizado” y la “evaluación de su rendimiento”, asegurando que la solución propuesta no solo aporte conocimiento teórico, sino también relevancia práctica para la detección temprana de riesgos.

Los estudios previos respaldan la eficacia y pertinencia de este enfoque. Por ejemplo, González-Prieto et al. (2021) emplearon técnicas de machine learning para predecir la reincidencia en delitos de género, logrando mayor precisión que métodos convencionales y proporcionando herramientas valiosas para la toma de decisiones en políticas públicas (González-Prieto et al., 2021). Asimismo, Lima y de Oliveira (2024) utilizaron modelos LSTM para identificar patrones de riesgo en informes policiales previos a feminicidios en Brasil, demostrando la capacidad de estas técnicas para anticipar eventos violentos y contribuir a su prevención (Lima & de Oliveira, 2024).

En suma, el alcance explicativo y predictivo garantiza no solo la ampliación del conocimiento sobre las causas y dinámicas de la violencia de género, sino también la aplicación práctica de modelos predictivos en la toma de decisiones, optimizando las respuestas de los actores involucrados y avanzando así hacia el cumplimiento integral de los objetivos de la investigación.

### **3.3 Delimitación del Proyecto**

#### **3.3.1 Delimitación geográfica**

La presente investigación se centra en el contexto ecuatoriano, tomando como base el ENVIGMU Dataset, derivado de la Encuesta Nacional sobre Relaciones Familiares y Violencia de Género contra las Mujeres realizada por el INEC en 2019. Esta elección geográfica obedece a la necesidad de que los hallazgos reflejen patrones, factores culturales y dinámicas sociales específicas del país, ya que la violencia de

género no es un fenómeno homogéneo, sino que sus causas, manifestaciones y respuestas varían de acuerdo con el entorno sociocultural.

La pertinencia de focalizar en Ecuador radica también en la disponibilidad de datos nacionales confiables y en la posibilidad de orientar políticas públicas y estrategias preventivas ajustadas a la realidad local. De esta forma, los resultados obtenidos tendrán una aplicabilidad más directa y efectiva, brindando insumos útiles a instituciones gubernamentales, organizaciones no gubernamentales y entornos académicos para la implementación de medidas más acertadas y culturalmente pertinentes.

Adicionalmente, la inclusión del MeTwo Dataset (Rodriguez-Sanchez et al., 2020), proveniente de un estudio sobre clasificación automática del sexismo en redes sociales, se justifica por la creciente relevancia del discurso digital en el país y el uso extendido de plataformas como Twitter. Adaptar este conjunto de datos al contexto ecuatoriano permite analizar la expresión contemporánea de la violencia de género en el ámbito virtual, complementando la perspectiva obtenida del entorno físico y enriqueciendo la comprensión integral del fenómeno.

### **3.3.2 Delimitación temporal**

El proyecto comprende el periodo de mayo a diciembre del 2024 para el desarrollo de las actividades de análisis, modelado y evaluación. Esta delimitación temporal responde a la necesidad de un marco operativo claro para la implementación del modelo, la recolección, el preprocesamiento y el análisis de datos, así como la evaluación del rendimiento de las técnicas de machine learning propuestas.

En cuanto a las fuentes de datos, el ENVIGMU Dataset se centra en información recolectada durante el año 2019. Este marco temporal histórico es relevante, ya que permite identificar patrones previos y tendencias de largo plazo en la violencia de género

en Ecuador, ofreciendo así un punto de referencia para evaluar la evolución del fenómeno y su posible transformación en años recientes.

Por su parte, el MeTwo Dataset del 2020 incorpora datos extraídos de redes sociales en un contexto relativamente actual, reflejando las dinámicas emergentes y el lenguaje utilizado en entornos digitales. Esto resulta pertinente, dado que la comprensión y predicción de la violencia de género no solo deben anclarse en la realidad histórica, sino también en los discursos contemporáneos que influyen en las actitudes y comportamientos de la sociedad. De esta manera, el contraste entre datos históricos (2019) y datos más recientes (2020), junto con el periodo operativo del proyecto en 2024, proporciona un panorama temporal equilibrado y actual, garantizando que las conclusiones no solo sean contextualizadas geográfica y culturalmente, sino también oportunas y pertinentes a la realidad ecuatoriana.

### **3.3.3 Población y muestra**

Desde el punto de vista de la población y la muestra, el ENVIGMU Dataset se delimita a variables relacionadas con distintos tipos de violencia (física, psicológica, sexual, económica) y características demográficas (edad, estado civil, nivel educativo). Estas variables son seleccionadas específicamente para construir modelos predictivos que identifiquen factores de riesgo asociados con la violencia de género en Ecuador. En paralelo, el MeTwo Dataset incluye datos etiquetados en tres categorías (sexista, no sexista, dudoso), lo que facilita la identificación de patrones léxicos y contextuales en el discurso digital (Rodríguez-Sánchez et al., 2020).

### **3.3.4 Sobre los datasets**

**ENVIGMU Dataset:**

Este dataset contiene información recolectada en Ecuador en 2019 a través de la Encuesta Nacional sobre Relaciones Familiares y Violencia de Género contra las Mujeres (ENVIGMU) del INEC.

Se delimita a variables relacionadas con distintos tipos de violencia (física, psicológica, sexual, económica) y características demográficas (edad, estado civil, nivel educativo), que son relevantes para construir modelos predictivos y entender los factores de riesgo.

#### **MeTwo Dataset:**

Datos extraídos de Twitter en español, etiquetados en tres categorías (sexista, no sexista, dudoso) para analizar y predecir patrones de lenguaje sexista.

El análisis se limita a la identificación de patrones léxicos y contextuales, aplicando procesamiento de lenguaje natural (NLP) para crear modelos de clasificación multiclase en un entorno de redes sociales.

### **3.4 Métodos Empleados**

El método empírico es un enfoque de investigación que se fundamenta en la observación meticulosa y la experiencia directa para adquirir conocimiento sobre la realidad. Este método se centra en la recolección sistemática de datos a través de los sentidos y la experimentación controlada, permitiendo la formulación y verificación rigurosa de hipótesis (Lifeder, 2022).

Mediante la observación detallada, los investigadores examinan fenómenos en su entorno natural, registrando minuciosamente las variables relevantes. La experiencia directa implica la interacción práctica con el objeto de estudio, proporcionando una comprensión profunda de sus características y comportamientos.

La experimentación controlada permite manipular variables específicas en condiciones predeterminadas para observar los efectos resultantes, estableciendo relaciones causales y validando teorías propuestas. La recopilación sistemática de datos asegura que la información obtenida sea precisa y confiable, facilitando análisis cuantitativos y cualitativos que sustentan conclusiones sólidas.

Dentro de este marco, la revisión de la literatura y la entrevista se erigen como herramientas esenciales para la obtención y análisis de información.

### **3.4.1 Revisión Literaria**

Una revisión de la literatura es una investigación que incluye procedimientos de selección de la base de la evidencia y de extracción de datos, caracterizándose por su transparencia y trazabilidad. Este proceso permite al investigador situar su trabajo en el contexto del conocimiento existente y detectar áreas que requieren mayor exploración (Codina, Lluís & Lopezosa, Carlos, 2022).

Una revisión de la literatura es una investigación que incluye procedimientos de selección de la base de la evidencia y de extracción de datos, caracterizándose por su transparencia y trazabilidad. Este proceso permite al investigador situar su trabajo en el contexto del conocimiento existente y detectar áreas que requieren mayor exploración (Codina, 2021). En el caso de esta investigación, la revisión literaria se utilizó como un método esencial para recopilar, analizar y sintetizar información relevante sobre la violencia de género y la aplicación de machine learning en su prevención.

La importancia de la revisión de la literatura radica en su capacidad para proporcionar un marco teórico sólido que respalde los objetivos del estudio. Este enfoque no solo permite identificar las tendencias actuales en la investigación, sino también establecer las bases para justificar la necesidad de esta propuesta en el contexto ecuatoriano. Además, ayuda a identificar vacíos en la literatura existente, como



la falta de estudios que combinen herramientas tecnológicas avanzadas con la realidad social de Ecuador, lo que refuerza la pertinencia de esta investigación.

Un aspecto crucial de la revisión literaria es la selección cuidadosa de fuentes confiables y relevantes. En esta investigación, se priorizó el análisis de estudios publicados a partir de 2019, lo que garantizó que las perspectivas y metodologías analizadas estuvieran actualizadas y alineadas con las necesidades contemporáneas. Este proceso incluyó la revisión de artículos científicos, reportes técnicos y documentos legales relacionados con la violencia de género.

Además, la revisión de la literatura proporciona un entendimiento integral de cómo tecnologías como el machine learning han sido aplicadas en otros contextos para prevenir la violencia de género.

La revisión de la literatura no solo actúa como un medio para recopilar información relevante, sino que también guía el desarrollo del proyecto al identificar enfoques innovadores, resaltar vacíos en la investigación y proporcionar un marco teórico que refuerza la importancia del estudio. En este sentido, se constituye como un pilar fundamental para garantizar la relevancia y solidez del trabajo investigativo.

### **3.4.2 Entrevista**

La entrevista cualitativa, entendida como un intercambio verbal entre entrevistador y entrevistado, constituye una herramienta fundamental para la recolección de información en investigaciones sociales. Su flexibilidad permite adaptar las preguntas, el lenguaje y el ritmo al contexto y las características del participante, facilitando la obtención de datos ricos y detallados sobre sus experiencias, opiniones y perspectivas (Ana Angarita Hurtado, 2024)

Además, la entrevista cualitativa se presenta en diferentes formatos, como las estructuradas, semiestructuradas y abiertas, lo que brinda al investigador la posibilidad de elegir el enfoque que mejor se ajuste a sus objetivos y a las dinámicas del estudio

Esta técnica, por su capacidad para captar significados en contextos específicos, resulta especialmente relevante en investigaciones como la presente, donde la comprensión profunda de las dinámicas sociales relacionadas con la violencia de género es esencial para el análisis y desarrollo de soluciones.

La interacción directa permite al investigador explorar áreas sensibles y obtener información significativa, convirtiéndose en una fuente invaluable para complementar los datos cuantitativos y literarios existentes.

En el contexto de esta investigación, las entrevistas fueron diseñadas para explorar en profundidad las perspectivas de expertos en psicología y análisis de datos, quienes aportaron conocimientos clave sobre factores sociales, psicológicos y tecnológicos asociados a la violencia de género. Este enfoque cualitativo permitió no solo obtener información detallada, sino también contextualizar el fenómeno estudiado desde diversas disciplinas, integrando las dimensiones humanas y técnicas del problema. Por ejemplo, se formularon preguntas que exploraban tanto los factores psicológicos que contribuyen a la violencia de género como las posibilidades del uso de machine learning en la identificación de patrones de riesgo.

La estructura de las entrevistas, semiestructuradas en su mayoría, permitió una flexibilidad que facilitó profundizar en temas emergentes según las respuestas de los entrevistados. Este diseño permitió capturar aspectos esenciales relacionados con la implementación de tecnologías predictivas, el impacto psicológico en las víctimas y la validación de datos para modelos de inteligencia artificial.

Así, las entrevistas complementaron los datos obtenidos a través de otros métodos, proporcionando un marco robusto para interpretar y aplicar los hallazgos en un contexto ecuatoriano.

### **3.5 Procesamiento y análisis de la Información**

En esta investigación, el procesamiento y análisis de la información se realizó empleando una combinación de métodos cualitativos y cuantitativos, integrados para garantizar una interpretación robusta de los datos recolectados. Inicialmente, los datos obtenidos de las entrevistas fueron transcritos y procesados utilizando técnicas de codificación cualitativa, lo que permitió identificar temas y patrones clave relacionados con la violencia de género y el uso de machine learning en su prevención.

Por otro lado, los datos cuantitativos derivados de encuestas o bases existentes fueron analizados mediante técnicas estadísticas y algoritmos de aprendizaje automático. Esto incluyó la normalización de datos, tratamiento de valores faltantes y la implementación de métricas como TF-IDF para el análisis de textos.

Los modelos predictivos fueron entrenados utilizando bibliotecas como Scikit-learn y TensorFlow, priorizando algoritmos que optimizaran la detección de patrones asociados a la violencia de género en el contexto ecuatoriano. Este enfoque dual aseguró que los resultados no solo fueran precisos, sino también contextualizados dentro de las dinámicas sociales y tecnológicas relevantes.

### **3.6 Elementos Metodológicos específicos para TI**

#### **3.6.1 CRISP-DM aplicado al Dataset ENVIGMU**

##### **Fase 1: Entendimiento del Negocio**

El objetivo principal es analizar factores de riesgo asociados a la violencia de género en Ecuador, considerando variables socioeconómicas y culturales. Este enfoque responde a la necesidad de las instituciones públicas en el sector de la salud, como la

psicología y ONG de contar con herramientas que prioricen recursos preventivos. La relevancia de este marco conceptual fue corroborada mediante consultas con la experta Psico. Diana Ramírez, cuya orientación permitió focalizar en variables con influencia directa en la identificación temprana de casos.

## **Fase 2: Entendimiento de los Datos**

El dataset ENVIGMU proviene de la Encuesta Nacional sobre Relaciones Familiares y Violencia de Género contra las Mujeres del INEC (2019). Previo al modelado, se examinó la calidad y estructura de los datos, identificando valores faltantes, posibles sesgos en la distribución de variables y presencia de outliers. La validación de la pertinencia de variables (como nivel educativo, estado civil o percepción de violencia) se efectuó combinando criterios estadísticos (frecuencia, correlaciones) y el asesoramiento experto. Este proceso permitió asegurar la relevancia de las características empleadas.

## **Fase 3: Preparación de los Datos**

Se emplearon herramientas ampliamente reconocidas en Python, dentro de entornos Jupyter Notebook. Para manipulación de datos se utilizaron pandas y numpy, mientras que la detección y corrección de datos faltantes se abordó con imputaciones simples (media, mediana) basadas en análisis estadístico. Se eliminó información irrelevante o duplicada, y se codificaron variables categóricas con LabelEncoder de sklearn.preprocessing. El desbalance de clases —por ejemplo, mayor cantidad de casos “no violentos” que “violentos”— se atendió mediante técnicas de sobremuestreo o submuestreo para mejorar la capacidad de detección de casos minoritarios. La calidad tras la limpieza se aseguró midiendo la reducción del porcentaje de datos faltantes, el mantenimiento de la consistencia lógica entre variables y la eliminación de

outliers extremos. Estas revisiones incrementaron la confiabilidad del dataset antes del modelado.

#### **Fase 4: Modelado**

Se consideraron modelos como árboles de decisión, Random Forest y XGBoost. Estas elecciones se justifican por su alto desempeño reportado en la literatura, su robustez frente a datos desbalanceados y su capacidad para capturar relaciones no lineales. El ajuste de hiperparámetros se realizó mediante Grid Search sobre el conjunto de entrenamiento y validación cruzada (k-fold cross-validation), garantizando que los resultados no se debieran al azar. El uso de scikit-learn (`sklearn.ensemble.RandomForestClassifier`, `sklearn.model_selection.GridSearchCV`) permitió estandarizar la búsqueda de hiperparámetros y registrar sistemáticamente los resultados, facilitando comparaciones objetivas entre diferentes configuraciones.

#### **Fase 5: Evaluación**

La evaluación se realizó con métricas como precisión, recall, F1-score y AUC-ROC, poniendo énfasis en minimizar falsos negativos por su implicancia práctica. Se empleó validación cruzada para asegurar que el desempeño no fuese resultado de una sola partición de datos. Además, se dividió el dataset en entrenamiento y prueba para medir la capacidad de generalización del modelo. De esta manera se minimizó el riesgo de sobreajuste, garantizando que el modelo refleje un rendimiento estable y confiable.

