

Artículo Original/Original Article

Violencia basada en género en Paraguay: selección de características y modelos predictivos

Gender-based violence in Paraguay: selected characteristics and predictive models

Federico Javier Beck



¹Universidad Nacional de Concepción. Concepción, Paraguay.

<https://orcid.org/0000-0002-2404-0651>

Autor correspondiente: beckfedericojavier@gmail.com

Agustina Alfonso González



¹Universidad Nacional de Concepción. Concepción, Paraguay.

<https://orcid.org/0009-0006-8625-0730>

Para citar este artículo:

Beck, F. J. y Alfonso González, A. (2025). Violencia basada en género en Paraguay: selección de características y modelos predictivos. *UCOM Scientia*,3(1), 60-84.

Fecha de recepción: 31/08/2024

Fecha de aceptación: 23/09/2025

Resumen

El presente estudio tiene como objetivo identificar las características que inciden en la violencia de género en Paraguay mediante el uso de algoritmos de machine learning. Utilizando datos de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP), se aplicaron varios modelos predictivos, incluyendo Random Forest y Regresión Logística, para analizar los factores asociados con la violencia de género. La metodología incluyó un riguroso preprocesamiento de datos y una cuidadosa selección de características para mejorar la precisión de los modelos. Los resultados destacaron la importancia de factores como la edad, el nivel de ingresos y las condiciones de la vivienda en la predicción de la violencia de género. El modelo Random Forest mostró un rendimiento superior al equilibrar precisión y capacidad de discriminación. Este estudio subraya la utilidad de los modelos predictivos en la formulación de políticas públicas, sugiriendo que su integración puede mejorar significativamente las estrategias de prevención y respuesta ante la violencia de género. Se recomienda la continuidad de investigaciones con modelos avanzados y técnicas de balanceo de datos para optimizar la identificación de factores de riesgo y fortalecer las políticas basadas en datos.

Palabras clave: Violencia de género, machine learning, modelos predictivos, políticas públicas, Paraguay.

Abstract

This study aims to identify the characteristics influencing gender-based violence in Paraguay using machine learning algorithms. Utilizing data from the National Survey on the Situation of Women in Paraguay (ENSIMUP), several predictive models, including Random Forest and Logistic Regression, were applied to analyze factors associated with gender-based violence. The methodology involved rigorous data preprocessing and careful feature selection to enhance model accuracy. The results highlighted the importance of factors such as age, income level, and housing conditions in predicting gender-based violence. The Random Forest model demonstrated superior performance by balancing precision and discriminatory capability. This study underscores the usefulness of predictive models in shaping public policies, suggesting that their integration can significantly improve strategies for preventing and responding to gender-based violence. Continued research with advanced models and data balancing techniques is recommended to optimize risk factor identification and strengthen data-driven policies.

Keywords: Gender-based violence, machine learning, predictive models, public policies, Paraguay.

1. Introducción

La violencia basada en género (VBG) constituye un problema social crítico que afecta a mujeres en todo el mundo, la misma se manifiesta en diversas formas, incluyendo violencia psicológica, física, sexual y/o económico-laboral. La violencia es prevenible y requiere un enfoque basado en datos para la formulación de políticas efectivas (World Health Organization, 2014). Para comprender mejor el significado, se debe conocer cuál es el concepto de violencia, a menudo no se considera adecuadamente en el ámbito de las políticas públicas debido a la falta de una definición clara del problema. Es un fenómeno complejo y difuso, donde las experiencias de las mujeres afectadas son cruciales para su comprensión y abordaje. La percepción de lo que constituye un daño y los comportamientos aceptables dependen de contextos culturales, lo que complica la formulación de políticas universales. Para desarrollar políticas efectivas, es esencial reconocer las características específicas de las mujeres violentadas, incluyendo su contexto socioeconómico, nivel educativo y antecedentes culturales, estos influyen en cómo experimentan la violencia (Escobar Manero, et al., 2024).

La Organización Mundial de la Salud define violencia como el uso intencional de fuerza física o poder, amenazado o real, contra uno mismo, contra otra persona o contra un grupo o comunidad, que resulta o tiene una alta probabilidad de resultar en lesión, muerte, daño psicológico, mal desarrollo o privación (Organización Mundial de la Salud [OMS], 2002). Otros autores, mencionan que la VBG es una manifestación de las desigualdades de poder entre géneros, influenciada por normas culturales y sociales (Heise, 1998). La teoría de la socialización de género sugiere que las expectativas sociales sobre los roles de género contribuyen a la perpetuación de la violencia (Connell, 2005). Por tanto, este estudio considera no solo factores individuales, sino también contextuales que pueden contribuir a la VBG. En Paraguay, la situación es alarmante, con un número significativo de mujeres que sufren diversas formas de violencia. La Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP) ofrece un conjunto de datos valioso para comprender este fenómeno en el contexto local, lo que puede permitir identificar patrones y factores de riesgo asociados con la VBG.

La Encuesta Nacional sobre Situación de las Mujeres en Paraguay 2021 (ENSIMUP) revela cifras preocupantes: 8 de cada 10 mujeres han experimentado algún tipo de violencia en su vida. Específicamente, la prevalencia de la violencia psicológica fue del 57.9%, la violencia física del 25.7%, la violencia sexual del 60.9% y la económica del 25%. Estas estadísticas no solo reflejan la gravedad del problema, sino que también resaltan la necesidad urgente de entender mejor

las dinámicas subyacentes a estos tipos de violencia. Por ende, el objetivo del estudio es analizar modelos comparativos de algoritmos predictivos en relación con la selección de características utilizando datos de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP) sobre violencia basada en género.

En este contexto, el presente estudio emplea técnicas avanzadas de machine learning aplicadas a los datos de la ENSIMUP para identificar las características específicas que inciden de manera significativa en la violencia basada en género. Al analizar estos datos detalladamente, se busca identificar características que permitan comprender qué factores socioeconómicos, educativos y demográficos están más estrechamente relacionados con la ocurrencia de violencia. Este enfoque no solo amplía nuestro conocimiento sobre los elementos que contribuyen a la violencia, sino que también proporciona una base sólida para el diseño de políticas públicas más efectivas y focalizadas. Al hacerlo, se busca equipar a los responsables de la formulación de políticas con herramientas analíticas precisas, que les permitan desarrollar estrategias de intervención más adecuadas a las necesidades específicas de las mujeres en distintos contextos, promoviendo así la reducción de la violencia y el fortalecimiento de sus derechos y seguridad.

2. Materiales y métodos

a. Uso de Machine Learning en la Predicción de la Violencia Basada en Género

El uso de machine learning ha emergido como una herramienta crucial en la predicción y análisis de la violencia basada en género, proporcionando la capacidad de manejar grandes volúmenes de datos y descubrir patrones complejos que no son evidentes mediante métodos tradicionales. Los métodos híbridos de machine learning han demostrado ser particularmente efectivos en la evaluación del riesgo de reincidencia en crímenes de género, mostrando que la combinación de modelos predictivos, como Random Forest y Nearest Centroid, mejora significativamente la precisión y la eficacia de las predicciones de riesgo, al tiempo que optimiza los recursos de protección policial (González-Prieto et al., 2023).

