



CARRERA: ESPECIALIZACIÓN EN CIENCIA DE DATOS

TRABAJO FINAL INTEGRADOR

**VIOLENCIA DOMÉSTICA EN ARGENTINA: UN MODELO DE
EVALUACIÓN DE RIESGOS APLICANDO TÉCNICAS DE
MACHINE LEARNING**

Autora: Lic. Marina Clur

Título de grado: Licenciada en Sociología (UBA)

Tutora:

Lic. Valeria Soliani

Ciudad de Buenos Aires, Marzo 2022

Índice

Abstract	3
Introducción	4
Estado de la Cuestión (Antecedentes/ Estado del Arte/ Marco Teórico/ Conceptual)	4
Definición del Problema	9
Justificación del trabajo	9
Alcances del trabajo y limitaciones	9
Hipótesis	10
Objetivos	11
Objetivo general	11
Objetivos específicos	11
Metodología	11
Técnicas	12
Herramientas	13
Resultados	15
Análisis exploratorio y creación de variables	15
Primeras aproximaciones	19
Desarrollo de la solución: riesgo altísimo + alto	21
Principales hallazgos y conclusiones	27
Anexo	30
Referencias-Bibliografía	32

Abstract

En el presente trabajo se analizan las características de las personas que sufren episodios de violencia doméstica o de género en base a las denuncias realizadas entre el 2017 y 2020 en Argentina. El principal objetivo consistió en desarrollar un modelo predictivo que permita definir de forma sistemática el nivel de riesgo al que están expuestas las personas que denuncian dichos episodios utilizando los datos que son relevados al momento de la denuncia y el nivel de riesgo evaluado por los profesionales del organismo que toma dichas denuncias. Actualmente no existe en Argentina una técnica sistemática para la valoración del riesgo o grado de peligro en el que se encuentran las personas que sufren violencia doméstica al momento de realizar la denuncia.

Como resultado, se observa que existen ciertos factores de riesgo o variables (cantidad y tipos de violencia denunciados, frecuencia de los episodios, edad de la víctima, género del agresor, entre otros) que inciden en la evaluación profesional del riesgo alto, posibilitando el desarrollo de un modelo predictivo que determine el riesgo de manera sistemática con una asertividad aceptable ($AUC = 0.82$). Por otra parte, se encontraron dificultades y limitaciones al buscar predecir el riesgo altísimo, el valor más alto de la escala. Esto se vincula a la naturaleza social y subjetiva de los datos, por lo cual no fue posible predecirlo con los datos relevados durante la denuncia.

1. Introducción

La violencia doméstica hacia las mujeres es considerada la violación a los derechos humanos más frecuente y generalizada en el mundo. Es un problema público global y estructural, formado por varias dimensiones: sociales, culturales, políticas y económicas. En los últimos años, movimientos sociales feministas colocaron esta problemática en la agenda global, cobrando relevancia pública. En este marco, el derecho internacional avanzó en la definición de protocolos y herramientas jurídicas para la protección de las mujeres ante los distintos tipos de violencia.

En Argentina, a pesar que se diseñaron e implementaron políticas públicas que involucran a los distintos poderes del estado, los femicidios se mantienen estables entre 2017 y 2020. De acuerdo al Registro de Femicidios de la Corte Suprema de Justicia de la Nación (CSJN, 2020) la tasa de víctimas directas de femicidio cada 100.000 mujeres pasa de 1.11 en 2017 a 1.14 en 2018, desciende a 1.10 en 2019 y a 1.09 en 2020. El 69% de las víctimas de femicidio eran pareja, ex pareja o familiares directos de sus agresores. Por otra parte, el 15% había realizado denuncias formales por episodios de violencia con anterioridad. En este sentido, son necesarias mejores y más eficientes políticas públicas de prevención y atención a personas que sufren situaciones de violencia doméstica. Se vuelve necesario unificar los criterios y protocolos de actuación frente a las denuncias de violencia doméstica. Por otra parte, se vislumbra la oportunidad de aplicar técnicas y herramientas tecnológicas para una mejor comprensión del fenómeno y para el desarrollo de mecanismos de prevención más robustos y veloces.