#### **Fase 6: Implementación y Monitoreo**

Si bien la implementación completa no es parte del alcance inmediato, se propone una aplicación web básica con Flask para la interacción con el modelo. Esta interfaz podría conectarse con una base de datos para almacenar predicciones (de manera próxima de otra versión), facilitando un monitoreo continuo del rendimiento. Se planifica la actualización periódica del modelo trimestralmente conforme surjan nuevos

datos que serán recogidos por el aplicativo web o cambien las condiciones socioeconómicas, asegurando que el modelo se mantenga relevante y útil a lo largo del tiempo.

### **3.6.2 CRISP-DM aplicado al Dataset MeTwo**

#### **Fase 1: Entendimiento del Negocio**

El dataset MeToo se orienta a la identificación de lenguaje sexista en redes sociales. Su utilidad radica en apoyar esfuerzos de monitoreo y prevención de discurso de odio digital, beneficiando a organizaciones de derechos humanos e instituciones sociales que requieren herramientas precisas para intervenir en dinámicas comunicacionales dañinas.

#### **Fase 2: Entendimiento de los Datos**

El dataset MeTwo incluye textos etiquetados en español, provenientes de plataformas de redes sociales como Twitter. Durante esta fase, se analiza la calidad del texto, identificando problemas como ruido en los datos, presencia de caracteres especiales y desbalanceo en las etiquetas. Se realiza un análisis exploratorio que incluye la identificación de palabras y frases más frecuentes en cada categoría, proporcionando un entendimiento preliminar de las características léxicas asociadas con el discurso sexista. Estos hallazgos guían la preparación del texto para el modelado.

#### **Fase 3: Preparación de los Datos**

Se emplearon técnicas de Procesamiento de Lenguaje Natural (NLP) mediante librerías como nltk para eliminar stopwords y normalizar el texto. Para representar los documentos se utilizó TF-IDF (`sklearn.feature_extraction.text.TfidfVectorizer`), lo que permitió capturar relevancia relativa de términos. La subrepresentación de ciertas clases se atendió con `imblearn.under_sampling.RandomUnderSampler`. Estas acciones

garantizaron datos equilibrados y representativos, mejorando la validez del conjunto de entrenamiento.

#### **Fase 4: Modelado**

Se probaron algoritmos como Naive Bayes, SVM y redes neuronales, atendiendo el alto volumen y diversidad del texto. SVM (con `sklearn.svm.SVC`) fue elegida por su buen desempeño en problemas de clasificación textual, mientras que Naive Bayes (`sklearn.naive_bayes.GaussianNB`) proporcionó un punto de comparación inicial por su simplicidad y eficiencia. La selección final se basó en métricas obtenidas mediante validación cruzada y Grid Search de hiperparámetros, registrando sistemáticamente los resultados.

#### **Fase 5: Evaluación**

Además de precisión, recall y F1-score, se utilizó AUC-ROC y análisis de la curva ROC para evaluar la capacidad discriminante del modelo. La validación cruzada k-fold permitió asegurar que el rendimiento no dependiera de una sola partición del dataset. La matriz de confusión brindó información sobre los tipos de errores cometidos, facilitando la identificación de ajustes necesarios en el preprocesamiento o los hiperparámetros.

#### **Fase 6: Implementación y Monitoreo**

Se propone una aplicación web basada en Flask y HTML/CSS/Javascript para interactuar con el modelo y evaluar casos en tiempo real. El registro de predicciones y métricas en bases de datos (SQLite en una versión de mejora) permitirá monitorear el rendimiento del modelo a lo largo del tiempo. Asimismo, se planea una actualización periódica del modelo con nuevos datos, a partir de los tweets u oraciones recolectadas, manteniendo su pertinencia ante cambios en el discurso digital y garantizando un control sostenido sobre el sesgo y la calidad de la información procesada.

## **4 Análisis De Resultados De La Investigación**

### **4.1 Aspectos Generales de los Datasets y Requisitos del Sistema**

La presente investigación utiliza dos conjuntos de datos principales: el ENVIGMU Dataset, que contiene información demográfica y sobre violencia de género en Ecuador, y el MeTwo Dataset, que recopila tweets en español clasificados en categorías de lenguaje sexista. Ambos datasets presentan retos técnicos significativos debido al volumen, la diversidad y la sensibilidad de la información procesada. Para garantizar un análisis eficiente y preciso, se han definido los siguientes requisitos generales del sistema y el entorno de desarrollo.

En términos de hardware, el sistema debe contar con computadoras equipadas con al menos 16 GB de RAM, procesadores de alto rendimiento de múltiples núcleos que operen a más de 2.7 GHz y almacenamiento SSD de al menos 256 GB. Estas especificaciones permiten manejar los grandes volúmenes de datos, realizar transformaciones complejas y entrenar modelos de machine learning con eficiencia.

El software utilizado incluye Windows 11 como sistema operativo base y Python como lenguaje de programación principal, ejecutado en Jupyter Notebook dentro de Anaconda Navigator. Este entorno permite integrar múltiples librerías especializadas, como pandas, scikit-learn, nltk para procesamiento de lenguaje natural (NLP) y matplotlib para visualización, facilitando el análisis y modelado iterativo de los datos.

En cuanto a las tecnologías y herramientas, Jupyter Notebook y Anaconda Navigator son los componentes centrales del desarrollo. Estos entornos ofrecen flexibilidad, gestión eficiente de paquetes y entornos virtuales, así como una interfaz amigable para la experimentación, visualización y ajuste constante de modelos. Esto resulta esencial para procesar datos estructurados (ENVIGMU) y textuales (MeTwo), permitiendo explorar y transformar los datos, así como diseñar y evaluar modelos de clasificación adaptados a las características de cada dataset.



Finalmente, el proceso de implementación se realiza en entornos controlados para garantizar la seguridad y precisión de los modelos antes de cualquier despliegue. Los modelos se entrenan y validan en Jupyter Notebook, asegurando un control detallado de todas las etapas del análisis, desde la carga de datos hasta la interpretación de métricas. Aunque la implementación se limita a pruebas internas, el diseño considera la integración en un aplicativo web en Flask para demostrar la aplicabilidad práctica del modelo predictivo.

Esta descripción general del ambiente técnico y los requisitos refleja las necesidades de los datasets y sienta las bases para un análisis robusto y una integración efectiva de las tecnologías en el marco de esta investigación.

## **4.2 ENVIGMU Dataset**

### **4.2.1 Entendimiento del Negocio**

El modelo diseñado para el dataset ENVIGMU tiene como objetivo principal identificar factores de riesgo asociados con la violencia de género en Ecuador. Este análisis busca reconocer patrones significativos vinculados a diversas manifestaciones de violencia, como la física, psicológica y económica. Para ello, se consideran determinantes clave como la edad, el estado civil y el nivel educativo, que permiten establecer perfiles de riesgo. Esta herramienta está orientada a satisfacer las necesidades de instituciones públicas y ONG, proporcionando capacidades predictivas que faciliten la asignación eficiente de recursos y la planificación de estrategias dirigidas a prevenir y mitigar la violencia de género.

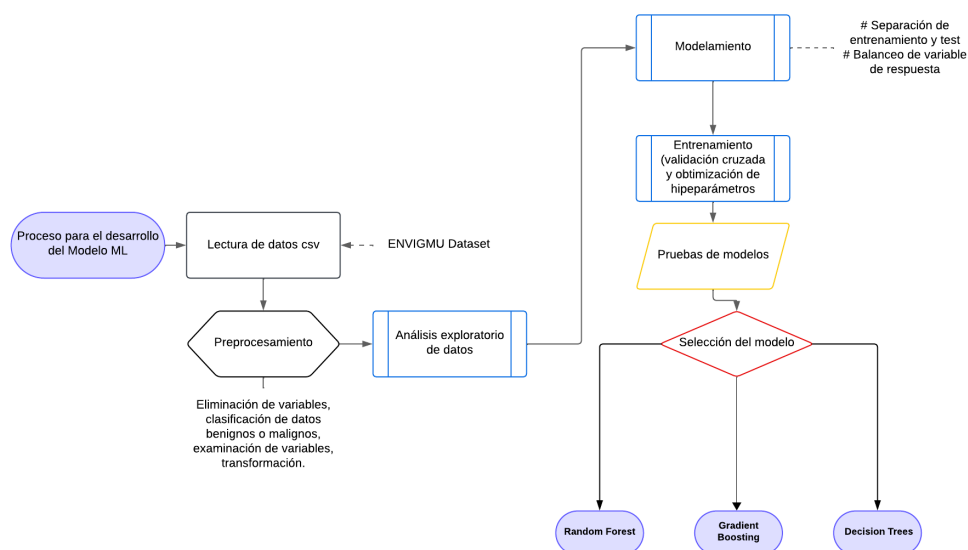


Figura 1: Proceso para el desarrollo del modelo ML Envigmu

#### 4.2.2 Entendimiento de los datos

Se presenta un conjunto de archivos relacionados con el proyecto ENVIGMU, que contiene datos sobre indicadores de violencia de género. Estos archivos incluyen bases de datos en formato CSV y documentación complementaria en formato ODS para facilitar la comprensión de las variables y metadatos. Entre los archivos en formato CSV, se encuentran: datos de mujeres casadas o en unión (201911\_EnvigmuBDD\_casadas\_unidas.csv), datos de mujeres separadas o viudas (201911\_EnvigmuBDD\_separadas\_viudas.csv), datos de mujeres solteras (201911\_EnvigmuBDD\_solteras.csv) y un archivo que agrupa indicadores generales de violencia (201911\_EnvigmuBDD\_indicadores\_violencia.csv).

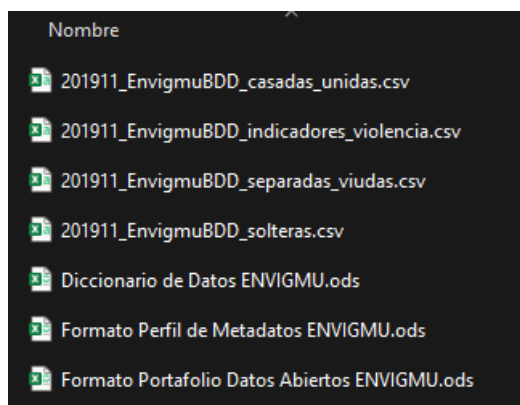


Figura 2: Subdatasets ENVIGMU

Se utiliza la biblioteca Pandas para cargar el archivo CSV llamado "Dataset\_Concatenado\_Limpio.csv" en un DataFrame denominado df. El argumento `low_memory=False` se utiliza para evitar que Pandas cargue el archivo en fragmentos, lo que puede ocurrir si hay muchas columnas con tipos de datos heterogéneos. Esto asegura que el archivo completo se cargue en memoria correctamente. El DataFrame resultante (df) contiene la información consolidada y limpia del dataset, lista para su exploración y análisis.

```
In [56]: import pandas as pd

# Cargar el archivo CSV
df = pd.read_csv("Dataset_Concatenado_Limpio.csv", low_memory=False)
df
```

Figura 3: Lectura del CSV

Se utiliza Pandas para cargar un archivo Excel llamado "preguntas\_por\_ambito.xlsx" en un DataFrame denominado df\_preguntas\_ambito. El argumento `engine="openpyxl"` se especifica para asegurar la compatibilidad con el formato XLSX. Una vez cargado, se utilizan las funciones `info()` y `head()` para inspeccionar la estructura del DataFrame:

- `info()` proporciona un resumen del DataFrame, incluyendo el número de filas, columnas, tipos de datos y valores nulos.

- `head()` muestra las primeras filas del DataFrame para una visualización inicial de los datos.

Este proceso confirma que los datos se cargaron correctamente y permite entender mejor su organización para los análisis posteriores.

```
In [57]: # Cargar el archivo de preguntas por ámbito
df_preguntas_ambito = pd.read_excel("preguntas_por_ambito.xlsx", engine="openpyxl")

# Confirmar la estructura
df_preguntas_ambito.info()
df_preguntas_ambito.head()
```

Figura 4: Leer preguntas por ámbito

El DataFrame cargado contiene dos columnas principales: "Pregunta" y "Ámbito". La columna "Pregunta" incluye textos descriptivos relacionados con situaciones o actividades, mientras que la columna "Ámbito" clasifica cada pregunta dentro de una categoría específica.

	Pregunta	Ámbito
0	Ámbito Educativo: Asistió a un centro educativo	Educativo
1	Ámbito Educativo: A lo largo de su vida ha asi...	Educativo
2	La insultaron, gritaron, ofendieron o humillar...	Educativo
3	¿Quién fue?	Educativo
4	¿Esto le ocurrió en:	Educativo

Figura 5: Preguntas y ámbito

Se realiza un proceso de normalización de texto tanto en los nombres de las columnas como en los valores de las preguntas dentro de los DataFrames para asegurar consistencia y evitar problemas de comparación debido a diferencias de formato.

1. En el **DataFrame principal**, los nombres de las columnas se convierten a minúsculas y se eliminan los espacios en blanco iniciales y finales mediante el método `str.strip()` seguido de `str.lower()`.

2. En el **archivo de preguntas por ámbito**, la columna Pregunta se normaliza de forma similar, asegurando que todo el texto sea en minúsculas y sin espacios innecesarios al inicio o al final.

Este proceso es esencial para unificar el formato de los datos, facilitando operaciones como uniones, comparaciones y análisis posteriores

```
In [58]: # Normalizar Los nombres de Las columnas en el DataFrame principal
df.columns = df.columns.str.strip().str.lower()

# Normalizar Los nombres de Las preguntas en el archivo de ámbitos
df_preguntas_ambito['Pregunta'] = df_preguntas_ambito['Pregunta'].str.strip().str.lower()
```

*Figura 6: Normalización de texto*

Se crea un diccionario llamado mapeo\_ambito para asociar cada pregunta con su respectivo ámbito. Esto se logra utilizando la función zip() para emparejar los valores de las columnas Pregunta y Ámbito del DataFrame df\_preguntas\_ambito, y luego transformándolos en un diccionario con dict().

Este diccionario permite acceder rápidamente al ámbito correspondiente de una pregunta específica, facilitando tareas como categorización, filtrado o análisis basado en los diferentes contextos definidos en el dataset.

```
In [59]: # Crear un diccionario de preguntas a ámbitos
mapeo_ambito = dict(zip(df_preguntas_ambito['Pregunta'], df_preguntas_ambito['Ámbito']))
```

*Figura 7: Creación de un diccionario*

Se define una función llamada asignar\_ambito para identificar el ámbito predominante en cada fila del DataFrame principal utilizando el diccionario mapeo\_ambito. La función recorre las preguntas en cada fila y, si una respuesta es positiva (valor igual a 1), agrega el ámbito correspondiente a una lista. Al final, asigna los ámbitos encontrados como texto separado por comas o "desconocido" si no se identifican ámbitos. Esta función se aplica a todas las filas del DataFrame, generando una nueva columna ámbito que facilita el análisis de los datos según su contexto.

```
In [60]: # Función para determinar el ámbito predominante en cada fila
def asignar_ambito(row):
    ambitos = []
    for pregunta, ambito in mapeo_ambito.items():
        if pregunta in row.index and row[pregunta] == 1: # Si la respuesta es positiva
            ambitos.append(ambito)
    return ', '.join(set(ambitos)) if ambitos else "desconocido"

# Aplicar la función al DataFrame principal
df['ambito'] = df.apply(asignar_ambito, axis=1)
```

Figura 8: Identificar el ámbito predominante

### 4.2.3 Preparación de los datos

Se calcula el porcentaje de valores faltantes en cada columna del DataFrame principal utilizando la fórmula  $(df.isnull().sum() / len(df)) * 100$ . Esto proporciona una visión clara de la calidad de los datos, indicando qué columnas tienen datos incompletos y en qué proporción. Esta información es clave para decidir las estrategias de limpieza, como la imputación o eliminación de columnas con un alto porcentaje de valores faltantes.