En un contexto similar, se han utilizado técnicas de machine learning para clasificar y predecir la vulnerabilidad socioeconómica en áreas rurales de Indonesia. Aunque estos estudios no se centraron exclusivamente en la violencia de género, los métodos y enfoques aplicados pueden ser utilizados para entender cómo los factores socioeconómicos y contextuales influyen en la vulnerabilidad a la violencia. La capacidad de estos modelos para manejar múltiples variables y su robustez en la clasificación los hace relevantes para la identificación de factores de riesgo en la violencia basada en género (Yuliawan et al., 2022).

Además, modelos de machine learning han sido utilizados para explorar los factores asociados con la violencia sexual en el contexto matrimonial, como en el caso de India. Las técnicas de regresión regularizada y redes neuronales han sido eficaces para identificar factores clave como la exposición previa a la violencia y el control por parte del esposo, proporcionando una comprensión detallada de las dinámicas subyacentes a la violencia de género. Estos enfoques son valiosos para identificar características específicas que inciden significativamente en la violencia de género y para desarrollar intervenciones dirigidas (McDougal et al., 2021).

Finalmente, se ha demostrado que los modelos predictivos pueden ser aplicados para predecir la violencia de género utilizando datos históricos. Estudios realizados en España utilizando algoritmos como Random Forest han mostrado cómo los datos pueden ser utilizados para prever la ocurrencia de violencia basada en género, facilitando la planificación de recursos y la implementación de políticas públicas efectivas (Rodríguez-Rodríguez et al., 2020).

b. Diseño del Estudio

Este estudio se basa en un análisis de datos secundarios provenientes de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP) del año 2021. Se realizó un enfoque descriptivo y comparativo para evaluar modelos predictivos sobre violencia basada en género.

c. Métodos de Análisis

- **Incorporación del Modelo CRISP-DM**

El CRISP-DM (Proceso Estándar de Minería de Datos para la Industria) es un enfoque ampliamente adoptado en el análisis de datos que proporciona una estructura clara para la ejecución de proyectos de minería de datos. Este modelo guía el proceso de análisis a través de seis fases fundamentales, permitiendo a los investigadores planificar, ejecutar y evaluar sus estudios de manera sistemática. La flexibilidad inherente del CRISP-DM facilita la adaptación a diferentes tipos de proyectos, especialmente aquellos que requieren iteraciones constantes para refinar resultados y enfoques (Marbn, Mariscal & Segovi, 2009).

En este estudio, el modelo CRISP-DM fue esencial para organizar el análisis de los datos provenientes de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP). Se inició con una comprensión profunda del problema de la violencia basada en género, definiendo objetivos específicos de predicción y análisis. Posteriormente, se llevó a cabo un proceso exhaustivo de comprensión y preparación de los datos, que incluyó la limpieza, normalización y selección de características clave.

Durante la fase de modelado, se implementaron algoritmos avanzados de machine learning, incluidos Random Forest, Support Vector Machine (SVM) y XGBoost, para desarrollar modelos predictivos. Estos modelos fueron evaluados cuidadosamente utilizando métricas de rendimiento como precisión, recall, F1-score y área bajo la curva ROC (ROC-AUC). Aunque no se completó la fase de despliegue, la evaluación realizada proporciona una base sólida para futuras implementaciones prácticas y políticas públicas.

d. Descripción del Dataset

- **Origen del Dataset**

El dataset utilizado en este estudio proviene de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP) 2021. Esta encuesta recopila información detallada sobre las experiencias de las mujeres en relación con diferentes tipos de violencia, así como sus características sociodemográficas y económicas. El objetivo de la encuesta es proporcionar una visión comprensiva de la prevalencia y los factores asociados con la violencia basada en género en Paraguay.

- **Tamaño y Estructura del Dataset**

El dataset contiene información de 3.276 mujeres, cada una representando un registro individual en el conjunto de datos. Cada registro contiene información relevante sobre las características personales, económicas y de experiencia de violencia de las encuestadas.

- **Variables**

Las variables de interés se clasifican en:

Demográficas: área, departamento, estado geográfico.

Socioeconómicas: edad, ingresos, condición del hogar¹, nivel educativo, situación laboral.

Experiencias de Violencia: en casos en donde la mujer haya sufrido algún tipo de violencia (psicológica, física, sexual o económico-laboral).

¹ El análisis estructural de la pobreza multidimensional indica que las variables de vivienda, como el estado del hogar y el hacinamiento, tienden a ser indicadores centrales dentro de la red de privaciones que conforman la pobreza en un contexto multidimensional (Beytía, 2017).

- **Selección de características**

Para identificar las características más relevantes, se utilizó un análisis de importancia de características basado en modelos de Random Forest. Las características seleccionadas incluyen variables socioeconómicas, educativas, demográficas, y de antecedentes de violencia previa.

e. Introducción a los Modelos Predictivos

Los modelos predictivos son herramientas fundamentales en el análisis de datos, especialmente en contextos complejos como la predicción de la violencia basada en género (VBG). Estos modelos permiten a los investigadores y responsables de políticas públicas identificar patrones y factores de riesgo asociados con la ocurrencia de violencia, basándose en datos históricos y características identificadas a través de encuestas y estudios. En el contexto de la VBG, los modelos predictivos ayudan a detectar casos potenciales de violencia y a comprender las dinámicas subyacentes que perpetúan estas conductas, facilitando la implementación de estrategias de prevención más efectivas.

f. Tipos de Modelos Predictivos Utilizados

En el estudio de la violencia basada en género (VBG), los modelos predictivos pueden clasificarse en dos categorías principales: modelos basados en reglas y modelos de aprendizaje automático. Los modelos basados en reglas son más sencillos y se construyen a partir de lógica predefinida de decisiones, lo que los hace menos flexibles, pero más interpretables. En contraste, los modelos de aprendizaje automático emplean algoritmos avanzados para detectar patrones complejos en grandes volúmenes de datos sin requerir intervención humana constante. Estos modelos han demostrado ser particularmente útiles en la predicción de fenómenos sociales complejos, como la VBG, debido a su capacidad para adaptarse y mejorar con la incorporación de nuevos datos (González-Prieto et al., 2023).

- **Regresión Logística**

La regresión logística es ampliamente reconocida como uno de los modelos más utilizados para problemas de clasificación binaria, especialmente en contextos donde se busca predecir la presencia o ausencia de un evento específico, como la violencia de género. Este modelo estadístico estima la probabilidad de que ocurra un evento basado en una o más variables independientes, lo que permite evaluar cómo diferentes factores afectan la probabilidad de que se produzca dicho evento (Hosmer, Lemeshow, & Sturdivant, 2013). En este estudio, la regresión logística se utilizó para evaluar cómo características sociodemográficas, tales como la

edad, nivel educativo e ingresos, influyen en la probabilidad de que una mujer experimente violencia. La capacidad del modelo para producir una interpretación probabilística de los resultados facilita su aplicación en la toma de decisiones informadas y en la formulación de políticas públicas dirigidas a la prevención de la violencia de género.