2. Estado de la Cuestión (Antecedentes/ Estado del Arte/ Marco Teórico/ Conceptual)

De acuerdo al trabajo de Flury, Nyberg y Riecher-Rössler (2010), la violencia doméstica es definida como la amenaza, ya sea de episodios de violencia física, psicológica, emocional o económica, con la intención de infligir un daño o ejercer poder sobre la persona afectada y en la que el agresor pertenece al entorno doméstico de la víctima, ya sea pareja, ex pareja, familiar, amigo o conocido. No refiere a un episodio de violencia puntual sino a un complejo sistema de abusos que puede incluir tanto violencia física como psicológica o sexual. Las víctimas de violencia doméstica son principalmente mujeres, siendo esta la forma más común de violencia de género, y es experimentada por entre el 10% y el 35% de las mujeres en algún momento de sus vidas. Si bien es un fenómeno muy generalizado, todavía es un problema tabú y no todas las mujeres que pasan por estas situaciones se animan a compartir sus problemas y buscar ayuda. Por este motivo es fundamental trabajar, por un lado, en políticas públicas de concientización para visibilizar el problema, disminuir los comportamientos violentos y aumentar los pedidos de ayuda, y por el otro la identificación de factores de riesgo y metodologías de valoración de riesgos para la prevención de la violencia.

Los distintos tipos de violencia que conforman la violencia doméstica son:

- “Violencia física: La que se emplea contra el cuerpo de la mujer produciendo dolor, daño o riesgo de producirlo y cualquier otra forma de maltrato agresión que afecte su integridad física.
- Violencia psicológica: La que causa daño emocional y disminución de la autoestima o perjudica y perturba el pleno desarrollo personal o que busca degradar o controlar sus acciones, comportamientos, creencias y decisiones, mediante amenaza, acoso, hostigamiento, restricción, humillación, deshonra, descrédito, manipulación aislamiento. Incluye también la culpabilización, vigilancia constante, exigencia de obediencia sumisión, coerción verbal, persecución, insulto, indiferencia, abandono, celos excesivos, chantaje, ridiculización, explotación y limitación del derecho de circulación o cualquier otro medio que cause perjuicio a su salud psicológica y a la autodeterminación.
- Violencia económica patrimonial: La que se dirige a ocasionar un menoscabo en los recursos económicos o patrimoniales de la mujer, a través de:
 - o La perturbación de la posesión, tenencia o propiedad de sus bienes;
 - o La pérdida, sustracción, destrucción, retención o distracción indebida de objetos, instrumentos de trabajo, documentos personales, bienes, valores y derechos patrimoniales;
 - o La limitación de los recursos económicos destinados a satisfacer sus necesidades o privación de los medios indispensables para vivir una vida digna;
 - o La limitación o control de sus ingresos, así como la percepción de un salario menor por igual tarea, dentro de un mismo lugar de trabajo.
- Violencia sexual: Cualquier acción que implique la vulneración en todas sus formas, con o sin acceso genital, del derecho de la mujer de decidir voluntariamente acerca de su vida sexual o reproductiva a través de amenazas, coerción, uso de la fuerza o intimidación, incluyendo la violación dentro del matrimonio o de otras relaciones vinculares o de parentesco, exista o no convivencia, así como la prostitución forzada, explotación, esclavitud, acoso, abuso sexual y trata de mujeres.
- Violencia simbólica: La que, a través de patrones estereotipados, mensajes, valores, íconos o signos transmita y reproduzca dominación, desigualdad y discriminación en las relaciones sociales, naturalizando la subordinación de la mujer en la sociedad.” (Ley 26.485, 2009: art. 5).
- Violencia ambiental: “Consiste en daños a objetos pertenecientes a la víctima u otros objetos de su entorno (por ejemplo, rotura de puertas, muebles, electrodomésticos, elementos personales, etc).
- Violencia social: Aquella en la que el agresor limita los contactos sociales y familiares de la víctima, aislándola de su entorno y limitando así un apoyo social de mucha importancia en estos casos” (INDEC, 2019: 35).