#### Identificación de Valores Faltantes

```
In [74]: print(df.isnull().sum() / len(df) * 100)
```

Figura 9: Identificar valores faltantes

Se realiza el manejo de valores faltantes en el DataFrame principal utilizando dos estrategias:

1. **Eliminación de columnas con más del 50% de valores faltantes:** Se filtran las columnas cuyo porcentaje de valores nulos es menor al 50%, utilizando `df.loc[:, df.isnull().mean() < 0.5]`. Esto garantiza que se conserven solo las columnas con datos mayoritariamente completos.
2. **Imputación de valores faltantes:** Para las columnas numéricas (tipos float e int), se imputan los valores faltantes con la mediana de cada columna,

empleando el método `fillna()` con la opción `inplace=True`. Esto ayuda a preservar la distribución de los datos sin afectar significativamente las métricas.

## Manejo de Valores Faltantes

```
In [78]: # Eliminar columnas con más del 50% de valores faltantes
df = df.loc[:, df.isnull().mean() < 0.5]

# Imputar valores faltantes (ejemplo: con la mediana)
for column in df.select_dtypes(include=['float', 'int']):
    df[column].fillna(df[column].median(), inplace=True)
```

Figura 10: Manejo de valores faltantes

Se realiza un manejo de valores faltantes en el DataFrame. Primero, se identifica el porcentaje de valores nulos por columna y se eliminan aquellas con más del 50% de datos faltantes, dejando 95 columnas útiles. Luego, para las columnas numéricas (`float64` e `int64`), los valores faltantes se imputan utilizando la mediana de cada columna. Este proceso asegura un dataset más limpio y preparado para el análisis posterior.

## Manejo de valores faltantes

```
: print(df.isnull().mean() * 100)
persona 0.000000
la ignoraron o la hicieron sentir inferior por ser mujer? 5.670792
¿resultado de ese(esos) embarazo(s): cuántos hijas e hijos nacieron vivos? 0.000000
factor de expansión de la mujer 0.000000
¿resultado de ese(esos) embarazo(s): cuántos hijas e hijos nacieron muertos? 0.000000
...
le hicieron insinuaciones sexuales a cambio de un ascenso en trabajo 17.105340
la ignoraron o la hicieron sentir inferior por ser mujer 17.105340
le hicieron algún comentario o insinuación sexual que la hizo sentir ofendida o incomoda 22.468189
grupo 0.000000
ámbito 0.000000
Length: 95, dtype: float64

: df = df.loc[:, df.isnull().mean() < 0.5]

: df.shape

: (17211, 95)

: # Imputar valores faltantes para columnas numéricas con la mediana
for col in df.select_dtypes(include=['float64', 'int64']):
    df[col].fillna(df[col].median(), inplace=True)
```

Figura 11: Imputación de la mediana

Se utiliza `LabelEncoder` para convertir columnas categóricas en valores numéricos. Primero, se verifican y rellenan valores nulos con "Desconocido" en caso de ser necesario. Luego, cada columna categórica se transforma en etiquetas numéricas

con `fit_transform()`, asegurando que los datos estén en formato de cadena. Cualquier error durante el proceso se captura y se informa, garantizando que las columnas categóricas estén listas para su uso en modelos de Machine Learning.

```

from sklearn.preprocessing import LabelEncoder

labelencoder = LabelEncoder()

for col in categorical_columns:
    try:
        # Verificar valores nulos y rellenar si es necesario
        if df[col].isnull().sum() > 0:
            df[col].fillna('Desconocido', inplace=True)

        # Codificar columna categórica
        df[col] = labelencoder.fit_transform(df[col].astype(str))
    except Exception as e:
        print(f"Error en la columna '{col}': {e}")

```

Figura 12: LabelEncoder convertir columnas categóricas

Se seleccionan muestras balanceadas de la columna grupo del DataFrame. Primero, se identifican los valores únicos de la columna para separar los datos por grupo. Luego, para cada grupo, se toma una muestra de 800 registros de forma aleatoria y sin reemplazo (`sample()`), garantizando la reproducibilidad con `random_state=42`. Las muestras seleccionadas de cada grupo se concatenan en un nuevo DataFrame llamado **data**, asegurando un conjunto balanceado para análisis o modelado posterior.

```

# Verificar los grupos únicos en la columna 'grupo'
unique_groups = df['grupo'].unique()

# Inicializar un DataFrame vacío para almacenar las muestras
data = pd.DataFrame()

for group in unique_groups:
    group_data = df[df['grupo'] == group]
    sampled_group = group_data.sample(n=800, random_state=42, replace=False)
    data = pd.concat([data, sampled_group], axis=0)

```

Figura 13: Muestras balanceadas

Se prepara el conjunto de datos separando las variables predictoras y los objetivos. Las variables independientes (X) se obtienen eliminando las columnas grupo y ámbito del DataFrame principal, ya que estas son las variables objetivo. La columna grupo se almacena como `y_grupo` y representa el primer objetivo, mientras que la



columna ámbito se almacena como `y_ámbito` para el segundo objetivo. Esta separación facilita la construcción de modelos específicos para predecir cada objetivo.

### Preparar los datos

```
# Variables independientes (X) y objetivos (y_grupo y y_ámbito)
X = data.drop(['grupo', 'ámbito'], axis=1) # Variables predictoras
y_grupo = data['grupo'] # Objetivo 1: grupo
y_ámbito = data['ámbito'] # Objetivo 2: ámbito
```

Figura 14: Preparación de los datos

Se utiliza la función `train_test_split` de `sklearn.model_selection` para dividir los datos en conjuntos de entrenamiento y prueba para los dos objetivos del análisis. Para el objetivo grupo, las variables predictoras (X) y la variable objetivo (`y_grupo`) se separan asignando un 70% de los datos al entrenamiento y un 30% a la prueba. De manera similar, para el objetivo ámbito, se realiza la misma división utilizando las variables predictoras (X) y la variable objetivo (`y_ámbito`). Ambas divisiones comparten el mismo valor de `random_state=42` para asegurar la reproducibilidad de los resultados. Esto permite entrenar y evaluar modelos para ambos objetivos de manera eficiente y separada.

```
from sklearn.model_selection import train_test_split

# División para `grupo`
X_train_grupo, X_test_grupo, y_train_grupo, y_test_grupo = train_test_split(X, y_grupo, test_size=0.3, random_state=42)

# División para `ámbito`
X_train_ámbito, X_test_ámbito, y_train_ámbito, y_test_ámbito = train_test_split(X, y_ámbito, test_size=0.3, random_state=42)
```

Figura 15: Separar data de entrenamiento

#### 4.2.4 Modelado

Se implementa el modelo Random Forest para predecir los objetivos grupo y ámbito de manera separada. Para el objetivo grupo, se crea una instancia de `RandomForestClassifier` con `random_state=42` para garantizar reproducibilidad y se entrena el modelo con los datos de entrenamiento (`X_train_grupo` y `y_train_grupo`). De forma similar, para el objetivo ámbito, se utiliza otra instancia del modelo,

entrenándolo con los datos correspondientes ( $X_{\text{train\_ámbito}}$  y  $y_{\text{train\_ámbito}}$ ). Este enfoque permite utilizar la capacidad de los Random Forest para manejar conjuntos de datos con múltiples clases y realizar predicciones robustas para ambos objetivos.

## Random Forest

### Modelo para predecir grupo

```
from sklearn.ensemble import RandomForestClassifier

# Modelo para grupo
model_grupo = RandomForestClassifier(random_state=42)
model_grupo.fit(X_train_grupo, y_train_grupo)
```

```
RandomForestClassifier
RandomForestClassifier(random_state=42)
```

### Modelo para predecir ámbito

```
# Modelo para ámbito
model_ambito = RandomForestClassifier(random_state=42)
model_ambito.fit(X_train_ambito, y_train_ambito)
```

```
RandomForestClassifier
RandomForestClassifier(random_state=42)
```

Figura 16: RandomForest

## 4.2.5 Evaluación

Se evalúa el modelo Random Forest para predecir el objetivo grupo utilizando el conjunto de prueba. Las predicciones ( $y_{\text{pred\_grupo}}$ ) se generan a partir de los datos de prueba ( $X_{\text{test\_grupo}}$ ) y se analizan mediante un reporte de clasificación y una matriz de confusión. El reporte de clasificación proporciona métricas detalladas para cada clase, como precisión, recall y F1-Score. El modelo alcanza una precisión promedio (macro avg) de 0.83 y una exactitud general (accuracy) del 83%, lo que indica un desempeño sólido. La matriz de confusión muestra la distribución de predicciones correctas y errores, con valores en la diagonal representando las clasificaciones correctas.

```
In [309... from sklearn.metrics import classification_report, confusion_matrix

# Predicciones para grupo
y_pred_grupo = model_grupo.predict(X_test_grupo)

# Evaluación
print("Evaluación para grupo:")
print(classification_report(y_test_grupo, y_pred_grupo))
print(confusion_matrix(y_test_grupo, y_pred_grupo))
```

Evaluación para grupo:				
	precision	recall	f1-score	support
0	0.83	0.85	0.84	252
1	0.79	0.82	0.81	234
2	0.86	0.81	0.83	234
accuracy			0.83	720
macro avg	0.83	0.83	0.83	720
weighted avg	0.83	0.83	0.83	720

```
[[213  21  18]
 [ 27 193  14]
 [ 16  29 189]]
```

Figura 17: Evaluación para Grupo

Este código evalúa el modelo para predecir el "ámbito" utilizando métricas de clasificación y una matriz de confusión. Primero, genera las predicciones para el conjunto de prueba ( $X_{\text{test\_ámbito}}$ ) y las compara con las etiquetas reales ( $y_{\text{test\_ámbito}}$ ). Luego, utiliza un informe de clasificación que incluye precisión, recall, y F1-Score para cada clase, así como promedios macro y ponderados, mostrando un desempeño general muy alto del modelo con una exactitud del 97%. La matriz de confusión permite observar los errores específicos en la clasificación, mostrando que la mayoría de las predicciones son correctas (valores en la diagonal), con pocos errores entre clases. En particular, el modelo tiene un desempeño casi perfecto en las clases "Educativo", "Laboral" y "Social", mientras que la clase "Familiar" tiene un recall ligeramente menor (0.97) debido a algunos errores. Esto sugiere que el modelo es robusto, pero un análisis más detallado podría centrarse en los errores para mejorar aún más su rendimiento.

```
In [312... # Predicciones para ámbito
y_pred_ámbito = model_ámbito.predict(X_test_ámbito)

# Evaluación
print("Evaluación para ámbito:")
print(classification_report(y_test_ámbito, y_pred_ámbito))
print(confusion_matrix(y_test_ámbito, y_pred_ámbito))
```

Evaluación para ámbito:

	precision	recall	f1-score	support
Educativo	1.00	0.99	0.99	154
Familiar	0.93	0.97	0.95	130
Gineco-Obstétrica	0.95	0.94	0.94	159
Laboral	0.97	0.97	0.97	147
Social	1.00	1.00	1.00	130
accuracy			0.97	720
macro avg	0.97	0.97	0.97	720
weighted avg	0.97	0.97	0.97	720

```
[[152  2  0  0  0]
 [  0 126  3  1  0]
 [  0  7 149  3  0]
 [  0  0  5 142  0]
 [  0  0  0  0 130]]
```

Figura 18; Evaluación para Ámbito

#### 4.2.6 Implementación

La implementación de esta aplicación web con Flask permite que los usuarios interactúen con un modelo de Machine Learning para obtener predicciones personalizadas de manera sencilla. La aplicación se compone de un frontend, un backend, y un sistema de visualización que trabaja en conjunto para procesar las entradas del usuario y devolver resultados en un formato amigable.

El frontend, diseñado con HTML, CSS y Bootstrap, presenta un formulario responsivo donde los usuarios ingresan datos como edad, nivel educativo, ingreso mensual y estado civil. Esta información se envía al servidor mediante el método POST al hacer clic en "Obtener Predicción". El diseño es limpio, intuitivo y compatible con dispositivos móviles, facilitando su uso.

Figura 19: Formulario del aplicativo web

El backend, desarrollado con Flask, recibe los datos del formulario y los convierte en un formato que el modelo de Machine Learning, previamente entrenado y cargado con Joblib, puede procesar. El modelo realiza una predicción sobre el ámbito más probable y calcula las probabilidades para todas las categorías. Estos resultados se preparan para ser enviados al frontend.

Para la visualización, Flask genera una página de resultados que muestra el ámbito predicho y las probabilidades de cada clase en forma de lista. Además, utiliza Matplotlib para crear un gráfico de barras dinámico que ilustra la distribución de probabilidades, ayudando a los usuarios a comprender mejor los resultados.

## Resultados de la Predicción

**Ámbito Predicho: Laboral**

Detalles de las probabilidades por ámbito:

- Educativo: 5%
- Familiar: 10%
- Gineco-Obstétrica: 2%
- Laboral: 75%
- Social: 8%

Figura 20: Resultados de la Predicción

#### **4.2.7 Análisis Crítico**

En suma, los resultados con el ENVIGMU Dataset muestran un desempeño técnico sólido, alineado con los objetivos de desarrollar un modelo útil, replicable y orientado a la prevención de la violencia de género. El modelo alcanzó métricas de evaluación prometedoras, especialmente en la clasificación de ámbitos, lo que sugiere su potencial utilidad para las instituciones que buscan optimizar la toma de decisiones.

No obstante, la interpretación crítica de estas cifras indica que existe margen para mejorar la sensibilidad en ciertas clases, profundizar en el impacto de los errores y trabajar con datos más ricos y representativos. Estas reflexiones resultan esenciales para guiar futuras iteraciones, incorporando nuevos conjuntos de datos y técnicas de ajuste que permitan incrementar la fiabilidad del modelo en contextos reales y dinámicos.

### **4.3 MeTwo Dataset**

#### **4.3.1 Entendimiento del Negocio**

En este proyecto, el objetivo es predecir si un texto clasificado puede ser etiquetado como "sexist" o "not sexist". Esto permite detectar tendencias en la violencia de género a partir de datos textuales. El modelo busca maximizar el recall para minimizar los falsos negativos, lo cual es crucial en problemas sociales sensibles.

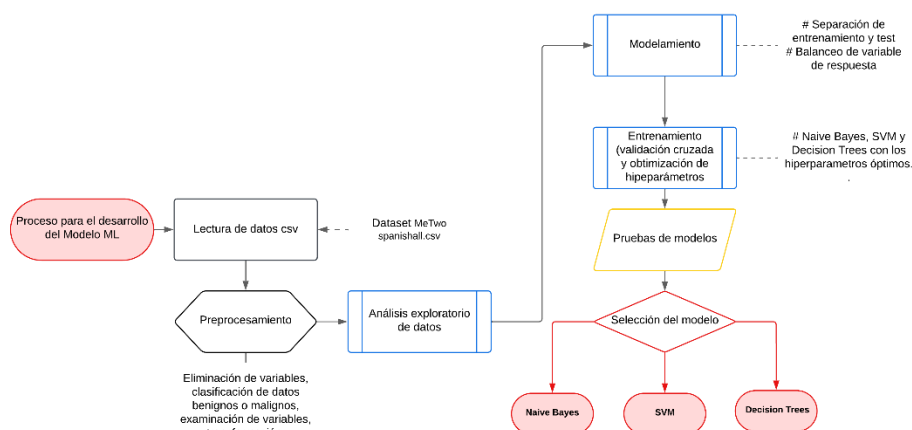


Figura 21: Proceso para desarrollo de ML MeTwo

### 4.3.2 Entendimiento de los datos

Se importa dos bibliotecas esenciales para la visualización de datos en Python. Primero, `matplotlib.pyplot` (alias `plt`), que permite crear gráficos básicos como líneas, barras, histogramas, y dispersión, funcionando como una herramienta flexible para personalizar visualizaciones. Luego, `seaborn` (alias `sns`), una biblioteca basada en `matplotlib`, que simplifica la creación de gráficos estadísticos con estilos predeterminados más elegantes, como mapas de calor, gráficos de violín y gráficos de caja. Estas bibliotecas suelen usarse juntas para complementar sus funcionalidades y producir visualizaciones claras y estéticas en análisis de datos.