- **Árboles de Decisión**

Los árboles de decisión son modelos de clasificación y regresión que dividen iterativamente un conjunto de datos en subconjuntos más homogéneos utilizando criterios de división específicos basados en las características de los datos. Este enfoque no solo permite una visualización intuitiva del proceso de toma de decisiones, sino que también facilita la identificación de interacciones complejas entre las variables (González-Prieto et al., 2023). En el contexto de la VBG, los árboles de decisión ayudan a identificar umbrales específicos y puntos de corte en los cuales las características sociodemográficas cambian la probabilidad de violencia. Aunque los árboles de decisión son más propensos al sobreajuste, especialmente en su forma básica, su simplicidad y facilidad de interpretación los convierten en una herramienta útil para explorar las relaciones subyacentes en los datos.

- **Random Forest**

El modelo de Random Forest es una extensión de los árboles de decisión que mejora la precisión y la robustez al combinar los resultados de múltiples árboles de decisión entrenados en diferentes subconjuntos del mismo conjunto de datos. Este enfoque de ensamble, donde cada árbol en el bosque emite un voto y la clase con más votos se selecciona como la predicción final, reduce significativamente el riesgo de sobreajuste que a menudo afecta a los modelos de árboles de decisión individuales (Breiman, 2001). En la predicción de VBG, Random Forest ha demostrado ser particularmente efectivo debido a su capacidad para manejar datos de alta dimensionalidad y captar complejas interacciones entre las variables, lo que permite a los investigadores y formuladores de políticas identificar mejor los factores de riesgo de la violencia de género y diseñar intervenciones más efectivas (Rodríguez-Rodríguez et al., 2020).

- **Support Vector Machine (SVM)**

Las Support Vector Machines (SVM) son modelos de clasificación que buscan encontrar el hiperplano óptimo que separa las diferentes clases en un espacio de características. Este enfoque es especialmente útil en situaciones donde las clases no son linealmente separables, ya que SVM utiliza funciones de kernel para proyectar los datos en un espacio de mayor

dimensión donde las clases se vuelven separables (Goode, 1971). La capacidad de SVM para manejar espacios de alta dimensionalidad y proporcionar una separación clara entre las clases lo convierte en una opción valiosa para la predicción de VBG, especialmente en contextos donde las relaciones entre las variables son complejas y no lineales. Su aplicación en estudios de VBG ha demostrado ser efectiva, proporcionando una buena precisión y robustez en la clasificación de casos de violencia (Yuliawan et al., 2022).

- **XGBoost**

XGBoost es un algoritmo de boosting basado en árboles de decisión que ha ganado popularidad por su alto rendimiento y eficiencia computacional. Este modelo de ensamble mejora iterativamente los resultados de los árboles de decisión individuales al enfocarse en los errores de predicción de los modelos anteriores, ajustando las predicciones y mejorando la precisión general del modelo (Chen & Guestrin, 2016). En la investigación de VBG, XGBoost se destaca por su capacidad para manejar grandes volúmenes de datos, detectar patrones no lineales complejos y trabajar con datos faltantes y características irrelevantes. Estudios recientes han mostrado su efectividad en la identificación de factores de riesgo y la predicción de violencia de género, convirtiéndolo en una herramienta valiosa para los investigadores y formuladores de políticas que buscan aplicar enfoques de análisis de datos avanzados para abordar problemas sociales complejos (González-Prieto et al., 2023).

g. Aplicación de los Modelos Predictivos en el Estudio

En el análisis de la violencia basada en género (VBG) en Paraguay, se implementaron varios modelos predictivos utilizando datos de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP). Se seleccionaron modelos que no solo poseían alta capacidad de predicción, sino que también podían manejar la complejidad y la multifaceticidad intrínseca de la VBG. Los modelos elegidos incluyeron Regresión Logística, Árboles de Decisión, Random Forest, Support Vector Machine (SVM) y XGBoost. Cada uno de estos modelos ofrece ventajas únicas en la identificación de patrones complejos asociados con la violencia de género, proporcionando una visión integral de los factores que contribuyen a este fenómeno.

- **Preprocesamiento de Datos**

El preprocesamiento de datos es un paso crucial en el análisis predictivo para garantizar la calidad y la integridad de los datos utilizados. En este estudio, se trabajó con un conjunto de datos de 3,276 mujeres encuestadas. Originalmente, los datos incluían múltiples registros por

cada participante, lo que requería una estructuración adecuada para garantizar que cada fila del conjunto de datos representara los datos completos de una sola mujer encuestada. Este ajuste fue esencial para mantener la consistencia y precisión en el análisis. Las características utilizadas se centraron en aspectos demográficos (edad, estado civil), socioeconómicos (nivel de ingresos, empleo) y antecedentes de violencia previa. Este enfoque permitió una comprensión general de los factores que influyen en la VBG sin profundizar en los tipos específicos de violencia sufrida o las posibles causas y consecuencias, las cuales están presentes en la ENSIMUP, pero no se abordan en detalle en este estudio. Para futuras investigaciones, se sugiere explorar en profundidad estos aspectos específicos para obtener una visión más matizada de los factores de riesgo y las dinámicas subyacentes de la violencia de género. Durante el pre procesamiento, se prestó especial atención a la limpieza de datos y la imputación de valores faltantes de manera que no se alteraran los valores verdaderos de los datos, asegurando que los resultados fueran fieles a la realidad observada.

- **Selección de Características**

Antes de aplicar los modelos predictivos, se realizó un análisis exhaustivo de selección de características para identificar las variables más relevantes. Este proceso es crucial, ya que permite a los modelos centrarse en las variables que tienen un mayor impacto en la predicción, mejorando así la precisión y la interpretabilidad de los resultados. Se emplearon métodos como Random Forest para asignar un puntaje de importancia a cada característica, evaluando su contribución relativa a la predicción del modelo (Breiman, 2001). Las características seleccionadas incluyeron variables demográficas, socioeconómicas, educativas y antecedentes de violencia previa. Estas variables son fundamentales para entender los factores que influyen en la VBG y permiten a los modelos detectar patrones significativos asociados con el riesgo de violencia (Rodríguez-Rodríguez et al., 2020).

- **Entrenamiento y Validación de Modelos**

El entrenamiento y la validación de los modelos se llevaron a cabo utilizando un enfoque riguroso para garantizar la robustez y la generalización de los resultados. Los datos disponibles se dividieron en conjuntos de entrenamiento y prueba, donde los modelos se entrenaron utilizando el conjunto de entrenamiento y se evaluaron en el conjunto de prueba. Además, se empleó la validación cruzada, un método que consiste en dividir los datos en múltiples subconjuntos o folds. Cada modelo se entrena y evalúa iterativamente en estos subconjuntos, lo que proporciona una evaluación más precisa y confiable del rendimiento del modelo y minimiza el sesgo (Kohavi, 1995). Este proceso es fundamental para asegurar que los modelos

no solo se desempeñen bien en el conjunto de datos de entrenamiento, sino que también sean capaces de predecir con precisión en datos no vistos, reflejando así su capacidad para ser aplicados en escenarios reales.

- **Comparación de Modelos:**

La comparación de los diferentes modelos predictivos se basó en varias métricas de rendimiento, incluyendo la precisión, el recall, el F1-score y el área bajo la curva ROC (AUC). Estas métricas proporcionan una visión holística del rendimiento de cada modelo, permitiendo evaluar diferentes aspectos críticos de su capacidad predictiva. Por ejemplo, la precisión mide la proporción de predicciones correctas realizadas por el modelo, mientras que el recall evalúa la capacidad del modelo para identificar correctamente los casos de violencia, es decir, su sensibilidad. El F1-score combina ambas métricas en una medida equilibrada, siendo particularmente útil en escenarios donde existe un desbalance en las clases. Finalmente, el AUC proporciona una medida de la capacidad del modelo para discriminar entre casos de violencia y no violencia en un rango de umbrales de decisión (Fawcett, 2006). Modelos como Random Forest y XGBoost tienden a mostrar un rendimiento elevado en términos de AUC debido a su capacidad para manejar interacciones complejas entre las características y para evitar el sobreajuste (Chen & Guestrin, 2016).