La valoración del riesgo de los episodios de violencia doméstica es un tema que tiene varias aristas y definiciones. Kropp (2008) menciona que no existe consenso respecto del concepto de riesgo de violencia doméstica dado que, si bien muchos lo entienden como la probabilidad de que exista violencia a futuro, la complejidad del fenómeno obliga a considerar la naturaleza de este y los distintos tipos de violencia (física, psicológica, económica, etc.) para la definición del riesgo. Otro aspecto es la naturaleza cambiante del riesgo de violencia debido a que los factores de riesgo también se modifican con el tiempo. Además, Kropp (2008) describe tres modelos de evaluación de riesgos: toma de decisiones clínicas no estructuradas, toma de decisiones actuariales y juicio profesional estructurado. El primero refiere a la evaluación clínica del profesional que atiende el caso de acuerdo con su experiencia y calificación profesional, sin un marco predefinido. Si bien es el modelo más utilizado, el mismo carece de validez y confiabilidad. Los modelos actuariales de evaluación de riesgos buscan predecir comportamientos específicos en determinados periodos de tiempo. El método consiste en predecir la violencia en dos sentidos: relativo, es decir comparando un individuo con un grupo de referencia basado en normas, y absoluto, es decir realizando una estimación probabilística de violencia futura. Este enfoque, si bien cuenta con mayor confiabilidad y validez estadística, es criticado por carecer de una evaluación profesional en la definición del riesgo de cada caso. Por último, el juicio profesional estructurado intenta cerrar la brecha entre los dos enfoques anteriores. En este caso, el profesional realiza la evaluación de acuerdo con pautas definidas que se enmarcan en conocimientos teóricos y empíricos.

Existen varios instrumentos de evaluación de riesgo basados en cuestionarios con escalas de peligrosidad, evaluación de factores de riesgo predefinidos, frecuencia de los episodios entre otros indicadores, que son ampliamente utilizados (Kropp, 2008). En torno a estas temáticas se encuentra la discusión académica sobre la evaluación de modelos de riesgo y su capacidad predictiva.

Según Dutton (2000), en el ámbito de la psiquiatría forense existe consenso sobre los principales factores que inciden al momento de evaluar o predecir el riesgo de violencia. Ellos son el historial de comportamiento agresivo, comportamientos y actitudes antisociales, estabilidad de las relaciones personales, estabilidad del empleo, salud mental y desorden de personalidad, historia de abusos en edad infantil y comportamientos que tienden al maltrato hacia las mujeres. En base a estos factores de riesgo se elaboran una serie de instrumentos o escalas que buscan determinar el riesgo de violencia. De acuerdo con Dutton (2000), las principales herramientas son:

- Danger Assessment (DA): es una herramienta basada en la percepción de las mujeres del riesgo de ser asesinadas por sus parejas. En otras palabras, se fundamenta en el miedo que las mujeres les tienen a sus parejas y su propia valoración del riesgo en que se encuentran.
- Spousal Assault Risk Assessment (SARA): es un conjunto de pautas predefinidas que incluyen entrevistas con el acusado y la víctima, indicadores de abuso físico y

emocional, indicadores de consumo de alcohol y drogas y la revisión de otros registros como ser reportes policiales, declaraciones, antecedentes penales y otras evaluaciones psicológicas. En base a toda la información relevada se define un sistema de scoring con el fin de identificar si la víctima del caso analizado se encuentra en inminente peligro.

- Propensity for Abusiveness Scale (PAS): es un desarrollo exhaustivo que busca determinar la propensión de los hombres a comportarse violentamente. Involucra factores más generales de la historia del agresor como ser la relación con sus padres y las características de su vínculo, la respuesta ante la ira, síntomas de traumas y el concepto de sí mismo. La herramienta se centra en el prevenir abusos psicológicos y emocionales, buscando determinar la propensión del comportamiento abusivo de los hombres. No es un buen predictor de la violencia física.