#### Leer dataset

```
[388]: import matplotlib.pyplot as plt
import seaborn as sns
```

Figura 22: Primerías Librerías

Se utiliza la biblioteca Pandas para leer un archivo CSV llamado `spanish_all.csv` y cargar su contenido en un `DataFrame` denominado `df`. Este `DataFrame` es una estructura tabular que permite analizar y manipular los datos de manera eficiente. Al llamar a `df`, se visualiza el contenido del `DataFrame` en la salida del entorno de trabajo, mostrando las filas y columnas del archivo cargado.

```
[389]: import pandas as pd

df= pd.read_csv('spanish_all.csv')
df
```

Figura 23: Lectura del CSV

	text	label_sexist
0	Mi mamá: Si te llegas a ir del país, vas a sab...	not sexist
1	@BraulioC Jaja. Ayay. Cuáles son los atributos...	not sexist
2	Se me ha caído una taza de Superman que le reg...	not sexist
3	Por si alguien no se ha enterado, Suso se ha p...	not sexist
4	Koalita tenía a su amiga Miriam ayudándole en ...	not sexist
...	...	...
2288	Yo no puedo darte luz todos los días, pero si ...	not sexist
2289	Que bien! Aunque digan que las mujeres no debe...	not sexist
2290	@AriOrsingher Y misoginia las pelotas no quier...	not sexist
2291	"Imaginen el tipo de sociedad mojigata y castr...	not sexist
2292	@SenadoraBlas por favor pase a la historia com...	not sexist

2293 rows x 2 columns

Figura 24: Contenido del Dataset

Se realiza un análisis de la distribución de clases en la columna `label_sexist` del DataFrame. Primero, se calcula la cantidad de instancias por clase (`not sexist` y `sexist`) con `value_counts()` y se genera un gráfico de barras con `plot(kind='bar')`. Finalmente, se utiliza `plt.show()` para mostrar el gráfico, que permite visualizar el balance o desbalance de las clases en el conjunto de datos.

```
In [390]: df['label_sexist'].value_counts().plot(kind='bar', color=['lightblue', 'orange'])
plt.title('Distribución de Clases')
plt.xlabel('Clase')
plt.ylabel('Número de Instancias')
plt.show()
```



Figura 25: Gráfico de barras: Distribución de clases en el dataset



Se identifica la cantidad de valores nulos en cada columna del DataFrame utilizando `df.isnull().sum()`. Esto genera una tabla que muestra el número total de valores faltantes por columna. En este caso, la columna `text` tiene 2 valores nulos, mientras que `label_sexist` no tiene valores faltantes. Esto es útil para evaluar la calidad de los datos y planificar estrategias de limpieza.

### 4.3.3 Preparación de los datos

#### Identificar valores nulos

```
In [392...] valores_nulos = df.isnull().sum()
           valores_nulos

Out[392...] text          2
           label_sexist    0
           dtype: int64
```

Figura 26: Identificar Valores Nulos

Se utiliza el método `dropna()` para eliminar filas que contienen valores nulos en la columna `text` del DataFrame original. El resultado se almacena en un nuevo DataFrame llamado `df_review`, que excluye dichas filas. Esto asegura que la columna `text` no tenga valores faltantes y permite trabajar únicamente con datos completos en esa columna, mejorando la calidad del análisis posterior.

```
In [393...] df_review = df.dropna(subset=['text'])
           df_review
```

Figura 27: Eliminación de filas con valores nulos en la columna 'text'

Primero, se analiza la distribución de la columna `label_sexist` usando `value_counts()`, mostrando que hay 1508 instancias de `not sexist` y 783 de `sexist`. Para abordar el desbalance, se realiza un muestreo controlado. Se seleccionan las primeras 1500 instancias de `not sexist` y las primeras 700 de `sexist`, creando dos DataFrames separados (`df_positivo` y `df_negativo`). Luego, estos se concatenan con `pd.concat()` en un nuevo DataFrame llamado `df_review_des`. Finalmente, la distribución

ajustada muestra que ahora el conjunto tiene 1500 instancias de not sexist y 700 de sexist, reflejando un desbalance más controlado que permitirá un análisis más enfocado.

```
In [394...] df_review.value_counts('label_sexist')

Out[394...] label_sexist
not sexist    1508
sexist        783
Name: count, dtype: int64

In [395...] df_positivo = df_review[df_review['label_sexist']=='not sexist'][:1500]
df_negativo = df_review[df_review['label_sexist']=='sexist'][:700]

# desbalanceado
df_review_des = pd.concat([df_positivo, df_negativo])
df_review_des.value_counts('label_sexist')

Out[395...] label_sexist
not sexist    1500
sexist        700
Name: count, dtype: int64
```

Figura 28: Análisis y ajuste del balance en las clases del dataset

Se utiliza la técnica de submuestreo aleatorio mediante la clase `RandomUnderSampler` de la biblioteca `imbalanced-learn` para balancear las clases del dataset. El método `fit_resample` toma como entrada las columnas de texto (`text`) y etiquetas (`label_sexist`) del DataFrame desbalanceado `df_review_des`, y genera un nuevo conjunto de datos balanceado (`df_review_bal`). El resultado final muestra 700 instancias para cada clase (`not sexist` y `sexist`), logrando un equilibrio perfecto entre ambas categorías. Este balance es crucial para entrenar modelos de clasificación más justos y eficaces.

#### Balanceando Dataset

```
In [397...] from imblearn.under_sampling import RandomUnderSampler

rus = RandomUnderSampler()
df_review_bal, df_review_bal['label_sexist'] = rus.fit_resample(df_review_des[['text']], df_review_des['label_sexist'])

df_review_bal.value_counts(['label_sexist'])

Out[397...] label_sexist
not sexist    700
sexist        700
Name: count, dtype: int64
```

Figura 29: Balanceo del dataset

Se utiliza la función `train_test_split` de `sklearn.model_selection` para dividir los datos en dos conjuntos: uno para entrenamiento (train) y otro para prueba (test).

- Las características (X) se definen como la columna `text`, mientras que las etiquetas (y) corresponden a la columna `label_sexist`.
- El tamaño del conjunto de prueba se establece en el 20% del total (`test_size=0.2`), mientras que el restante 80% se destina al entrenamiento.
- El parámetro `random_state=42` asegura la reproducibilidad de la partición.

El resultado genera subconjuntos de entrenamiento y prueba tanto para las características como para las etiquetas, permitiendo separar los datos necesarios para entrenar el modelo y luego evaluar su desempeño

#### Separando data para entrenar (train) y testear (test)

```
In [399]: from sklearn.model_selection import train_test_split

# Definir características (X) y etiquetas (y)
X = df['text'] # Características (columna 'text')
y = df['label_sexist'] # Etiquetas (columna 'label_sexist')

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

In [400]: train_x, train_y = train['text'], train['label_sexist']
test_x, test_y = test['text'], test['label_sexist']
```

Figura 30: División del dataset en conjuntos de entrenamiento y prueba

Se utiliza Tf-idf (frecuencia de término - frecuencia inversa de documento) como método para transformar texto en una representación numérica que refleja la relevancia de cada palabra en un conjunto de documentos, ignorando aquellas que son demasiado comunes.

Primero, se obtienen las stopwords en español mediante la biblioteca NLTK. Estas palabras vacías, como "el", "la", "de", etc., son excluidas del análisis, ya que no aportan información significativa al modelo. Luego, se inicializa el `TfidfVectorizer` y se

configura para aplicar el filtro de stopwords en español. Este vectorizador convierte el texto en una matriz donde cada fila representa un documento y cada columna una palabra única, asignando un peso basado en la frecuencia relativa de la palabra.

En el conjunto de entrenamiento (`train_x`), el texto se ajusta y transforma mediante `fit_transform()`. Para el conjunto de prueba (`test_x`), solo se realiza la transformación con `transform()`, asegurando que el vectorizador use la misma escala y palabras identificadas en el entrenamiento. Finalmente, se verifica el tamaño de las matrices resultantes. El conjunto de entrenamiento tiene 938 documentos y 4487 características (palabras únicas relevantes), mientras que el conjunto de prueba cuenta con 462 documentos y el mismo número de características.

#### Representacion de Text

En este caso usaremos Tf-idf, frecuencia de término – frecuencia inversa de documento, es una medida numérica que expresa cuán relevante es una palabra para un documento en una colección.

```
import nltk
from sklearn.feature_extraction.text import TfidfVectorizer
from nltk.corpus import stopwords

# Obtener Las stopwords en español
spanish_stopwords = stopwords.words('spanish')

# Aplicar TfidfVectorizer con stopwords en español
tfidf = TfidfVectorizer(stop_words=spanish_stopwords)

# Transformar Los datos de entrenamiento y prueba
train_x_vector = tfidf.fit_transform(train_x)
test_x_vector = tfidf.transform(test_x)

# Verificar el tamaño de las matrices resultantes
print(train_x_vector.shape)
print(test_x_vector.shape)
```

```
(938, 4487)
(462, 4487)
```

Figura 31: Preparación de los datasets

### 4.3.4 Modelado

Se implementan diversos algoritmos de Machine Learning para entrenar modelos de clasificación. Primero, la Regresión Logística utiliza un enfoque estadístico para predecir la probabilidad de las clases, ajustándose con los datos de entrada y salida. Luego, las Máquinas de Soporte Vectorial (SVM) emplean un kernel lineal para encontrar el hiperplano óptimo que separa las clases, configurando el cálculo de probabilidades y garantizando la reproducibilidad.

También se incluye el modelo Naive Bayes, específicamente GaussianNB, ideal para datos continuos, convirtiendo previamente los datos en matrices densas debido a sus limitaciones con matrices dispersas. Finalmente, se utiliza el modelo de Árbol de Decisión, que clasifica los datos creando nodos basados en las características, ofreciendo interpretabilidad y flexibilidad. Estos modelos son entrenados con los mismos datos para evaluar su rendimiento y compararlos en el conjunto de prueba.

**Selección del Modelo**  
Algoritmos de ML

**Regresión Logística**

```
In [407]: from sklearn.linear_model import LogisticRegression
lr = LogisticRegression()
lr.fit(train_x_vector, train_y)
```

```
Out[407]: LogisticRegression()
```

**Support Vector Machines (SVM)**

```
In [409]: from sklearn.svm import SVC
svc = SVC(kernel='linear', probability=True, random_state=42)
svc.fit(train_x_vector, train_y)
```

```
Out[409]: SVC(kernel='linear', probability=True, random_state=42)
```

**Naive Bayes**

```
In [413]: from sklearn.naive_bayes import GaussianNB
gnb = GaussianNB()
gnb.fit(train_x_vector.toarray(), train_y)
```

```
Out[413]: GaussianNB()
GaussianNB()
```

**Decision tree**

```
In [415]: from sklearn.tree import DecisionTreeClassifier
dec_tree = DecisionTreeClassifier()
dec_tree.fit(train_x_vector, train_y)
```

```
Out[415]: DecisionTreeClassifier()
DecisionTreeClassifier()
```

Figura 32: Selección de modelos de Machine Learning para clasificación

Se evalúan los modelos entrenados utilizando el conjunto de prueba mediante la métrica de Score (Accuracy), que mide la proporción de predicciones correctas. Los resultados muestran que las Máquinas de Soporte Vectorial (SVM) alcanzan la mayor precisión (70.56%), seguidas por la Regresión Logística (69.91%), el Árbol de Decisión (61.26%) y, finalmente, Naive Bayes (54.98%).

## Evaluación del Modelo

### Score (Accuracy)

```

... print(svc.score(test_x_vector, test_y))
    print(dec_tree.score(test_x_vector, test_y))
    print(gnb.score(test_x_vector.toarray(), test_y))
    print(lr.score(test_x_vector, test_y))

```

```
0.7056277056277056
```

```
0.6125541125541125
```

```
0.5497835497835498
```

```
0.6991341991341992
```

Figura 33: Evaluación de modelos de Machine Learning mediante métricas de precisión

De tal manera que según estos resultados SVM, va a ser el algoritmo a utilizar de aquí en adelante.

### 4.3.5 Evaluación

Se utiliza la métrica F1-Score de la biblioteca `sklearn.metrics` para evaluar el desempeño del modelo de Máquinas de Soporte Vectorial (SVM) en cada clase (`sexist` y `not sexist`). Este indicador combina la precisión y el recall, ofreciendo una medida equilibrada especialmente útil en conjuntos de datos desbalanceados.

El cálculo se realiza mediante la función `f1_score`, comparando las etiquetas verdaderas (`test_y`) con las predicciones realizadas por el modelo SVM (`svc.predict(test_x_vector)`). Se especifican las clases (`labels=['sexist', 'not sexist']`) y se configura el promedio como `None` para obtener resultados separados por clase.

Los resultados indican que el F1-Score para la clase `sexist` es 0.71, mientras que para `not sexist` es 0.70. Esto refleja un buen desempeño en ambas clases, con un ligero mejor rendimiento en la clase `sexist`.

## F1 SCORE

F1 Score =  $2(\text{Recall Precision}) / (\text{Recall} + \text{Precision})$

```
In [420... from sklearn.metrics import f1_score

f1_score(test_y, svc.predict(test_x_vector),
         labels=['sexist', 'not sexist'],
         average=None)

Out[420... array([0.71186441, 0.69911504])
```

Figura 34: Cálculo del F1-Score por clase utilizando SVM

Se genera un reporte de clasificación utilizando la función `classification_report` de `sklearn.metrics` para evaluar el desempeño del modelo de Máquinas de Soporte Vectorial (SVM) en términos de precisión, recall, F1-Score y soporte.

## Reporte de Clasificación

```
In [422... from sklearn.metrics import classification_report

print(classification_report(test_y, svc.predict(test_x_vector),
                          labels=['sexist', 'not sexist']))
```

	precision	recall	f1-score	support
sexist	0.72	0.70	0.71	240
not sexist	0.69	0.71	0.70	222
accuracy			0.71	462
macro avg	0.71	0.71	0.71	462
weighted avg	0.71	0.71	0.71	462

Figura 35: Reporte de Clasificación

Se genera una matriz de confusión utilizando la función `confusion_matrix` de `sklearn.metrics` para analizar el rendimiento del modelo de Máquinas de Soporte Vectorial (SVM) en términos de predicciones correctas e incorrectas para cada clase.

La matriz resultante es:

**Tabla 2**

	Predicción sexist	Predicción not sexist
--	-------------------	-----------------------

<b>Real sexist</b>	168	72
<b>Real not sexist</b>	64	158

Resultados de la matriz de confusión

- 168: Predicciones correctas de la clase `sexist` (verdaderos positivos).
- 72: Instancias de `sexist` clasificadas incorrectamente como `not sexist` (falsos negativos).
- 158: Predicciones correctas de la clase `not sexist` (verdaderos negativos).
- 64: Instancias de `not sexist` clasificadas incorrectamente como `sexist` (falsos positivos).

### Confusion Matrix

```
In [424...] from sklearn.metrics import confusion_matrix
           confusion_matrix(test_y, svc.predict(test_x_vector),
                           labels=['sexist', 'not sexist'])

Out[424...] array([[168, 72],
                   [ 64, 158]], dtype=int64)
```

Figura 36: Matriz de confusión

Se optimiza el modelo de Máquinas de Soporte Vectorial (SVM) utilizando la técnica `GridSearchCV` de `sklearn.model_selection`, que permite explorar combinaciones de hiperparámetros predefinidos para encontrar la mejor configuración. En este caso, se definen dos parámetros a probar: `C` con valores `[1, 4, 8, 16, 32]`, que controla el margen del clasificador, y `kernel` con opciones `['linear', 'rbf']`, que especifica el tipo de función kernel utilizada para transformar los datos.