- **Interpretación de Resultados**

La interpretación de los resultados de los modelos predictivos es crucial para traducir los hallazgos en recomendaciones de políticas efectivas. Cada modelo ofrece una perspectiva única sobre la detección de la violencia de género. Por ejemplo, un modelo con un alto recall, como puede ser el caso de SVM y Random Forest, es capaz de identificar la mayoría de los casos de violencia, lo cual es beneficioso en la creación de estrategias preventivas, aunque puede generar un mayor número de falsos positivos. Por otro lado, modelos como la Regresión Logística pueden proporcionar una mayor precisión, reduciendo los falsos positivos, pero podrían no detectar todos los casos de violencia, lo que puede ser un desafío en términos de intervención preventiva (McDougal et al., 2021). La capacidad de XGBoost para ajustar sus predicciones de manera iterativa lo convierte en una herramienta valiosa para equilibrar estos trade-offs y ofrecer predicciones más refinadas. Los responsables de políticas deben considerar estos trade-offs al utilizar modelos predictivos para diseñar estrategias de intervención, asegurando que las medidas preventivas sean tanto efectivas como eficientes en términos de recursos.

h. Evaluación del Rendimiento

- **Importancia de la Evaluación del Rendimiento en Modelos Predictivos**

La evaluación del rendimiento es una etapa crucial en el desarrollo de modelos predictivos, ya que proporciona una medida de la efectividad del modelo en la tarea para la cual fue diseñado. En el contexto de la violencia basada en género, la evaluación rigurosa del rendimiento de los modelos es esencial para garantizar que las predicciones sean precisas y útiles para la toma de decisiones políticas. La selección de métricas de evaluación adecuadas permite a los investigadores comparar diferentes modelos y elegir el más apropiado para su propósito específico.

- **Métricas Comunes para la Evaluación del Rendimiento**

Precisión (Accuracy)

La precisión es una métrica básica que indica la proporción de predicciones correctas realizadas por el modelo en relación con el total de predicciones. En el contexto de la VBG, la precisión muestra qué tan bien el modelo puede identificar tanto los casos de violencia (positivos) como los casos de no violencia (negativos). Sin embargo, en problemas de clasificación desbalanceados, como la VBG, la precisión puede ser engañosa, ya que un modelo que predice predominantemente la clase mayoritaria puede tener una alta precisión sin ser efectivo en identificar la clase minoritaria (Goutte & Gaussier, 2005).

Recall (Sensibilidad o Tasa de Verdaderos Positivos)

El recall mide la capacidad del modelo para identificar correctamente todos los casos positivos. En el contexto de la violencia de género, un alto recall significa que el modelo es efectivo para detectar la mayoría de los casos de violencia, lo cual es crucial para prevenir y mitigar los efectos de la violencia. Un modelo con bajo recall podría pasar por alto casos de violencia, lo que sería inaceptable en aplicaciones donde la seguridad y el bienestar de las personas están en juego (Powers, 2020).

Precision (Precisión de Clasificación Positiva)

La precisión mide la proporción de verdaderos positivos entre todas las predicciones positivas realizadas por el modelo. En términos simples, indica cuántas de las predicciones de violencia realizadas por el modelo son realmente casos de violencia. Esta métrica es importante para minimizar los falsos positivos, es decir, evitar clasificar como violencia situaciones que no lo son.



En el contexto de políticas públicas, un modelo con alta precisión puede ayudar a evitar la sobrecarga de los recursos de intervención y asegurar que se brinde apoyo a quienes realmente lo necesitan.

F1-Score

El F1-score es la media armónica de la precisión y el recall, proporcionando una métrica equilibrada que es útil cuando se busca un compromiso entre ambas. Un F1-score alto indica que el modelo tiene un buen equilibrio entre la precisión y la capacidad de detectar todos los casos positivos. Esta métrica es particularmente valiosa en contextos donde las clases están desbalanceadas y se desea minimizar tanto los falsos positivos como los falsos negativos (Sasaki, 2007).

Área Bajo la Curva ROC (AUC - Area Under the Curve)

El AUC es una métrica que evalúa la capacidad de un modelo para distinguir entre clases positivas y negativas a través de diferentes umbrales de clasificación. Un AUC cercano a 1 indica que el modelo tiene una excelente capacidad de discriminación, mientras que un AUC cercano a 0.5 sugiere que el modelo no es mejor que una predicción aleatoria. En la evaluación de modelos predictivos para la VBG, un alto AUC es deseable ya que indica que el modelo puede diferenciar eficazmente entre situaciones de violencia y no violencia, independientemente del umbral utilizado para la clasificación (Bradley, 1997).

Promedio de Precisión (AP - Average Precision)

AP es una métrica que resume la precisión en diferentes niveles de recall, proporcionando una visión completa del rendimiento del modelo en la clasificación positiva. Esta métrica es útil para evaluar cómo cambia la precisión del modelo cuando se ajustan los umbrales para maximizar el recall, especialmente en problemas de clasificación desbalanceada.

Importancia de Múltiples Métricas en la Evaluación

La evaluación del rendimiento de los modelos predictivos a través de múltiples métricas permite obtener una visión integral de su efectividad y adecuación para tareas específicas. En el caso de la violencia basada en género (VBG), donde las consecuencias de los errores de predicción pueden ser significativas y potencialmente perjudiciales, la utilización de varias métricas es esencial para asegurar que los modelos no solo son precisos, sino también sensibles a los casos de interés (Fawcett, 2006). La precisión y la capacidad de identificación precisa son

factores críticos, ya que un error en la clasificación podría significar la falta de intervención en casos de violencia o, inversamente, la movilización innecesaria de recursos para falsos positivos.

Precisión vs. Recall

La precisión y el recall son métricas fundamentales que proporcionan perspectivas diferentes pero complementarias sobre el rendimiento del modelo. La precisión se refiere a la proporción de verdaderos positivos sobre el total de predicciones positivas realizadas por el modelo. Un modelo con alta precisión minimiza los falsos positivos, lo cual es crucial en contextos donde los recursos son limitados y es importante evitar alarmas innecesarias (Goutte & Gaussier, 2005). Por otro lado, el recall, o sensibilidad, mide la capacidad del modelo para identificar correctamente todos los casos de interés, es decir, los verdaderos positivos. En situaciones donde es imperativo no perder ningún caso de violencia, como en la intervención temprana para prevenir daños mayores, un alto recall podría ser más valorado, incluso si eso significa un aumento en los falsos positivos (McDougal et al., 2021).