Siguiendo el trabajo de Van der Put et al. (2019), las herramientas de evaluación de riesgos de violencia doméstica tienen una capacidad predictiva moderada, con un efecto medio significativo ($AUC = 0.647$). Además, se destaca la superioridad científica de las técnicas de juicio profesional estructurado combinado con técnicas actuariales por sobre la valoración clínica no estructurada. Las principales limitaciones que se encuentran en este tipo de instrumentos son por un lado los tiempos que conlleva realizar estas evaluaciones a víctimas y agresores. Por otra parte, se necesita una estrategia definida y unificada de recolección y disponibilidad de los datos para poder analizarlos en conjunto, cruzando información de cuestionarios realizados a víctimas y agresores, antecedentes penales de los agresores, declaraciones e indicadores socioeconómicos.

Aun siendo necesario el criterio profesional para la evaluación, los tiempos y mecanismos que representan realizar las evaluaciones no va de la mano con el volumen de llamadas y pedidos de asistencia ni con la urgencia que pueden tener los casos de mayor riesgo. En este sentido, la aplicación de técnicas de machine learning a problemáticas de violencia doméstica surge en los últimos años como una forma de acelerar los tiempos de la evaluación de riesgos de manera que con una llamada se puedan priorizar y atender los casos con mayor riesgo. Con este fin, Grogger, Ivandic y Kirchmaier (2020) realizaron un estudio comparativo de la capacidad predictiva de las herramientas tradicionales de evaluación de riesgos vs modelos basados en técnicas de machine learning. Utilizando datos de llamadas por violencia doméstica, respuestas a un cuestionario DASH (Domestic, Abuse, Stalking and Harassment Honor-Based Violence, un cuestionario de 27 preguntas utilizado en Gran Bretaña para evaluación de riesgos) y variables del historial criminal del agresor, el objetivo del trabajo es predecir la reincidencia de un acto violento denunciado. Los autores concluyen que las técnicas de machine learning aplicadas a la evaluación de riesgos de violencia doméstica producen mejores resultados que los métodos de evaluación tradicionales. También resaltan los buenos resultados que obtuvieron al aplicar métodos de machine learning a datos de historial criminal y antecedentes penales, lo cual serviría para definir un primer modelo de riesgo basado en el agresor y que, al momento de la llamada de asistencia e identificación del agresor, se obtenga un primer score de prioridad. Un segundo modelo basado en el cuestionario DASH sería necesario debido a que con el primer

modelo obtuvieron un alto número de falsos positivos. Este procedimiento de dos pasos sería la solución propuesta para la evaluación de riesgo y priorización de llamadas para proveer atención y protección a potenciales víctimas.

Por otra parte, el trabajo de Berk, Sorenson y Barnes (2016) tiene por objetivo pronosticar la reincidencia de personas que enfrentan cargos por violencia doméstica al momento de la evaluación de riesgo y peligrosidad futura, para su liberación. Los autores utilizan datos del historial criminal de los agresores y con técnicas de machine learning (específicamente Random Forest) buscan determinar la probabilidad de reincidencia en los próximos años. Según las estadísticas el 20% de los individuos liberados después de la lectura de cargos por violencia doméstica, son arrestados con el mismo cargo en los siguientes dos años. En cambio, si se liberaran solo a las personas que el modelo indica que no van a reincidir, entonces el número bajaría al 10%.

Adicionalmente, en España la Secretaría de Estado de Seguridad del Ministerio de Interior junto con SAS y su programa Data4Good actualmente están desarrollando un sistema que ayuda a predecir las agresiones y a mejorar la protección de las víctimas de violencia doméstica. Con datos relevados de las denuncias por violencia de género combinados con indicadores socioeconómicos del núcleo familiar del agresor y de la víctima la empresa desarrolló un software que permite predecir las agresiones reincidentes (Granados, 2021).