Se configura `GridSearchCV` para realizar una búsqueda con validación cruzada de 5 particiones (`cv=5`) y se entrena con los datos de entrada (`train_x_vector`) y las etiquetas (`train_y`). Los resultados indican que los



mejores hiperparámetros son `C=4` y `kernel='rbf'`, logrando un puntaje de validación cruzada de 0.713, lo que representa una mejora en el rendimiento del modelo optimizado. Este proceso asegura que el modelo final esté ajustado para maximizar su desempeño en el dataset.

## Optimización del Modelo

### GridSearchCV

SVM MEJOR MODELO

```
In [427... from sklearn.model_selection import GridSearchCV

parametros = {'C':[1,4,8,16,32], 'kernel':['linear', 'rbf']}
svc = SVC()
svc_grid = GridSearchCV(svc, parametros, cv=5)
svc_grid.fit(train_x_vector, train_y)
```

```
Out[427... GridSearchCV
  estimator: SVC
    SVC
```

```
In [428... print(svc_grid.best_estimator_)
print(svc_grid.best_params_)

SVC(C=4)
{'C': 4, 'kernel': 'rbf'}
```

```
In [429... svc_grid.best_score_

Out[429... 0.7131983160769144
```

Figura 37: Optimización del modelo SVM usando GridSearchCV

Se realiza una prueba del modelo entrenado utilizando ejemplos de texto seleccionados aleatoriamente de la columna `text` del dataset balanceado. Estos textos se transforman mediante el vectorizador TF-IDF, asegurando que estén en el formato adecuado para ser procesados por el modelo.

El modelo SVM previamente entrenado genera predicciones para cada texto. Para cada ejemplo, se muestra el texto original junto con la predicción del modelo, que clasifica los textos como `sexist` o `not sexist`.

En los resultados, se pueden observar las predicciones realizadas por el modelo.

Por ejemplo:

1. Un texto con contenido ofensivo es correctamente clasificado como `sexist`.
2. Otro texto, con lenguaje frontal y acusatorio, también es identificado como `sexist`.
3. Finalmente, un texto más neutral es clasificado como `not sexist`.

**Testeo**

```
In [411]: # Ejemplos de texto extraídos de la columna 'text'
sample_texts = df_review_bal['text'].sample(3).values

# Transformar los textos de ejemplo con el vectorizador TF-IDF
sample_texts_vector = tfidf.transform(sample_texts)

# Realizar predicciones utilizando el modelo entrenado (SVC en este caso)
print("Textos de ejemplo y predicción del modelo:")
for i, text in enumerate(sample_texts):
    prediction = svc.predict(sample_texts_vector[i])
    print(f"Texto: {text}\nPredicción: {prediction}\n")
```

Textos de ejemplo y predicción del modelo:  
 Texto: @chehescachis @kronoskafk @vampire Jajajaja "Misty la lagartona" esa sí era una del clan de RuPaul?! Jajajajajaja-  
 Predicción: ['sexist']

Texto: @katherinecorvb Mariconas? Es Frontal que es distinto, ahora que tú solo te atreves a escribir las cosas por twitter-  
 Predicción: ['sexist']

Texto: Sabes que te has hecho mayor cuando para desconectar te pones a fregar platos  
 Predicción: ['not sexist']

Figura 38: Testeo

### 4.3.6 Implementación

#### Fase de Implementación

La implementación del modelo se llevó a cabo utilizando Flask, un framework ligero y eficiente que permite crear aplicaciones web de forma rápida. El modelo de detección, previamente entrenado y evaluado, fue serializado con Joblib para facilitar su carga dentro de la aplicación. Esto garantiza que el modelo esté disponible cada vez que el servidor Flask procesa una solicitud de predicción.



Figura 39: Frontend del formulario

La interfaz de usuario se diseñó utilizando HTML y CSS para ofrecer una experiencia visual atractiva y accesible. La estructura incluye un formulario en el que los usuarios pueden ingresar un tweet, y un botón que, al ser presionado, envía el texto al servidor Flask para su análisis. Dependiendo del resultado de la predicción, el sistema muestra si el tweet ingresado es "Sexista" o "No Sexista". Los resultados se presentan de manera clara, con colores diferenciados: rojo para tweets sexistas y verde para los no sexistas.



Figura 40: Tweet Sexista o no Sexista

Para agregar funcionalidad dinámica, se utilizó JavaScript, que permite recargar la página cuando el usuario desea analizar otro tweet. Esto facilita una experiencia fluida sin necesidad de recargar completamente la aplicación web. Por último, la aplicación fue probada en un entorno virtual.

La implementación se enfocó en mantener un diseño sencillo pero efectivo, con herramientas fáciles de usar que aseguren un flujo de trabajo claro tanto para desarrolladores como para usuarios finales.

#### **4.3.7 Análisis Crítico**

El logro de un 70% de exactitud y F1-Scores cercanos a 0.71 demuestra que el modelo, si bien funcional, no es infalible. En escenarios reales, donde la prevención de la violencia de género es una prioridad, estos resultados deben interpretarse con prudencia. El modelo podría servir como filtro inicial, priorizando la revisión humana de los mensajes más ambiguos o incorporar umbrales de confianza para actuar solo en casos más claros. Esta integración de la herramienta con expertos en género, moderadores de contenido y políticas institucionales puede mejorar la aplicación práctica del modelo.

En síntesis, si bien el trabajo con el dataset MeToo logró cumplir el objetivo de identificar patrones de discurso sexista y mostró avances en la precisión del modelo, aún existen desafíos en términos de sensibilidad, representatividad de datos y replicabilidad. Los resultados indican un camino prometedor, pero también subrayan la necesidad de continuar perfeccionando el modelo, incorporando más datos, técnicas de NLP más avanzadas y una evaluación más profunda del impacto de los errores en contextos reales, para garantizar que esta herramienta se convierta en un recurso verdaderamente útil en la lucha contra la violencia de género en entornos digitales.

#### **4.4 Evaluaciones con expertos**

La Psic. Diana Ramírez, reconocida por su experiencia en la atención a víctimas de violencia de género, destacó en su entrevista varios aspectos clave para abordar esta problemática desde un enfoque psicológico. Según su perspectiva, los factores psicológicos más comunes que contribuyen a la perpetuación de la violencia incluyen la

baja autoestima, los traumas no resueltos y la influencia de los roles de género tradicionales.

Enfatizó cómo los estereotipos de género fomentan dinámicas de poder desiguales que perpetúan el control y la violencia en las relaciones. También subrayó la importancia de identificar señales tempranas de riesgo, como cambios drásticos en el comportamiento, aislamiento social y verbalizaciones que revelen normalización de la violencia.

Ramírez considera que las herramientas tecnológicas, como el Machine Learning, pueden ser valiosas para anticipar situaciones de riesgo, siempre que se garantice la privacidad de las víctimas y se eviten sesgos que puedan afectar la calidad de las predicciones. Su enfoque integral combina educación emocional, igualdad de género y terapias focalizadas para mitigar los efectos psicológicos tanto en las víctimas como en sus familias.

Desde el aspecto que abarca los datos, El Ing. Carlos Valle, experto en análisis de datos y Machine Learning, aportó una perspectiva técnica esencial para el desarrollo de modelos predictivos aplicados a la violencia de género. En su entrevista, destacó los pasos clave en la ingeniería de datos para asegurar que los conjuntos de datos sean representativos, incluyendo la anonimización, la eliminación de sesgos y el balance de clases mediante técnicas como SMOTE.

Valle enfatizó la importancia de usar métricas de validación, como el recall y el f1-score, para minimizar falsos negativos en modelos de clasificación, dado que estos errores pueden ignorar casos reales de violencia, lo cual resulta crítico en este contexto. Además, compartió sus experiencias en el uso de TF-IDF para representar datos textuales y recomendó configuraciones específicas, como la personalización de listas de stop words, para maximizar la relevancia de los términos analizados.

Sus contribuciones refuerzan el valor del Machine Learning como una herramienta innovadora para predecir patrones de riesgo y optimizar intervenciones preventivas en problemáticas sociales.

#### 4.5 Calificación del modelo por el experto en psicología.

Se solicitó al evaluado calificar el modelo desarrollado con base a los resultados obtenidos. Mediante la herramienta Google Forms se compartió la encuesta a través de la cual el experto calificó de la siguiente manera:

La escala del 1 al 5 en la rúbrica de calificación se puede interpretar de la siguiente manera: **1 – Insuficiente; 2 – Deficiente; 3 – Adecuado; 4 – Bueno; 5 – Excelente.**

##### 1. Pertinencia de Variables y Características Seleccionadas:

Se solicitó a la psicóloga evaluar si las variables elegidas (socioeconómicas, culturales, contextuales, y de lenguaje) son relevantes y representativas de los factores que influyen en la violencia de género, tanto en entornos físicos como digitales.




Figura 41: Resultado Pregunta 1

**Comentario:** La experta destaca que la mayoría de las variables utilizadas reflejan condiciones asociadas a la dinámica de la violencia, aunque sugiere incorporar información adicional sobre factores relacionales y mayor detalle sobre la temporalidad de los eventos.

## 2. Relevancia para la Prevención:

La experta valoró la capacidad de los modelos para orientar la detección temprana de situaciones potencialmente violentas, apoyando la toma de decisiones por parte de entidades gubernamentales, ONG y profesionales de la salud mental.





Figura 42: Resultado Pregunta 2

Comentario: Aunque el modelo facilita la priorización de casos, se sugiere una mayor sensibilidad en ciertos perfiles culturalmente vulnerables, así como la inclusión de datos longitudinales que permitan identificar patrones de escalamiento de la violencia.

## 3. Documentación y Comunicación de Resultados

Si bien las salidas del modelo pueden guiar intervenciones, la experta sugiere que su efectividad mejoraría al añadir información de índole psicosocial, por ejemplo, testimonios de víctimas o factores de salud mental, lo que incrementaría la precisión y relevancia en diferentes entornos. Finalmente, se solicitó valorar la calidad de la documentación, incluyendo la descripción detallada del proceso, las herramientas utilizadas, las limitaciones del estudio y las recomendaciones para trabajos futuros, con gráficos claros y conclusiones bien sustentadas.



*Figura 43: Resultado Pregunta 3*

#### 4. Consideración General por parte de la experta

Si bien las salidas de los modelos pueden guiar intervenciones, la experta sugiere que su efectividad mejoraría al añadir información de índole psicosocial, por ejemplo, testimonios de víctimas o factores de salud mental, lo que incrementaría la precisión y relevancia en diferentes entornos.



## 5. Conclusiones

El presente trabajo logró el objetivo general de desarrollar un modelo de machine learning para predecir casos de violencia de género en Ecuador, proporcionando una herramienta tecnológica que fortalece la identificación temprana de situaciones de riesgo. Este resultado se alcanzó mediante una arquitectura metodológica cuidadosamente diseñada, optimizando la capacidad de respuesta de las instituciones involucradas y sentando las bases para su adaptación a diversos contextos.

La revisión exhaustiva de investigaciones académicas y técnicas en torno a la violencia de género y la Inteligencia Artificial permitió asentar fundamentos teóricos y metodológicos sólidos. Este análisis fue determinante para seleccionar enfoques replicables y adecuados al escenario ecuatoriano, garantizando que la solución se sustentara en prácticas validadas.

Además, se abordaron tanto el entorno analógico como el digital, implementando un modelo con el ENVIGMU Dataset y otro con el MeToo Dataset. Mientras el primero proporcionó información estructurada y contextualizada sobre factores de riesgo en el ámbito físico, el segundo permitió detectar patrones lingüísticos asociados al discurso sexista en redes sociales.

El diseño de una arquitectura de software escalable y modular facilitó la adaptación de los modelos a diversos entornos, incluidos aplicativos webs. Esta flexibilidad no solo permite replicar la solución en distintas regiones de Ecuador, sino también transferirla a otros países con problemáticas afines, potenciando así su impacto y alcance.

La implementación del modelo, orientada por técnicas avanzadas de selección de características y optimización de hiperparámetros, incrementó la eficacia de los algoritmos de clasificación. La evaluación con métricas clave como la precisión, sensibilidad y especificidad, lo cual demostró una mejora sustancial en la identificación

de situaciones de riesgo, a la vez que señaló áreas susceptibles de mejora continua a medida que se incorporen más datos.

Finalmente, la rigurosa evaluación del rendimiento, que incluyó validación cruzada y control de desbalance de clases, reforzando la replicabilidad y adaptabilidad del enfoque. En conjunto, estos logros constituyen una base sólida para la evolución sostenida de soluciones tecnológicas orientadas a la prevención de la violencia de género, abarcando tanto el entorno físico como el digital, y solventando las necesidades de los involucrados de manera integral.

## 6. Recomendaciones

Es fundamental realizar pruebas extensivas del modelo en entornos reales para evaluar su desempeño en diversos contextos. Este proceso debe incluir el monitoreo continuo y ajustes regulares de los parámetros del modelo, incorporando datos actualizados para garantizar que las predicciones sean precisas y relevantes con el tiempo. Esto permitirá identificar y corregir posibles limitaciones en su implementación temprana.

Se recomienda ampliar el análisis de datos mediante la integración de nuevas fuentes, como redes sociales, registros judiciales y encuestas adicionales. Esta ampliación no solo enriquecerá la capacidad del modelo para detectar patrones complejos, sino que también garantizará que sea representativo de las diversas manifestaciones de violencia de género en Ecuador, fortaleciendo así su aplicabilidad en contextos específicos.

Un despliegue gradual a través de proyectos piloto es crucial para validar la funcionalidad del modelo antes de una implementación a gran escala. Colaborar con instituciones públicas, ONGs y actores clave permitirá identificar áreas de mejora técnica y operativa. Esta etapa preliminar asegurará una implementación más efectiva y adaptada a las necesidades de los usuarios finales.

Además, se debe invertir en programas de capacitación dirigidos a los usuarios finales del modelo, como el personal de instituciones gubernamentales y organizaciones de apoyo. Una formación adecuada garantizará que los usuarios comprendan cómo interpretar los resultados del modelo y cómo integrarlos en sus procesos de toma de decisiones, maximizando su impacto en la prevención de la violencia de género.

Finalmente, fomentar la colaboración interdisciplinaria es esencial para refinar y adaptar el modelo a los cambios en las dinámicas sociales. La participación de expertos en tecnología, ciencias sociales y políticas públicas permitirá desarrollar soluciones más

integrales y sostenibles, asegurando que el modelo responda a las necesidades del contexto ecuatoriano.

## 7. Anexos

### 7.1 Comparativa de los Datasets Utilizados en el Estudio

Tabla 3

<b>Característica</b>	<b>ENVIGMU Dataset</b>	<b>MeTwo Dataset</b>
<b>Fuente u Origen</b>	Encuesta Nacional sobre Relaciones Familiares y Violencia de Género (INEC, 2019)	Estudio "Automatic Classification of Sexism in Social Networks" (Rodríguez-Sánchez et al.)
<b>Nombre Dataset</b>	ENVIGMU	MeTwo
<b>Número de Subdatasets</b>	3 (mujeres casadas/unidas, separadas/viudas, solteras)	1
<b>Número Total de Variables</b>	~150 variables (según la estructura de la encuesta)	~10 variables
<b>Número Total de Registros</b>	Aproximadamente 40,000 registros (sumando subdatasets)	Aproximadamente 20,000 tweets
<b>Descripción General</b>	Datos sociodemográficos y sobre violencia (física, psicológica, sexual, económica).	Tweets etiquetados como sexistas o no sexistas.
<b>Desventajas</b>	Desbalance en los tipos de violencia; posibles valores faltantes.	Alta subjetividad en la anotación; posible sesgo cultural.
<b>Ventajas</b>	Amplia cobertura nacional; múltiples tipos de violencia analizados.	Datos contemporáneos de redes sociales; texto procesable para NLP.