Equilibrio con F1-Score

El F1-score se utiliza comúnmente para encontrar un equilibrio entre precisión y recall, especialmente en problemas de clasificación donde existe un desbalance significativo entre las clases. Este puntaje combina ambos aspectos en una sola métrica, proporcionando una visión equilibrada del rendimiento del modelo. En el análisis de la VBG, un alto F1-score indica que el modelo no solo es preciso en sus predicciones, sino también efectivo en la identificación de casos de violencia. Este enfoque equilibrado es particularmente relevante en situaciones en las que tanto la identificación precisa de casos de violencia como la minimización de falsos positivos son importantes (González-Prieto et al., 2023).

Evaluación Agregada con AUC

El Área Bajo la Curva (AUC) de la curva ROC es una métrica agregada que proporciona una medida de la capacidad discriminatoria del modelo en un rango de umbrales de clasificación. El AUC es particularmente útil en el contexto de la VBG porque permite evaluar la robustez del modelo en la identificación de casos de violencia, independientemente del umbral específico elegido. Un AUC alto sugiere que el modelo tiene una fuerte capacidad para distinguir entre casos de violencia y no violencia, lo cual es esencial para la aplicación práctica en contextos de políticas públicas y programas de intervención (Fawcett, 2006; Rodríguez-Rodríguez et al., 2020). Esta métrica es fundamental cuando los responsables de políticas necesitan ajustar los

umbrales de decisión para responder a cambios en las prioridades o en la disponibilidad de recursos.

Aplicación Práctica de la Evaluación del Rendimiento

En la práctica, la evaluación del rendimiento de los modelos predictivos no se limita a la mera obtención de métricas, sino que también implica interpretar estos resultados en el contexto de los objetivos específicos de intervención y prevención de la violencia de género. Los responsables de políticas deben considerar cómo se utilizarán las predicciones del modelo y qué métricas son más relevantes para sus objetivos específicos. Por ejemplo, en un programa de intervención en violencia de género, podría ser preferible un modelo con un alto recall para asegurar que la mayoría de los casos de violencia se detecten, evitando así que situaciones de riesgo pasen desapercibidas. Sin embargo, si los recursos son limitados y es crucial evitar falsas alarmas, un modelo con alta precisión podría ser más adecuado para garantizar que los recursos se asignen solo a casos con alta probabilidad de violencia real (Chen & Guestrin, 2016; Yuliawan et al., 2022). En este sentido, la elección de la métrica de evaluación más adecuada dependerá de las prioridades y limitaciones específicas del contexto en el que se aplicarán los modelos predictivos.

- **Contribución de los Modelos Predictivos a las Políticas Públicas**

Los modelos predictivos han emergido como herramientas esenciales para la formulación y evaluación de políticas públicas, especialmente en el contexto de la violencia basada en género (VBG). Estos modelos permiten a los responsables de la formulación de políticas identificar patrones y factores de riesgo asociados con la violencia, facilitando el diseño de intervenciones más específicas y efectivas (González-Prieto et al., 2023). Al analizar grandes volúmenes de datos y detectar relaciones complejas entre variables, los modelos predictivos proporcionan una comprensión más profunda de los elementos subyacentes que contribuyen a la VBG.

Identificación de Factores de Riesgo y Diseño de Intervenciones

Uno de los beneficios clave de los modelos predictivos es su capacidad para identificar características sociodemográficas y contextuales que están fuertemente asociadas con la VBG. Por ejemplo, estudios previos han demostrado que variables como el nivel educativo, el estado civil y los ingresos económicos son determinantes significativos en la probabilidad de que una mujer experimente violencia (McDougal et al., 2021). Al entender qué características aumentan el riesgo de violencia, los responsables de políticas pueden desarrollar estrategias de intervención más focalizadas, dirigiendo recursos y programas hacia los grupos que presentan

mayores niveles de vulnerabilidad. Esto no solo optimiza la asignación de recursos, sino que también aumenta la eficacia de las políticas al reducir los casos de violencia de manera más significativa y sostenible (Rodríguez-Rodríguez et al., 2020).

Monitoreo y Evaluación de la Efectividad de Políticas:

Además de ayudar en el diseño de políticas, los modelos predictivos son herramientas valiosas para el monitoreo y la evaluación continua de la efectividad de las políticas implementadas. Comparando las predicciones del modelo con los datos reales de incidencia de violencia, los responsables de políticas pueden evaluar en tiempo real el impacto de sus estrategias y realizar ajustes cuando sea necesario (Chen & Guestrin, 2016). Esta capacidad de ajuste dinámico es esencial en un entorno donde las condiciones sociales y económicas pueden cambiar rápidamente, y donde la respuesta a la violencia de género debe ser tanto ágil como adaptable. Por ejemplo, si se observa un aumento en los casos de violencia en un grupo demográfico específico que no había sido previamente identificado como de alto riesgo, los modelos predictivos pueden alertar a los responsables de políticas para ajustar sus enfoques y medidas preventivas en consecuencia.

Prevención y Reducción de la Violencia:

El uso de modelos predictivos también facilita una orientación preventiva, ayudando a identificar patrones tempranos de violencia que pueden ser abordados antes de que se desarrollen en situaciones más graves. La implementación de políticas basadas en predicciones permite actuar con anticipación, desarrollando programas de educación, apoyo y prevención dirigidos a las comunidades más vulnerables (Yuliawan et al., 2022). Este enfoque proactivo no solo protege a las potenciales víctimas, sino que también contribuye a la creación de una sociedad más segura y equitativa.

3. Resultados

En esta sección se presentan los resultados obtenidos a partir del análisis de la importancia de las características en la predicción de la violencia basada en género utilizando modelos de machine learning. Las características identificadas reflejan los factores que más influyen en la ocurrencia de violencia en función de los datos recogidos. El modelo aplicado asignó un puntaje de importancia a cada característica, indicando su contribución relativa en la predicción de los casos de violencia.

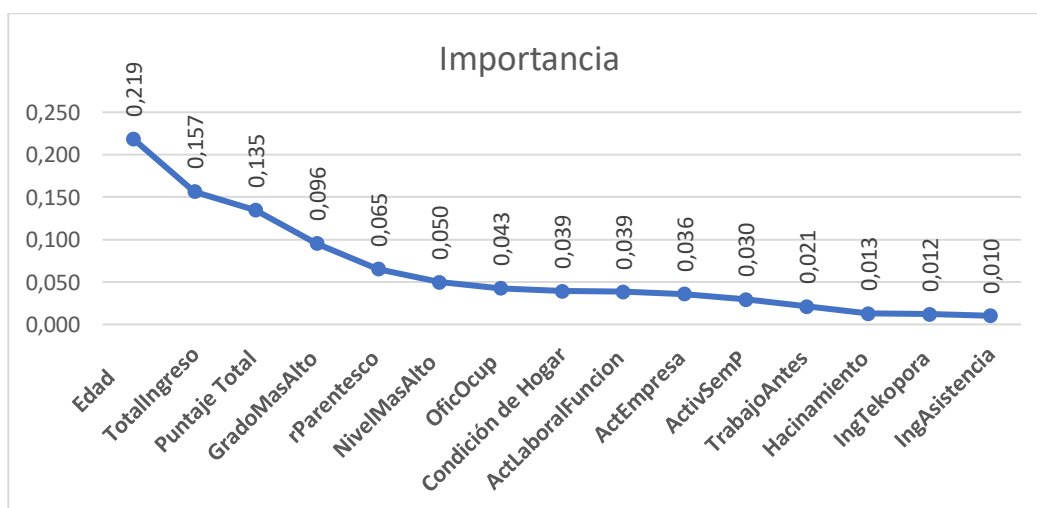
3.1 Importancia de las Características en la Predicción de Violencia Basada en Género