Nota: Comparativa de los Datasets Utilizados en el Estudio

## **7.2 Preguntas de Entrevista Psic. Diana Ramírez**

**Pregunta 1: En su experiencia como psicóloga, ¿cuáles son los factores psicológicos más comunes que contribuyen a la violencia de género?**

Factores como baja autoestima, dificultad para regular las emociones, creencias machistas arraigadas, dependencia emocional, escasas habilidades de comunicación y la normalización de patrones violentos aprendidos en la familia suelen contribuir a la violencia de género.

**Pregunta 2: ¿Cómo influyen los estereotipos y roles de género en la perpetuación de la violencia contra las mujeres?**

Los estereotipos y roles de género tradicionales refuerzan la idea de superioridad masculina y sumisión femenina, justificando el control, el abuso y la agresión. Esto crea un contexto cultural que tolera y reproduce la violencia, dificultando la prevención y la intervención.

**Pregunta 3: ¿Qué señales o comportamientos tempranos pueden indicar que alguien está en riesgo de ser víctima o perpetrador de violencia de género?**

Señales de alerta incluyen conductas controladoras, celos excesivos, humillaciones verbales, aislamiento social impuesto a la pareja, desvalorizaciones constantes, cambios bruscos de humor y falta de respeto hacia la autonomía y límites del otro.

**Pregunta 4: ¿Cómo afecta la violencia de género a la salud mental de las víctimas a corto y largo plazo?**

A corto plazo, las víctimas pueden experimentar ansiedad, depresión, temor constante, desconfianza y vergüenza. A largo plazo, la violencia puede generar trastorno de estrés postraumático, baja autoestima, dificultades en las relaciones futuras, mayor riesgo de abuso de sustancias y problemas de salud mental crónicos.

**Pregunta 5: ¿Cuál es el impacto psicológico en los hijos y familiares que presencian o viven en entornos de violencia de género?**

Los hijos y familiares pueden sufrir ansiedad, depresión, baja autoestima, dificultades escolares y problemas de conducta. A menudo desarrollan creencias erróneas sobre las relaciones, aumentando el riesgo de repetir patrones de violencia en la vida adulta.

**Pregunta 6: Desde su perspectiva, ¿qué estrategias terapéuticas son más efectivas para ayudar a las víctimas a superar el trauma?**

La terapia cognitivo-conductual enfocada en el trauma, la intervención en crisis, los grupos de apoyo, técnicas de regulación emocional, el fortalecimiento de la red social y la psicoeducación sobre relaciones saludables resultan efectivas para la recuperación.

**Pregunta 7: ¿Cómo puede la educación emocional y en igualdad de género contribuir a la prevención de la violencia?**

La educación emocional y la formación en igualdad promueven el respeto, la empatía y el entendimiento mutuo. Al cuestionar roles rígidos y estereotipos, se disminuye la tolerancia a la violencia y se fomenta la construcción de relaciones equitativas, sanas y libres de abuso.

**Pregunta 8: ¿Qué papel juegan las instituciones educativas y comunitarias en la detección y prevención de la violencia de género?**

Las instituciones pueden capacitar a docentes, personal de salud y líderes comunitarios para detectar señales de alerta, brindar orientación, desarrollar programas preventivos, facilitar el acceso a recursos especializados y fomentar la denuncia y apoyo a víctimas.

**Pregunta 9: ¿Cómo ha cambiado el abordaje psicológico de la violencia de género en los últimos años?**

Se ha pasado de enfoques fragmentados a modelos integrales que consideran la perspectiva de género, la cultura y el contexto social. Además, se utilizan guías basadas en evidencia, mayor capacitación profesional, intervención temprana y trabajo interdisciplinario.

**Pregunta 10: ¿Qué desafíos enfrentan los profesionales de la salud mental al trabajar con casos de violencia de género en Ecuador?**

Entre los desafíos están la escasez de recursos especializados, la falta de formación continua, barreras culturales y la necesidad de articular esfuerzos con el sistema legal y otras instituciones. Esto dificulta intervenciones integrales y eficaces.

**Pregunta 11: ¿Cuál es su opinión sobre la incorporación de tecnologías como el machine learning para predecir y prevenir casos de violencia de género?**

Puede ser una herramienta útil para identificar patrones de riesgo y guiar intervenciones tempranas, siempre que se aplique con rigor científico, supervisión profesional, criterios éticos claros y respeto a la privacidad de las potenciales víctimas.

**Pregunta 12: ¿Cree que los modelos predictivos pueden ser una herramienta eficaz para identificar situaciones de riesgo antes de que ocurran?**



Sí, pueden ser eficaces si se basan en datos fiables, se actualizan regularmente y se combinan con la evaluación clínica. Deben servir como apoyo, no como sustituto, de la intervención humana y el criterio profesional.

**Pregunta 13: ¿Qué papel pueden jugar las redes sociales y el análisis de datos en línea en la identificación de patrones de comportamiento asociados con la violencia de género?**

Las redes sociales y el análisis de datos pueden revelar amenazas, acoso, discursos machistas y patrones de control. Esto facilita la detección temprana, la sensibilización y la implementación de estrategias preventivas.

**Pregunta 14: ¿Cómo podrían los profesionales de la psicología y la tecnología colaborar para desarrollar soluciones innovadoras a este problema?**

Podrían trabajar en el diseño de herramientas de evaluación, aplicaciones de alerta temprana, programas de psicoeducación en línea, espacios virtuales de apoyo terapéutico y análisis de datos para mejorar la comprensión y abordaje de la violencia de género.

**Pregunta 15: Desde su punto de vista, ¿cómo podría afectar la implementación de estas tecnologías a la privacidad y seguridad de las potenciales víctimas?**

Es esencial contar con protocolos de seguridad, anonimato y consentimiento informado. La protección de la información es prioritaria, pues un uso inadecuado podría exponer a las víctimas o revictimizarlas en entornos digitales.

**Pregunta 16: ¿Qué medidas preventivas considera más urgentes para reducir la incidencia de violencia de género en nuestra sociedad?**

Educación en igualdad de género desde edades tempranas, capacitaciones continuas a profesionales, fortalecer la red de apoyo institucional, mejorar el acceso a

servicios de salud mental, impulsar campañas de sensibilización y asegurar políticas públicas efectivas que protejan a las víctimas y sancionen a los agresores.

### 7.2.1 Imagen de la entrevista



*Figura 44: Imagen de Entrevista - Psic. Diana Ramirez*

### 7.3 Preguntas de Entrevista Ing, Carlos Valle

**Trayectoria y experiencia:**

**Pregunta:**

**Pregunta 1: ¿Puede contarnos sobre su trayectoria profesional como analista de datos, particularmente en proyectos relacionados con temas sociales, y cómo utiliza Python en estos casos?**

**Respuesta:**

Mi trayectoria profesional como analista de datos incluye una sólida experiencia trabajando en proyectos orientados a resolver problemáticas sociales, como análisis de patrones de violencia de género y estudios sobre desigualdad social. En estos proyectos, he utilizado **Python** como una herramienta central debido a su versatilidad y su extenso ecosistema de bibliotecas, como **pandas**, **numpy**, **scikit-learn** y **nlTK**. Python me ha permitido procesar grandes volúmenes de datos, realizar análisis

exploratorios y desarrollar modelos predictivos enfocados en detectar patrones específicos en conjuntos de datos complejos. Por ejemplo, en un proyecto de análisis de denuncias de violencia de género, utilicé **NLTK** para el procesamiento de texto, combinándolo con algoritmos de machine learning para identificar patrones en declaraciones textuales.

## **2. Ingeniería de datos:**

**Pregunta 2: ¿Qué pasos clave considera esenciales en la ingeniería de datos para asegurar que los datos sean representativos, especialmente en contextos sociales sensibles como la violencia de género?**

### **Respuesta:**

En proyectos con datos sensibles, como violencia de género, la ingeniería de datos debe centrarse en garantizar la representatividad y la calidad de los datos. Los pasos clave incluyen:

1. **Comprensión del dominio:** Colaborar con expertos para entender las dinámicas sociales detrás de los datos.
2. **Preprocesamiento ético:** Anonimizar datos para proteger la privacidad de los participantes.
3. **Tratamiento de sesgos:** Identificar y corregir desequilibrios en la representación de grupos sociales o demográficos.
4. **Validación cruzada de fuentes:** Verificar la consistencia y fiabilidad de las fuentes de datos.
5. **Balance de clases:** Implementar técnicas como sobremuestreo, submuestreo o generación de datos sintéticos para manejar clases desbalanceadas. Este

enfoque asegura que los análisis no refuercen prejuicios existentes ni conduzcan a conclusiones erróneas.

### **3. Controles estadísticos:**

**Pregunta 3: ¿Qué métodos de control estadístico de procesos utiliza en sus análisis, y cómo estos contribuyen a la validación o mejora de modelos predictivos?**

**Respuesta:**

Utilizo herramientas de control estadístico como los gráficos de control y análisis de varianza (**ANOVA**) para identificar anomalías o variabilidad en los datos antes de entrenar modelos predictivos. Estos métodos son esenciales para detectar puntos fuera de control que pueden distorsionar los resultados del modelo. Por ejemplo, en un proyecto reciente, un análisis estadístico identificó inconsistencias en los datos demográficos que, al corregirse, mejoraron significativamente la precisión del modelo predictivo. Además, utilizo técnicas de validación cruzada para garantizar que los modelos sean robustos frente a la variabilidad de los datos.

### **4. Desarrollo y herramientas:**

**Pregunta 4: ¿Puede describir su proceso para desarrollar, entrenar y probar modelos de detección con Python? ¿Qué IDE o plataformas considera más efectivas para proyectos complejos?**

**Respuesta:**

El proceso incluye las siguientes etapas:

1. **Exploración de datos:** Utilizo **pandas** y **matplotlib** para realizar un análisis exploratorio inicial.

2. **Preprocesamiento:** Esto incluye limpieza, transformación y creación de características con bibliotecas como **scikit-learn**.
3. **Entrenamiento y evaluación:** Entreno modelos usando **scikit-learn** o **TensorFlow**, evaluando su desempeño con métricas relevantes.
4. **Optimización:** Aplico técnicas como búsqueda en cuadrícula o aleatoria para ajustar hiperparámetros.
5. **Validación:** Uso validación cruzada para garantizar la robustez del modelo.

Prefiero **Jupyter Notebooks** para la etapa exploratoria y **VS Code** o **PyCharm** para proyectos más complejos debido a su capacidad para manejar entornos de desarrollo integrados. En proyectos colaborativos, utilizo **Google Colab** por su facilidad para compartir trabajos.

#### 5. Métricas de validación:

**Pregunta 5: En un proyecto de clasificación como la detección de patrones de violencia de género, ¿qué métricas de validación considera más importantes y por qué?**

#### **Respuesta:**

En contextos como la violencia de género, priorizo **recall** y **f1-score**, ya que es crucial minimizar los **falsos negativos** (casos de violencia no detectados). Esto asegura que los casos críticos sean identificados incluso si implica un ligero aumento en los falsos positivos. También uso matrices **de confusión** para analizar patrones de error y ajustar el modelo según las prioridades del contexto.

#### 6. Desafíos en validación:

**Pregunta 6: ¿Podría compartir ejemplos de desafíos que ha enfrentado al validar modelos de clasificación en contextos con datos desbalanceados, y cómo los ha abordado?**

**Respuesta:**

Un desafío común es manejar clases mayoritarias y minoritarias en datos desbalanceados. En un proyecto de detección de violencia de género, las denuncias confirmadas representaban solo el 10% de los datos. Implementé **SMOTE** (Synthetic Minority Oversampling Technique) para generar datos sintéticos y usé algoritmos como **XGBoost**, que manejan mejores datos desbalanceados. Además, ajusté los pesos de las clases en las funciones de pérdida para equilibrar la influencia de cada clase.

**7. Integración de machine learning:**

**Pregunta 7: ¿Cómo integra el machine learning en proyectos de análisis de datos orientados a problemáticas sociales? ¿Qué algoritmos ha encontrado más efectivos en estos casos?**

**Respuesta:**

Integro machine learning para identificar patrones y realizar predicciones que guíen políticas sociales. Por ejemplo, utilicé **Random Forests** y **Support Vector Machines (SVM)** para analizar denuncias y predecir riesgos de reincidencia. En proyectos basados en texto, los algoritmos de **clasificación supervisada**, como **Logistic Regression** combinados con embeddings como **Word2Vec**, han demostrado ser efectivos.

**8. Elección de algoritmos:**

**Pregunta 8: ¿Qué tipos de algoritmos considera más convenientes para desarrollar un modelo de detección en Machine Learning, especialmente en proyectos enfocados en detectar y prevenir problemas sociales como la violencia de género?**

**Respuesta:**

Para problemas sociales, prefiero:

1. **Árboles de decisión (Random Forest, XGBoost):** Por su capacidad para manejar datos desbalanceados.
2. **Regresión logística:** Útil para problemas interpretables y más simples.
3. **Redes neuronales recurrentes (RNN):** Eficientes para datos textuales.

Cada elección depende de la naturaleza del problema y la interpretabilidad requerida.

**9. Transformaciones de texto con Tf-idf:**

**Pregunta 9: ¿Considera que el uso de Tf-idf es adecuado para representar textos en el contexto de mi modelo? ¿Qué configuraciones (manejo de stop words) recomendaría para mejorar su efectividad?**

**Respuesta:**

Tf-idf es adecuado porque pondera términos relevantes, descartando palabras frecuentes, pero no informativas. Recomiendo usar una lista personalizada de **stop words** basada en el dominio para evitar eliminar palabras que podrían tener significado contextual. También ajusto parámetros como el rango de n-grams para capturar frases clave.

**10. Evaluación de matrices de confusión:**

**Pregunta 10: Al analizar las matrices de confusión, ¿cómo priorizaría errores como falsos positivos o falsos negativos en un modelo orientado a la predicción de violencia de género?**

**Respuesta:**

En un contexto de violencia de género, los falsos negativos tienen mayor impacto porque

pueden ignorar casos reales de violencia. Priorizaría reducir estos errores incluso a costa de un ligero aumento en los falsos positivos, ya que es preferible una intervención adicional a la omisión de un caso crítico.

### 7.2.3 Imagen de la entrevista



Figura 45: Figura 41: Imagen de Entrevista - Ing. Carlos Valle

### 7.4 Diagrama de Gantt

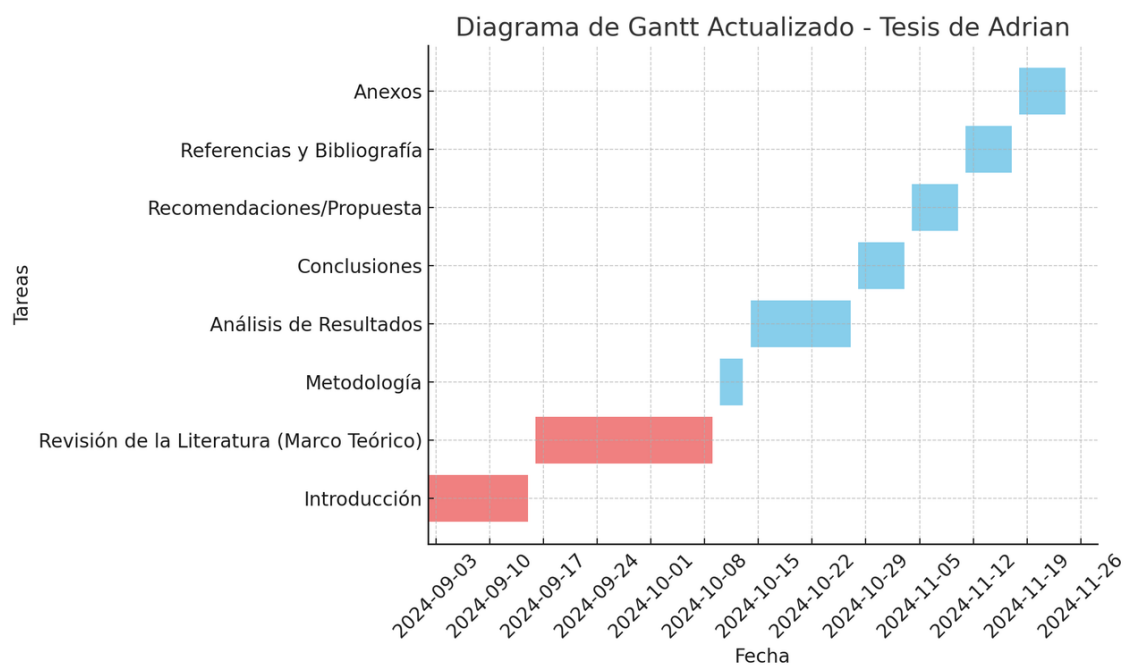


Figura 46: Diagrama de Gantt



## 7.5. Performance de Modelos

### 7.5.1 Envigmu Dataset

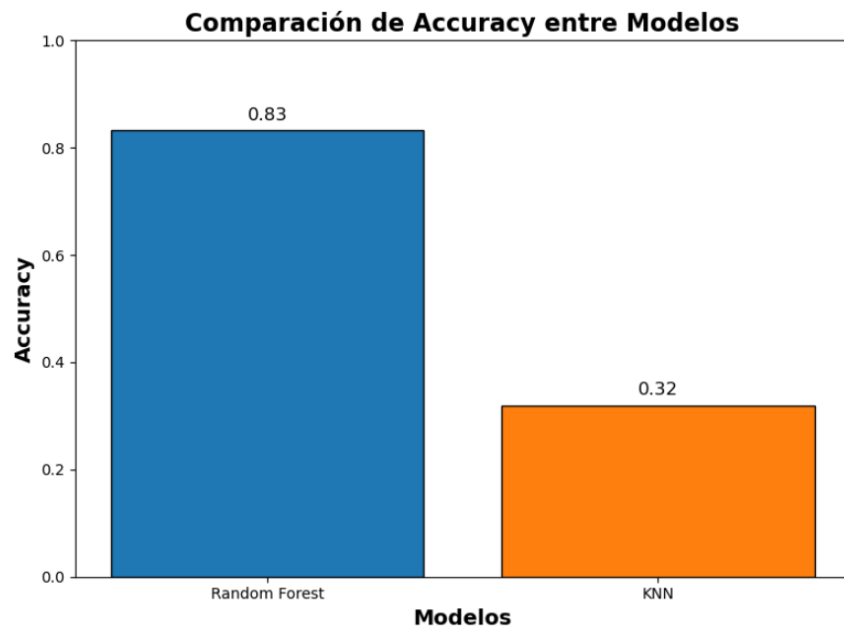


Figura 47: Envigmu Dataset Performance

### 7.5.2 MeTwo Dataset

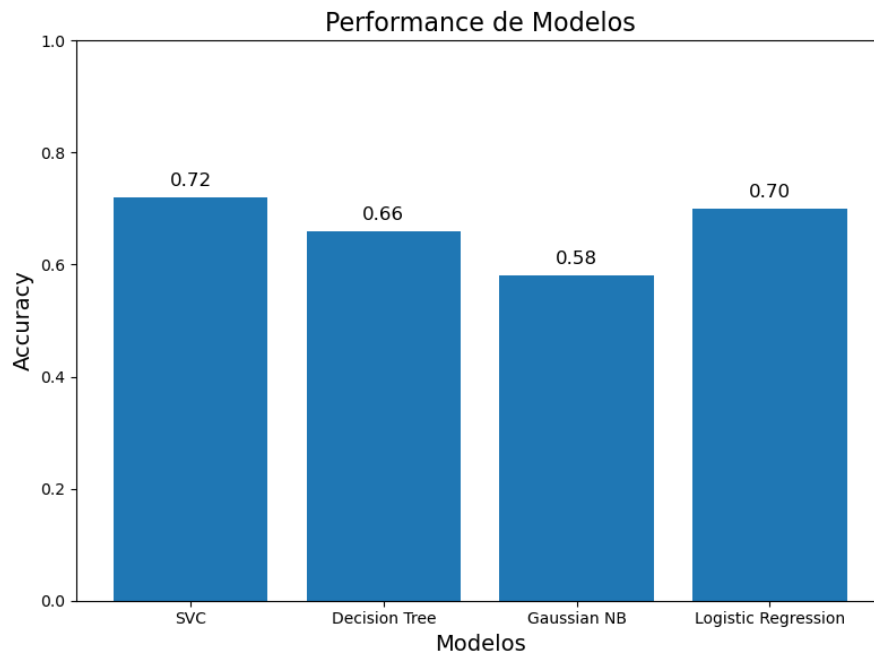


Figura 48: MeTwo Performance

## 7.5 CV de los Expertos



Número de cédula: 0926415035  
 Fecha de nacimiento: 16/03/2000  
 Edad: 24 años  
 Estado civil: Soltera

Me defino como una persona proactiva con buena comunicación, capacidad de adaptación e integra que cuenta con las cualidades adecuadas a desarrollar en el ambiente laboral.

### Contacto

+593 991976516 - +593  
 991562996

ramirezdianaca4@gmail.com  
 Urb. La joya Etapa Gema -  
 Ecuador

### Datos académicos

(En curso) Especialización como  
 Terapeuta en

Terapia Cognitivo Conductual I  
 (Finalizados) Estudios universitarios  
 Licenciatura en Psicología General,  
 itinerario Organizacional, Universidad  
 ECOTEC

Bachiller en ciencias  
 Unidad Educativa del Milenio Sarah Flor  
 Jiménez

### Referencias laborales

Ing. Karen Navarro  
 Cell: 099 321 3047

Psi. Clínica Lissette Candell  
 Cell: 0963855587

## Diana Carolina Ramírez Avilés Psicóloga general

- Pasantías en RRHH MARRIOTT - 2024 (6 meses)
- Procesos de reclutamiento y selección masivos de personal
- Toma de pruebas psicométricas e interpretación con elaboración de informes
- Inducción y capacitación.
- Procesos de desvinculación de personal
- Voluntariado en Instituto de Neurociencias, servicio de ANIMA EC -2024
- Atención en crisis y emergencia psicológica por medio de la línea de atención telefónica/horario de fines de semana
- Voluntariado en el Área de Hospitalización del Instituto de Neurociencias -2023 (4 meses)
- Atención a pacientes de área roja de hospitalización con terapia individual y terapia grupal, manejo de grupos, terapia familiar, realización de informes de evolución y nuevo ingreso de pacientes, aplicación y calificación de test como herramienta de evaluación.
- Voluntariado en el Departamento de Docencia e Investigación del Instituto de Neurociencias, en conjunto con el área de residencias -2022 (6 meses)
- Participación en proyecto de blog de Inst. de Neurociencias de 100 horas prácticas en los meses de septiembre a noviembre.
- Prácticas Pre profesionales Inst. De Neurociencias. ANIMA EC -2022 (6 meses)
- Atención en crisis y emergencia psicológica por medio de la línea de atención telefónica del servicio de ANIMA EC

### Certificados - capacitaciones

- Entrenamiento como Brigadista en Primeros Auxilios Psicológicos otorgado por Instituto de Neurociencias.
- Congreso Internacional de Líneas de Ayuda - Realizado en el Instituto de Neurociencias.
- Taller de Primeros Auxilios Psicológicos y Manejo de Crisis Suicida - Realizado en Alpha Psicología por la Psi. Ruth Baquerizo y Psi. Indira Carvajal
- Seminario Internacional de modificación de conducta en niños con trastorno de conducta violenta, dictado por PS. Diana Muñoz Arteaga.
- Realizado en Psique Ecuador. Seminario nacional de psicoterapia y mediación en caso de violencia familiar, dictado por Mg. Adrián Felipe Vásquez.
- Seminario Guía para el Psicólogo avalado por Ministerio de Salud Publica
- Licencia Tipo B / Movilización propia
- Rosetta Stone, Certificación en ingles B2

Carlos Alex Valle Chiriboga

## Datos Personales

Cédula de Id.: 091372438-1  
 Nacionalidad: Ecuatoriana  
 Estado Civil: Divorciado  
 Carga familiar: 1  
 Edad: 44 años  
 Dirección: Cdla. Valle Norte, MZ. 55 Villa 5  
 Teléfono celular: 0980862582  
 Lugar de Nacimiento: Guayaquil  
 Fecha de Nacimiento: 21 de noviembre de 1979  
 Correo electrónico: carlitos.alex.valle@gmail.com  
 LinkedIn: <https://www.linkedin.com/in/carlos-alex-v-92a47665/>



## Estudios Realizados

**Universidad:** UNEMI (Universidad Estatal de Milagro)  
**Título obtenido:** **Maestría en Sistemas de Información con mención en Inteligencia de Negocios y Analítica de Datos**  
 Registro Senescyt: 1024-2024-2813397

**Universidad:** ECOTEC Samborondón  
**Título obtenido:** **Maestría en Sistemas de Información con mención a la inteligencia de negocios**  
 Registro Senescyt: 1077-2020-2177113

**Universidad:** UESS  
**Título obtenido:** **Maestría en Inteligencia de Negocios y Ciencia de Datos**  
 Registro Senescyt: **CURSANDO EN LA ACTUALIDAD**

**Universidad:** Universidad de Guayaquil  
**Título obtenido:** Licenciatura en Sistemas de Información  
 Licenciado en Sistemas de Información  
 Registro Senescyt: 1006-15-1428578

**Universidad:** Escuela Superior Politécnica del Litoral  
 Licenciatura en Sistemas Operativos y Redes

**Secundaria:** Instituto Integral Sudamericano  
**Título:** Bachiller en Comercio y Administración  
**Especialización:** Computación

## Publicaciones

---

### CASA EDITORA DEL POLO

Guía Práctica de Inteligencia de Negocios: Optimizando Estrategias para el Éxito Empresarial

URL: <https://www.casadelpo.com/libro-academico/gu%C3%ADa-pr%C3%A1ctica-de-inteligencia-de-negocios%3A-optimizando-estrategias-para-el-%C3%A9xito-empresarial>  
 EDITORIAL: Casa Editora Del Polo (978-9942-684)  
 REVISTA: Libro digital descargable  
 ISSN: 978-9942-621-93-1  
 DOI: doi.org/10.23857/978-9942-621-93-1

### POLO DE CONOCIMIENTO - MAPA

El Internet de las Cosas (IoT) en la acuaponía: estándar, hardware y software

URL: <https://www.polodelconocimiento.com/ojs/index.php/es/article/view/6272>  
 EDITORIAL: Casa Editora del Polo  
 REVISTA: MAPA  
 ORCID: <https://orcid.org/0000-0003-0090-378X>  
 ISSN: 2550 - 682X  
 DOI: 10.23857/pc.v8i12.6272

### REVISTA DE CIENCIAS SOCIALES Y HUMANISITICA - MAPA

Uso de técnicas de inteligencia de negocios en una empresa de venta directa

URL: <https://revistamapa.org/index.php/es/article/view/370/558>  
 EDITORIAL: Saberes del Conocimiento  
 REVISTA: MAPA  
 ORCID: <https://orcid.org/0000-0003-0090-378X>  
 ISSN: 2602-8441  
 PÁGINAS: 117-128

### RECIAMUC

Virtualización de datos una alternativa moderna de integración de datos

DOI: 10.26820/recimundo/4.(3).julio.2020.242-250  
 URL: <https://www.recimundo.com/index.php/es/article/view/870/>  
 EDITORIAL: Saberes del Conocimiento  
 REVISTA: RECIMUNDO  
 ISSN: 2588-073X  
 CÓDIGO UNESCO: 1203 Ciencia de Los Ordenadores; 1203.17 Informática  
 PÁGINAS: 242-250

### CASEDELPO

URL: <https://www.polodelconocimiento.com/ojs/index.php/es/article/view/4251>  
 EDITORIAL: Polo del Conocimiento  
 REVISTA: CASEDELPO  
 ISSN: 2550-682X

## 8. Bibliografía

- Alba Moreira & Zita Santos. (2023). Tipos de violencia de género recurrentes en Manabí en el 2021, datos estadísticos de OVIGEMA. *Revista San Gregorio*, 1(53), 32-50.
- Alura. (2023, junio 30). *¿Qué es Python? Historia, sintaxis y una guía para iniciarse en el lenguaje* | Alura Cursos Online. Alura. <https://www.aluracursos.com/blog/que-es-python-historia-guia-para-iniciar>
- Alvaro Romero. (2023, noviembre 24). *Desafiando los estereotipos: La ingeniería y la tecnología en la lucha por la eliminación de la violencia contra la mujer*. <https://www.ui1.es/blog-ui1/desafiando-los-estereotipos-la-ingenieria-y-la-tecnologia-en-la-lucha-por-la-eliminacion-de-la-violencia-contra-las-mujeres>
- Amazon Web Services, Inc. (s. f.). *¿Qué es el ajuste de hiperparámetros? - Explicación de los métodos de ajuste de hiperparámetros - AWS*. Amazon Web Services, Inc. Recuperado 7 de octubre de 2024, de <https://aws.amazon.com/es/what-is/hyperparameter-tuning/>
- Ana Angarita Hurtado. (2024, septiembre 20). *Entrevistas cualitativas: Definición, tipos y recomendaciones – SIEPSI*. <https://siepsi.com.co/2024/09/20/entrevistas-cualitativas-definicion-tipos-y-recomendaciones/>
- Anirudha, S. (2021). *Understanding TF-IDF for Machine Learning*. Capital One. <https://www.capitalone.com/tech/machine-learning/understanding-tf-idf/>
- Avella, M. del P. R., Sanabria-Moyano, J. E., & Dinas-Hurtado, K. (2023). Herramientas de predicción de violencia basada en género y feminicidio mediante la Inteligencia Artificial. *Revista Jurídica Mario Alario D'Filippo*, 15(30), Article 30. <https://doi.org/10.32997/2256-2796-vol.15-num.30-2023-4254>
- AWS. (s. f.). *¿Qué es el machine learning? - Explicación sobre el machine learning empresarial - AWS*. Amazon Web Services, Inc. Recuperado 7 de octubre de 2024, de <https://aws.amazon.com/es/what-is/machine-learning/>

- Bagur Pons, S., Rosselló Ramon, M. R., Paz Lourido, B., & Verger, S. (2021). El Enfoque integrador de la metodología mixta en la investigación educativa. *RELIEVE - Revista Electrónica de Investigación y Evaluación Educativa*, 27(1). <https://doi.org/10.30827/relieve.v27i1.21053>
- bejarano, juan jose B. (2024, junio 15). *Evaluación de modelos: Métricas y técnicas para medir el rendimiento*. Universo-IA.com. <https://universo-ia.com/evaluacion-de-modelos-metricas-y-tecnicas-para-medir-el-rendimiento/>
- Benítez Baracaldo, C. R. (2024). Evaluación de riesgo de asalto doméstico de ontario (ODARA) y el proyecto de defensa comunitaria (CAP) en la predicción y prevención de riesgo de violencia de pareja íntima: Una revisión rápida. *Diversitas*, 20(1), 233-246. <https://doi.org/10.15332/22563067.10231>
- Cabrera, C. (2024, octubre 10). “Estoy aquí para darte apoyo”: Violetta, Sophia y Sara, los chatbots que acompañan a víctimas de violencia machista. El País. <https://elpais.com/tecnologia/2024-10-10/estoy-aqui-para-darte-apoyo-violetta-sophia-y-sara-los-chatbots-que-acompanan-a-victimas-de-violencia-machista.html>
- Caisa Coyago, P. A., & Rosero Espinosa, E. O. (2023). *Estudio descriptivo de la violencia de género en Ecuador utilizando técnicas de minería de datos* [bachelorThesis]. <http://dspace.ups.edu.ec/handle/123456789/25221>
- Canle, E. (2022, agosto 30). *La historia del machine learning desde sus comienzos | Tokio*. Tokio School. <https://www.tokioschool.com/noticias/historia-machine-learning/>
- CEPAL. (2024, marzo 6). *América Latina y el Caribe reafirma su compromiso con la igualdad de género de cara a la CSW68* [Text]. Comisión Económica para América Latina y el Caribe. <https://www.cepal.org/es/noticias/america-latina-caribe-reafirma-su-compromiso-la-igualdad-genero-cara-la-csw68>

Chávez, P. A. F., Quillupangui, H. E. Y., & Rodríguez, P. X. Z. (2022). *ANÁLISIS DE LA VIOLENCIA DE GÉNERO DESDE LA PERSPECTIVA DE LA CIBERSEGURIDAD*.