Tabla 1. Importancia de características

Características	Importancia
Edad	0.219
TotalIngreso	0.157
Puntaje Total	0.135
GradoMasAlto	0.096
rParentesco	0.065
NivelMasAlto	0.050
OficOcup	0.043
Condición de Hogar	0.039
ActLaboralFuncion	0.039
ActEmpresa	0.036
ActivSemp	0.030
TrabajoAntes	0.021
Hacinamiento	0.013
IngTekopora	0.012
IngAsistencia	0.010

Fuente: Elaboración propia (2024)

Figura 1. Importancia de características



Fuente: Elaboración propia (2024)



La característica más influyente identificada en el modelo fue la *Edad*, con un puntaje de importancia de 0.219, lo que sugiere que la edad de una mujer es un factor significativo en la predicción de la violencia de género. *TotalIngreso*, que mide el nivel de ingresos totales de la persona, y Puntaje Total, que refleja la suma de indicadores relacionados con las condiciones de la vivienda, también mostraron una alta relevancia, con puntajes de 0.157 y 0.135, respectivamente.

Otras características que demostraron ser importantes incluyeron el *GradoMasAlto* y *NivMasAlto* alcanzado, que indica el nivel educativo de la mujer, y *rParentesco*, que evalúa la relación de parentesco con el jefe del hogar. Estas características sugieren que tanto los factores socioeconómicos como los contextos familiares tienen un papel fundamental en la probabilidad de que una mujer experimente violencia de género.

3.2 Desempeño de Modelos de Clasificación

En este estudio, se evaluó el desempeño de varios modelos de clasificación para predecir la violencia basada en género. La Tabla 2 presenta un resumen de las métricas de desempeño utilizadas para comparar estos modelos: precisión (accuracy), precisión de clasificación positiva (76precisión), sensibilidad (recall), F1 Score, área bajo la curva ROC (AUC), y promedio de precisión (AP).

Tabla 2. Desempeño de los modelos de clasificación

Modelo	Accuracy	Precision	Recall	F1 Score	AUC	AP
Regresión Logística						
Random Forest	0.865	0.865	1	0.927	0.52	0.14
Decision Tree	0.858	0.865	0.989	0.923	0.59	0.17
XBoost	0.757	0.869	0.846	0.857	0.51	0.14
SVM	0.848	0.863	0.98	0.918	0.56	0.16
	0.864	0.867	0.994	0.926	0.54	0.17

Fuente: Elaboración propia (2024)

3.2.1 Análisis de Modelos de Machine Learning etiquetados para la Predicción de la Violencia Contra la Mujer

Este análisis compara cinco modelos de machine learning utilizados para predecir la violencia contra la mujer: Regresión Logística, Random Forest, Árbol de Decisión, XGBoost y Support Vector Machine (SVM). Los modelos se evaluaron utilizando las siguientes métricas: Accuracy (precisión general), Precision (precisión de clasificación positiva), Recall (sensibilidad), F1 Score,

AUC (Área bajo la curva ROC) y AP (Promedio de Precisión). Estas métricas proporcionan una visión integral del rendimiento de cada modelo en la tarea de predicción.

3.2.1.1 Regresión Logística

La regresión logística mostró un rendimiento notable con un accuracy de 0.865, lo que indica que el 86.5% de las predicciones realizadas por el modelo son correctas. Este modelo tiene una precisión de 0.865, lo que sugiere que, cuando predice un caso de violencia, es correcto el 86.5% de las veces. Destaca su recall perfecto (1.000), lo que significa que no dejó de identificar ningún caso de violencia. Este alto recall es crucial para aplicaciones donde la detección de todos los casos de violencia es una prioridad. El F1 Score de 0.927 refleja un buen equilibrio entre precisión y recall, haciendo de este modelo una opción robusta para identificar casos de violencia sin incurrir en muchos falsos positivos.

Sin embargo, la regresión logística muestra un AUC de solo 0.52, indicando una capacidad limitada para discriminar entre casos de violencia y no violencia. Esto sugiere que, si bien el modelo detecta correctamente los casos de violencia, no es mucho mejor que el azar en distinguir entre los dos tipos de casos en una gama de umbrales de decisión. El AP de 0.14 es bajo, indicando que la precisión a través de diferentes umbrales de decisión no es óptima, lo que podría limitar su utilidad en contextos donde se requieren ajustes finos en la toma de decisiones.

3.2.1.2 Random Forest

El modelo de Random Forest también tuvo un rendimiento alto, con un accuracy de 0.858, ligeramente inferior al de la regresión logística. Mantiene una precisión similar de 0.865, lo que indica un buen manejo de falsos positivos. Su recall de 0.989 es muy cercano al perfecto, lo que sugiere que es altamente efectivo para capturar casos de violencia, con solo una pequeña cantidad de casos pasados por alto. El F1 Score de 0.923 es similar al de la regresión logística, sugiriendo un buen equilibrio general.

Random Forest se distingue en su AUC de 0.59, que es superior a la de la regresión logística, indicando una mejor capacidad de discriminación. Esto sugiere que Random Forest es más efectivo en la diferenciación entre casos de violencia y no violencia en un rango de umbrales. Su AP de 0.17 también es más alto, lo que implica un mejor rendimiento en términos de precisión a través de diferentes niveles de recall. Estos resultados hacen de Random Forest una opción sólida para la predicción de violencia contra la mujer, especialmente cuando se requiere un equilibrio entre detección y minimización de falsos positivos.

3.2.1.3 Árbol de Decisión

El Árbol de Decisión mostró el rendimiento más bajo entre los modelos evaluados. Con un accuracy de 0.757, es evidente que comete más errores en comparación con los otros modelos. Aunque tiene una precisión de 0.869, lo que es comparable a los otros modelos, su recall de 0.846 es significativamente más bajo, lo que indica que el modelo pierde más casos de violencia. El F1 Score de 0.857 refleja esta disminución en la capacidad de equilibrio entre precisión y recall.

El AUC de 0.51 es apenas mejor que el azar, lo que sugiere una capacidad de discriminación pobre. Su AP de 0.14 es similar al de la regresión logística, lo que indica problemas en mantener la precisión en diferentes umbrales de decisión. Estos resultados sugieren que el Árbol de Decisión puede no ser adecuado para tareas complejas de predicción de violencia contra la mujer, donde se requiere una alta precisión y sensibilidad.

3.2.1.4 XGBoost (XBoost)

XGBoost mostró un rendimiento competitivo, con un accuracy de 0.848, un poco inferior al de la regresión logística y Random Forest. Tiene una precisión de 0.863 y un recall de 0.980, lo que sugiere que XGBoost es efectivo en identificar la mayoría de los casos de violencia con un número relativamente bajo de falsos positivos. El F1 Score de 0.918 muestra un buen equilibrio entre la capacidad de detectar casos de violencia y minimizar falsos positivos.

El AUC de 0.56 sugiere una capacidad de discriminación razonable, mejor que la de la regresión logística pero no tan alta como la de Random Forest. Su AP de 0.16 es también decente, lo que indica un buen rendimiento en términos de precisión a través de diferentes niveles de recall. Estos resultados hacen que XGBoost sea una opción viable para la predicción de violencia, especialmente si se requieren modelos que puedan ajustar finamente los umbrales de decisión.

3.2.1.5 Support Vector Machine (SVM)

El modelo SVM tuvo un accuracy de 0.864, muy cercano al de la regresión logística. Con una precisión de 0.867 y un recall de 0.994, SVM muestra una fuerte capacidad para detectar casi todos los casos de violencia, con un bajo número de falsos positivos. Su F1 Score de 0.926 refleja un excelente equilibrio entre precisión y recall.

El AUC de 0.54 indica una capacidad de discriminación razonable, aunque no tan alta como la de Random Forest. Sin embargo, el AP de 0.17 es igual al de Random Forest, lo que sugiere que SVM también maneja bien la precisión en diferentes umbrales de decisión. Estos resultados sugieren que SVM es un modelo eficaz para la predicción de violencia contra la mujer, ofreciendo un buen equilibrio entre precisión y capacidad de discriminación.

4. Discusión

El análisis de modelos predictivos utilizando los datos de la Encuesta Nacional sobre Situación de las Mujeres en Paraguay (ENSIMUP) ha revelado una serie de hallazgos clave que son fundamentales para comprender y abordar la violencia de género en el contexto paraguayo. La implementación de algoritmos de Machine learning para predecir la violencia de género no solo mejora nuestra comprensión de los factores asociados con este fenómeno, sino que también proporciona una base sólida para el diseño de políticas públicas más eficaces y basadas en datos.

4.1 Importancia de la Selección de Características

La selección de características ha demostrado ser crucial para la precisión y eficacia de los modelos predictivos. En este estudio, se ha identificado que variables como la edad, el nivel de ingresos, y las condiciones de vivienda son factores significativos en la predicción de violencia de género. La identificación de estas características resalta la importancia de enfoques integrales en políticas y programas de intervención que aborden estos factores de manera específica para reducir la incidencia de violencia. Además, las relaciones familiares saludables y las mejoras en las condiciones de vida se identifican como estrategias clave para la reducción de la violencia de género, lo que se alinea con las recomendaciones de organismos internacionales como la ONU (Organización de las Naciones Unidas Mujeres, 2017).

4.2 Comparación con Estudios Previos

Los resultados del presente estudio subrayan la importancia de las características sociodemográficas y socioeconómicas en la predicción de la violencia basada en género, lo cual es consistente con hallazgos de investigaciones anteriores. La identificación de la Edad como el factor más influyente en la predicción de violencia se alinea con los estudios de McDougal et al. (2021), quienes también encontraron que las mujeres jóvenes son más vulnerables a la violencia de género. Este patrón podría deberse a la mayor exposición de las mujeres jóvenes a dinámicas de poder desiguales y a entornos de trabajo y sociales menos estables.

La relevancia del TotalIngreso y del Puntaje Total en la predicción de la violencia destaca la relación entre la estabilidad económica y las condiciones de vida, y la vulnerabilidad a la violencia. González-Prieto et al. (2023) también identificaron que las condiciones socioeconómicas desempeñan un papel crucial en la evaluación del riesgo de crímenes de género, sugiriendo que mujeres en situaciones de pobreza o con inestabilidad económica tienen menos recursos para escapar o denunciar situaciones de violencia.



El nivel educativo (GradoMasAlto y NivMasAlto) también mostró una influencia significativa, lo cual refuerza la idea de que la educación es un factor protector contra la violencia de género. Las mujeres con mayor nivel educativo pueden tener más acceso a recursos de apoyo y ser más conscientes de sus derechos, lo que reduce su vulnerabilidad a la violencia. Este hallazgo concuerda con los resultados de estudios previos que destacan la educación como un medio para empoderar a las mujeres y reducir su exposición a la violencia (Rodríguez-Rodríguez et al., 2020).

La importancia de rParentesco refleja cómo las dinámicas familiares y la relación con el jefe de hogar pueden influir en la ocurrencia de violencia. En contextos donde las estructuras familiares son más rígidas o autoritarias, la violencia puede ser más prevalente. Este resultado subraya la necesidad de políticas que promuevan entornos familiares saludables y de apoyo como una estrategia para reducir la violencia de género.

Estos resultados reflejan que, la capacidad de los modelos predictivos para identificar y clasificar correctamente los casos de violencia sugiere que estos modelos pueden ser herramientas valiosas para la formulación de políticas públicas. Como sugieren Yuliawan et al. (2022), el uso de técnicas avanzadas de Machine Learning permite a los responsables de la formulación de políticas adaptar sus estrategias basadas en datos reales y en la identificación de grupos de alto riesgo. Esto permite una asignación más efectiva de los recursos y el diseño de intervenciones específicas que pueden reducir la incidencia de violencia de manera más eficaz.

4.3 Implicaciones para la política y la práctica

Los resultados de este estudio sugieren que las políticas enfocadas en mejorar el nivel de ingresos, la educación, las condiciones de vivienda y la promoción de relaciones familiares saludables pueden ser eficaces en la prevención de la violencia de género. Las mujeres con menor nivel educativo y menores ingresos son más vulnerables a la violencia debido a la dependencia económica y la falta de autonomía (Becker, 1975; Vyas & Watts, 2009). Mejorar las condiciones de vivienda puede reducir el estrés y los conflictos, lo que disminuye el riesgo de violencia (Sadownik, 2023). La implementación de modelos predictivos como Random Forest en políticas públicas podría aumentar significativamente la capacidad de las autoridades para identificar y responder a situaciones de violencia de género. Se recomienda que las estrategias de prevención incluyan programas de capacitación laboral, subsidios para la mejora de vivienda y campañas educativas sobre relaciones saludables, dirigidas a los grupos más vulnerables.

4.4 Comparación de Modelos Predictivos

Los modelos de Regresión Logística, Random Forest y SVM muestran un rendimiento destacado en la predicción de la violencia contra la mujer. La Regresión Logística y SVM ofrecen un recall casi perfecto, lo que es crucial para no dejar pasar casos de violencia. Random Forest, por su parte, muestra la mejor capacidad de discriminación (AUC) y rendimiento en precisión (AP), haciéndolo una opción robusta para aplicaciones donde la diferenciación entre casos es crucial. XGBoost ofrece un buen equilibrio entre estas métricas y puede ser una alternativa sólida. El Árbol de Decisión, en cambio, muestra limitaciones en su capacidad para manejar la complejidad de los datos, lo que sugiere que no es la mejor opción para este tipo de predicciones. Estos resultados proporcionan una base sólida para seleccionar y ajustar modelos predictivos en la lucha contra la violencia de género, dependiendo de las necesidades específicas de precisión, recall y capacidad de discriminación.

4.5 Impacto del CRISP-DM en los Resultados del Estudio

La adopción del modelo CRISP-DM como marco metodológico para esta investigación fue fundamental para estructurar y guiar todo el proceso de análisis de datos. Este enfoque permitió una comprensión sistemática de los factores de riesgo asociados con la violencia de género y facilitó el desarrollo de modelos predictivos precisos y efectivos. Los modelos, como Random Forest, que se beneficiaron de la estructura proporcionada por CRISP-DM, demostraron una mayor precisión en la identificación de casos de violencia. Estos resultados subrayan la importancia de utilizar marcos metodológicos sólidos para organizar el análisis y mejorar la calidad y aplicabilidad de los resultados obtenidos.