CNIG. (2021, noviembre 29). *BOLETÍN | Violencia por razones de género en espacios digitales – Consejo Nacional para la Igualdad de Género – CNIG*.

<https://www.igualdadgenero.gob.ec/boletin-violencia-por-razones-de-genero-en-espacios-digitales/>

Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, Pub. L. No. Cap II, Art. 3, Numeral 2, 113 (2016).

Codina, Lluís & Lopezosa, Carlos. (2022). Revisiones de la literatura y tesis doctorales: Fases y procedimientos principales para una scoping review. *Universitat Pompeu Fabra*.

Cole Stryker & Jim Holdsworth. (2024, agosto 11). *¿Qué es el PLN (procesamiento del lenguaje natural)? | IBM*. <https://www.ibm.com/es-es/topics/natural-language-processing>

Constitución de la República del Ecuador, Pub. L. No. Art. 425, 168 (2008).

Convención Interamericana para Prevenir, Sancionar y Erradicar la Violencia contra la Mujer, Pub. L. No. Art 7 (1994).

Daniel. (2022, mayo 13). Cross-Validation: Definición e importancia en Machine Learning. *Formación en ciencia de datos | DataScientest.com*.

<https://datascientest.com/es/cross-validation-definicion-e-importancia>

datacamp. (2024). *Tutorial de Pickle en Python: Serialización de objetos*.

<https://www.datacamp.com/tutorial/pickle-python-tutorial>

DataScientest. (2022, enero 25). Random Forest: Bosque aleatorio. Definición y funcionamiento. *Formación en ciencia de datos | DataScientest.com*.

<https://datascientest.com/es/random-forest-bosque-aleatorio-definicion-y-funcionamiento>

DATAtab. (s. f.). *T-Test, Chi-Square, ANOVA, Regression, Correlation...* Recuperado 7 de octubre de 2024, de <https://datatab.es/tutorial/logistic-regression>

Declaración de Beijing y Plataforma de Acción, Pub. L. No. Capítulo IV, Párrafo 129, 316 (1995).

Directrices de Ética para la Inteligencia Artificial, Pub. L. No. Sección B, Subsección IV (2021).

EFE / Redacción Primicias. (2024, agosto 30). *Violencia de género digital: Cómo identificarla y combatirla, según experta ecuatoriana*. Primicias EC. <https://www.primicias.ec/ciencia-tecnologia/violencia-genero-digital-como-identificarla-y-combatirla-experta-ecuatoriana-77716/>

Escudero, X. (2023, octubre 12). Mejora el rendimiento de tus algoritmos con Joblib. *Medium*. <https://xescuder.medium.com/mejora-el-rendimiento-de-tus-algoritmos-con-joblib-94a96e76094a>

Filzinger, T. (2023, mayo 29). *Word2vec: Análisis de textos mediante incrustación de palabras*. Konfuzio. <https://konfuzio.com/es/wordtovec/>

FOQUM. (2023). Recall. *FOQUM*. <https://foqum.io/blog/termino/recall/>

Fundación ISocial. (2022, agosto 30). *Usos del machine learning en los servicios sociales—Fundació iSocial. Innovació en l'acció social*. <https://isocial.cat/es/usos-del-machine-learning-en-els-serveis-socials/>

García-Vergara, E., Almeda, N., Fernández-Navarro, F., & Becerra-Alonso, D. (2023). Artificial intelligence extracts key insights from legal documents to predict intimate partner femicide. *Scientific Reports*, 13(1), 18212. <https://doi.org/10.1038/s41598-023-45157-5>

González-Prieto, Á., Brú, A., Nuño, J. C., & González-Álvarez, J. L. (2021). *Machine learning for risk assessment in gender-based crime* (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2106.11847>



- Google For Developers. (s. f.). *Clasificación: Exactitud, recuperación, precisión y métricas relacionadas | Machine Learning*. Google for Developers. Recuperado 3 de noviembre de 2024, de <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=es-419>
- Gustavo B. (2018, noviembre 16). *¿Qué es HTML? Explicación de los fundamentos del Lenguaje de marcado de hipertexto. Tutoriales Hostinger*.  
<https://www.hostinger.es/tutoriales/que-es-html>
- Haya, P. (2021, noviembre 29). *La metodología CRISP-DM en ciencia de datos—IIC. Instituto de Ingeniería del Conocimiento*.  
<https://www.iic.uam.es/innovacion/metodologia-crisp-dm-ciencia-de-datos/>
- INEC. (2019). *Violencia de Género*. <https://www.ecuadorencifras.gob.ec/violencia-de-genero/>
- IONOS. (2023, marzo 1). *¿Qué es Flask Python? Un breve tutorial sobre este microframework*. IONOS Digital Guide. <https://www.ionos.com/es-us/digitalguide/paginas-web/desarrollo-web/flask/>
- Jimenez Miguel. (2024). *Métricas para Evaluación de Modelos de Clasificación—Cursos documentation*.  
<https://migueljimenezg.github.io/cursos/AprenEst/Clasificaci%C3%B3n/M%C3%A9tricas/M%C3%A9tricas%20clasificaci%C3%B3n.html>
- Lagos, A. (2024, febrero 14). *Violetta, el chatbot con IA desarrollado por mexicanas para crear relaciones libres de violencia*. WIRED.  
<https://es.wired.com/articulos/violetta-el-chatbot-con-ia-desarrollado-por-mexicanas-para-crear-relaciones-libres-de-violencia>
- Ley Orgánica de Protección de Datos Personales, Pub. L. No. Art. 1 (2021).
- Ley Orgánica de Transparencia y Acceso a la Información Pública, Pub. L. No. Título I, Cáp. 1, Art. 1, 13 (2004).

Ley Orgánica de Transparencia y Acceso a la Información Pública, Pub. L. No. Título II, Cáp. 1, Art. 3, 13 (2004).

Ley Orgánica de Transparencia y Acceso a la Información Pública, Pub. L. No. Título III, Cáp. I, Art. 2, 13 (2004).

Ley Orgánica de Transparencia y Acceso a la Información Pública, Pub. L. No. Título III, Cáp. I, Art. 11, 13 (2004).

Lifeder. (2022, febrero 11). *Investigación empírica: Qué es, características, técnicas, tipos, ejemplos*. Lifeder. <https://www.lifeder.com/investigacion-empirica/>

Lima, V., & de Oliveira, J. A. (2024). *Identifying Risk Patterns in Brazilian Police Reports Preceding Femicides: A Long Short Term Memory (LSTM) Based Analysis* (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2401.12980>

Luna, L. L. (2021). *UNIVERSIDAD DE MURCIA ESCUELA INTERNACIONAL DE DOCTORADO*.

Luvini, P. S. (2024). *Herramientas de inteligencia artificial en la lucha contra la violencia de género digital: Un estudio con enfoque en el español rioplatense*. <https://repositorio.udes.edu.ar/items/bced2c64-f572-4ed2-8206-9e0925d02d84>

María José Moreno. (s. f.). *Resolver problemas de carácter social con «machine learning»* | *La Verdad* [La verdad]. La Verdad. Recuperado 7 de octubre de 2024, de <https://www.laverdad.es/ababol/ciencia/resolver-problemas-caracter-20221105004724-ntvo.html>

MathWorks. (s. f.). *Support Vector Machine (SVM)*. Recuperado 7 de octubre de 2024, de <https://www.mathworks.com/discovery/support-vector-machine.html>

Moreno, J. P. (2023). *Arquitectura de un sistema de ayuda a la prevención de casos de violencia de género en España*.

- Núñez Gómez, Patricia. (2021). Estudio de violencia de género en redes sociales. Prevención y formación para la igualdad. *Facultad de Ciencias de la Información, Universidad Complutense de Madrid*.
- OpenWebinars. (2023). *Datasets: Qué son y cómo acceder a ellos* | OpenWebinars. OpenWebinars.net. <https://openwebinars.net/blog/datasets-que-son-y-como-acceder-a-ellos/>
- Organización Mundial de la Salud. (2021). *Violencia contra la mujer*. <https://www.who.int/es/news-room/fact-sheets/detail/violence-against-women>
- Ortega, C. (2024, marzo 18). Modelos predictivo: De los datos a la toma de decisiones inteligente. *QuestionPro*. <https://www.questionpro.com/blog/es/modelos-predictivos/>
- Pablo Forni & Pablo De Grande. (2020, marzo). Triangulación y métodos mixtos en las ciencias sociales contemporáneas. *Revista mexicana de sociología*, 82(1).
- Paz y Desarrollo. (2022, agosto 31). *MURU: Mujeres Rurales Diversas y Gestión Local para erradicar las violencias basadas en género en 3 provincias de Ecuador – Paz y Desarrollo*. <https://www.pazydesarrollo.org/causes/programa-muru/>
- Pérez-Martínez, A., & Rodríguez-Fernández, A. (2024). La violencia contra la mujer, una revisión sistematizada. *Universitas*, 40, 139-158. <https://doi.org/10.17163/uni.n40.2024.06>
- Pinto-Muñoz, C.-C., Zuñiga-Samboni, J.-A., & Ordoñez-Erazo, H.-A. (2023a). Machine Learning Applied to Gender Violence: A Systematic Mapping Study. *Revista Facultad de Ingeniería*, 32(64), e15944. <https://doi.org/10.19053/01211129.v32.n64.2023.15944>
- Pinto-Muñoz, C.-C., Zuñiga-Samboni, J.-A., & Ordoñez-Erazo, H.-A. (2023b). Machine Learning Applied to Gender Violence: A Systematic Mapping Study. *Revista Facultad de Ingeniería*, 32(64), e15944. <https://doi.org/10.19053/01211129.v32.n64.2023.15944>

- Prieto Cruz, G. A., & Montoya Vasquez, E. E. (2020). Modelo de detección de violencia contra la mujer en redes sociales en español, utilizando opinion mining. *Universidad Tecnológica del Perú*.  
<http://repositorio.utp.edu.pe/handle/20.500.12867/3044>
- Psicología y Mente. (2017, febrero 11). *Los 7 tipos de violencia de género (y características)*. <https://psicologiymente.com/forense/tipos-violencia-de-genero>
- Ramirez, A. (2022, marzo 7). Recursos abiertos para combatir la violencia de género digital. *Abierto al público*. <https://blogs.iadb.org/conocimiento-abierto/es/combater-violencia-de-genero-digital/>
- Ramirez, D. (2024, septiembre 19). *Preguntas sobre el uso de tecnologías y machine learning en la lucha contra la violencia de género* [Audio].
- Ramírez, J. (2018, julio 19). Curvas PR y ROC. *Bluekiri*.  
<https://medium.com/bluekiri/curvas-pr-y-roc-1489fbd9a527>
- Reina Barreto, Johanna Alexandra, Rodríguez Martín, Vicenta, & Muñoz Macías, Noris Beatriz Juliana. (2021). Discursos culturales y mandatos de género sobre la violencia machista en Ecuador. *Revista de ciencias sociales*, 27(4), 131-148.
- Rivoir, A. L., & Morales, M. J. (Eds.). (2019). *Tecnologías digitales: Miradas críticas de la apropiación en América Latina*. CLACSO. <https://doi.org/10.2307/j.ctvt6rmh6>
- Rodriguez-Sanchez, F., Carrillo-de-Albornoz, J., & Plaza, L. (2020). Automatic Classification of Sexism in Social Networks: An Empirical Study on Twitter Data. *IEEE Access*, 8, 219563-219576.  
<https://doi.org/10.1109/ACCESS.2020.3042604>
- Roman, V. (2019, abril 29). Algoritmos Naive Bayes: Fundamentos e Implementación. *Ciencia y Datos*. <https://medium.com/datos-y-ciencia/algoritmos-naive-bayes-fundamentos-e-implementaci%C3%B3n-4bcb24b307f>

- San Martín Segura, D. (2023). Prevención algorítmica de la violencia de género: La discrecionalidad policial como decisión tecnológica en el contexto de VIOGÉN. *Estudios Penales y Criminológicos*, 1-35. <https://doi.org/10.15304/epc.44.9013>
- Santos, P. R. de los. (2021). *Cómo interpretar la matriz de confusión: Ejemplo práctico*. Telefónica Tech. <https://telefonicatech.com/blog/como-interpretar-la-matriz-de-confusion-ejemplo-practico>
- SAP. (s. f.). *Machine learning: El futuro de la inteligencia | Definición, tipos y ejemplos*. SAP. Recuperado 7 de octubre de 2024, de <https://www.sap.com/latinamerica/products/artificial-intelligence/what-is-machine-learning.html>
- Sarah Laoyan. (2024). *Scrumban: Lo mejor de dos metodologías ágiles [2024]* • Asana. Asana. <https://asana.com/es/resources/scrumban>
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- scikit-learn. (2019). 1.10. *Decision Trees*. Scikit-Learn. <https://scikit-learn/stable/modules/tree.html>
- Singh, K., Yamini Preethi, K., Vineeth Sai, K., & Modi, C. N. (2018). Designing an Efficient Framework for Violence Detection in Sensitive Areas using Computer Vision and Machine Learning Techniques. *2018 Tenth International Conference on Advanced Computing (ICoAC)*, 74-79. <https://doi.org/10.1109/ICoAC44903.2018.8939110>
- SMC España. (2023, diciembre 11). *Reacciones: Evalúan el impacto sobre la salud de la violencia contra las mujeres en la pareja y del abuso sexual infantil*. SMC España. <https://sciencemediacentre.es/reacciones-evaluan-el-impacto-sobre-la-salud-de-la-violencia-contra-las-mujeres-en-la-pareja-y-del>

- Timarán Pereira, S. R., Hernández Arteaga, I., Caicedo Zambrano, S. J., Hidalgo Troya, A., & Alvarado Pérez, J. C. (2016). *Descubrimiento de patrones de desempeño académico con árboles de decisión en las competencias genéricas de la formación profesional*. Universidad Cooperativa de Colombia.  
<https://doi.org/10.16925/9789587600490>
- UNDP. (2024). *Iniciativa EMonitor+ define sus alcances para operar en el país*. UNDP.  
<https://www.undp.org/es/bolivia/noticias/iniciativa-emonitor-define-sus-alcances-para-operar-en-el-pais>
- UNFPA Ecuador. (2023, junio 14). *La aplicación Junt@s responde a la violencia basada en género en Ecuador*. UNFPA-Ecuador.  
<https://ecuador.unfpa.org/es/news/la-aplicaci%C3%B3n-junts-responde-la-violencia-basada-en-g%C3%A9nero-en-ecuador>
- van Daalen, K. R., Kallesøe, S. S., Davey, F., Dada, S., Jung, L., Singh, L., Issa, R., Emilian, C. A., Kuhn, I., Keygnaert, I., & Nilsson, M. (2022). Extreme events and gender-based violence: A mixed-methods systematic review. *The Lancet Planetary Health*, 6(6), e504-e523. [https://doi.org/10.1016/S2542-5196\(22\)00088-2](https://doi.org/10.1016/S2542-5196(22)00088-2)
- Victor Nalda. (2020, septiembre 29). Machine Learning: Los orígenes y la evolución hasta la actualidad. *Future Space S.A.* <https://www.futurespace.es/machine-learning-los-origenes-y-la-evolucion/>
- Zhou, P., Ding, Q., Luo, H., & Hou, X. (2018). Violence detection in surveillance video using low-level features. *PLOS ONE*, 13(10), e0203668.  
<https://doi.org/10.1371/journal.pone.0203668>