5. Conclusiones

Este estudio ha demostrado que la aplicación de algoritmos de Machine learning es una herramienta eficaz para identificar las características que inciden en la violencia de género en Paraguay. Los resultados indican que modelos como Random Forest y Regresión Logística son particularmente efectivos para predecir casos de violencia de género, debido a su capacidad para manejar múltiples variables y ofrecer predicciones precisas. El modelo Random Forest, en particular, se destacó por su capacidad de equilibrar la precisión con la capacidad de discriminación, lo que sugiere su gran potencial para ser utilizado en la implementación de políticas públicas orientadas a la prevención de la violencia de género.

Los hallazgos subrayan la importancia de una selección cuidadosa de características en el proceso de modelado, lo cual permite identificar los factores de riesgo más significativos, como la edad, el nivel de ingresos y las condiciones de la vivienda, mejorando así la efectividad

predictiva de los modelos. Además, se reconoce la necesidad de incorporar técnicas de balanceo de datos en futuras investigaciones, para abordar la desproporción existente entre los casos de violencia y no violencia en los datos, que puede afectar el rendimiento de los modelos.

Adicionalmente, el uso de técnicas avanzadas de preprocesamiento de datos y la optimización continua de los hiperparámetros de los modelos podrían contribuir a mejorar aún más la precisión y la capacidad de generalización de estos modelos predictivos. La implementación de estos enfoques en las políticas públicas de Paraguay podría reforzar significativamente la capacidad del país para enfrentar el problema de la violencia de género, proporcionando una base sólida para el desarrollo de intervenciones preventivas más efectivas y focalizadas.

Se recomienda que las futuras investigaciones sigan explorando la aplicación de modelos avanzados de machine learning en diversos contextos. La integración de estas herramientas en las estrategias nacionales de prevención de la violencia no solo mejoraría la capacidad de respuesta ante la violencia de género, sino que también fortalecería la formulación de políticas informadas y basadas en datos, facilitando una toma de decisiones más eficaz y eficiente. Esto permitiría optimizar los recursos disponibles y maximizar el impacto de las intervenciones, contribuyendo así a la construcción de una sociedad más segura y equitativa.

6. Declaración de financiamiento

La presente investigación se llevó a cabo con financiación propia.

7. Declaración de conflictos de intereses

Los autores declaran no tener conflictos de intereses.

8. Declaración de autores

Los autores aprueban la versión final del artículo.

9. Contribución de los autores

Autor	Contribución
Federico Javier Beck	Participación importante en la selección del tema, en la redacción de introducción, diseño de la metodología, elaboración de tablas y su explicación, discusión, conclusión del borrador y versión final.
Agustina Alfonso González	Participación importante en la selección del tema, en la redacción de introducción, diseño de la metodología,



elaboración de tablas y su explicación, discusión, conclusión del borrador y versión final.

10. Referencias Bibliográficas

- Becker, G. S. (1975). *Human capital: A theoretical and empirical analysis, with special reference to education*. Midway Reprint.
- Beytía, P. (2017). La estructura interna de la pobreza multidimensional. En *Los invisibles: Por qué la pobreza y la exclusión social dejaron de ser prioridad* (pp. 71–88). Instituto de Estudios de la Sociedad.
- Bradley, Andrew P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/s0031-3203\(96\)00142-2](https://doi.org/10.1016/s0031-3203(96)00142-2)
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Connell, R. W. (2005). *Masculinities*. University of California Press.
- Escobar Manero, E. (2024). *Salud y Género*. Observatorio de Salud Estudio de Comunicación.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.
- González-Prieto, Á., Brú, A., Nuño, J. C., & González-Álvarez, J. L. (2023). Hybrid machine learning methods for risk assessment in gender-based crime. *Knowledge-Based Systems*, 260, 110130. <https://doi.org/10.1016/j.knosys.2022.110130>
- Goode, William J. (1971). Force and Violence in the Family. *Journal of marriage and the family*, 33(4), 624. <https://doi.org/10.2307/349435>
- Goutte, C., & Gaussier, E. (2005). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. *European Conference on Information Retrieval*, 345–359.
- Heise, L. L. (1998). Gender-based violence: An overview of the issues. *Reproductive Health Matters*, 6(11), 6–13.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. Wiley. <https://doi.org/10.1002/9781118548387>
- Kohavi, R. (1995). *A study of cross-validation and bootstrap for accuracy estimation and model selection*. <https://www.ijcai.org/Proceedings/95-2/Papers/016.pdf>
- Marbn, S., Mariscal, G., & Segovi, J. (2009). A data mining & knowledge discovery process model. En J. Ponce & A. Karahoc (Eds.), *Data Mining and Knowledge Discovery in Real Life Applications*. I-Tech Education and Publishing. <https://doi.org/10.5772/6438>
- McDougal, L., Dehingia, N., Bhan, N., Singh, A., McAuley, J., & Raj, A. (2021). Opening closed doors: Using machine learning to explore factors associated with marital sexual violence in a cross-sectional study from India. *BMJ Open*, 11(12), e053603. <https://doi.org/10.1136/bmjopen-2021-053603>



- Organización de las Naciones Unidas Mujeres. (2017). *El empoderamiento económico de la mujer en el mundo del trabajo*. <https://www.unwomen.org/sites/default/files/Headquarters/Attachments/Sections/CSW/61/CSW-Conclusions-61-SP-WEB.pdf>
- Organización Mundial de la Salud. (2002). *Informe mundial sobre la violencia y la salud: resumen*. https://iris.who.int/bitstream/handle/10665/43431/9275324220_spa.pdf
- Powers, D. M. W. (2020). *Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation*. <https://doi.org/10.48550/ARXIV.2010.16061>
- Rodríguez-Rodríguez, I., Rodríguez, J.-V., Pardo-Quiles, D.-J., Heras-González, P., & Chatzigiannakis, I. (2020). Modeling and forecasting gender-based violence through machine learning techniques. *Applied Sciences*, 10(22), 8244. <https://doi.org/10.3390/app10228244>
- Sadownik, A. R. (2023). Bronfenbrenner: Ecology of human development in ecology of collaboration. En *International Perspectives on Early Childhood Education and Development* (pp. 83–95). Springer International Publishing.
- Sasaki, M. (2007). *Morphogenesis of Flux Structure*. AA Publications
- Tan, P. N., Steinbach, M., Karpatne, A., & Kumar, V. (2019). *Introduction to Data Mining*. 2da ed. Pearson Education.
- Vyas, S., & Watts, C. (2009). How does economic empowerment affect women's risk of intimate partner violence in low and middle income countries? A systematic review of published evidence. *Journal of International Development*, 21(5), 577-602. <https://doi.org/10.1002/jid.1500>
- World Health Organization. (2014). *Informe sobre la situación mundial de la prevención de la violencia 2014*. <https://www.who.int/publications/i/item/9789241564793>
- Yuliawan, D., Hakim, D. B., Juanda, B., & Fauzi, A. (2022). Integrated rural socio-economic vulnerability analysis in Lampung Province. *Jurnal Perspektif Pembiayaan dan Pembangunan Daerah*, 10(3), 175-188. <https://doi.org/10.22437/ppd.v10i3.17591>