En Argentina, la Oficina de Violencia Doméstica (OVD) creada en 2006 por la Corte Suprema de la Nación es la encargada de realizar las evaluaciones de riesgo de las personas que denuncian episodios de violencia doméstica. La OVD recibe tanto presentaciones espontáneas de personas que se acercan a la institución como casos derivados de comisarías, hospitales y ONGs. En una entrevista con la persona afectada, los profesionales de la OVD realizan una evaluación de riesgos y elaboran un informe con el objetivo de proceder a la derivación correspondiente (OVD, 2021). Esta metodología de evaluación de riesgos implica una serie de problemas:

- No todas las personas víctimas de violencia que efectúan un primer llamado solicitando asistencia completan el proceso de denuncia ante la OVD, por lo cual no todos los llamados culminan en una evaluación de riesgo efectuada por profesionales.
- Para quienes completan la denuncia y la entrevista de evaluación de riesgo, los tiempos pueden ser más largos que la urgencia que requiere la denuncia.
- El análisis de riesgo se realiza por cada denuncia, siendo poco eficiente si una persona realiza más de una denuncia.
- Al depender del criterio profesional con el que se analiza cada caso puntualmente, se gana un entendimiento minucioso de los hechos, pero se pierde eficiencia, por ejemplo, ante un incremento en el volumen de denuncias.

En base a lo anterior, el trabajo busca responder la siguiente pregunta: ¿es posible agilizar este proceso y que con algunas preguntas se pueda definir rápidamente el riesgo para poder

priorizar los casos más urgentes, pudiendo analizar todos los casos, ya sean llamadas o denuncias?

3. Definición del Problema

En Argentina los movimientos feministas han logrado visibilizar y poner en escena la problemática de la violencia doméstica. En los últimos años se llevaron a cabo campañas de concientización y se crearon distintos canales (líneas telefónicas, comisarías de la mujer, oficinas públicas, etc.) para que las personas que sufren de violencia doméstica denuncien estos episodios de manera que se puedan proteger y prevenir una escalada de violencia. Durante el 2020 fue creado el Sistema Único de Registro de Denuncias por Violencia de Género (URGE) con el fin de definir protocolos de actuación policial para recibir, registrar y valorar el riesgo de las denuncias por violencia de género. En este marco, la resolución 408/2020 establece la prioridad de crear una escala única de valoración de riesgos.

En este contexto, actualmente no existe una técnica sistemática para la valoración de riesgo o grado de peligro en el que se encuentran las personas que sufren violencia doméstica al momento de realizar la denuncia o solicitar asistencia en los canales correspondientes.

4. Justificación del trabajo

La falta de políticas públicas sistémicas para prevenir casos de violencia doméstica y femicidios en Argentina justifica la realización del presente trabajo. En función del alto número de femicidios y los organismos que se han creado en los últimos años para atender los casos de violencia doméstica, se propone un modo de sistematizar y unificar los criterios de la evaluación del riesgo. A partir de la distribución y aplicación de un modelo que determine el riesgo a las denuncias se podrá intervenir en la prevención del femicidio.

El presente trabajo se ubica en un contexto de proliferación de diversos organismos, tanto estatales como no gubernamentales, dependientes de distintos poderes o que responden a distintas jurisdicciones, que trabajan para la prevención de la violencia de género. Sin embargo, el tratamiento de la información y los criterios de evaluación de las denuncias se encuentran descentralizados, dependiendo de las comisarías locales o instituciones que toman las denuncias en cada jurisdicción.

5. Alcances del trabajo y limitaciones

El alcance del trabajo es aportar conocimiento para el desarrollo de una herramienta que permita asignar, de manera sistemática, el grado de peligro en el que se encuentran las víctimas de violencia doméstica. Los resultados tienen por objetivo evaluar si es viable o no aplicar

técnicas de machine learning a los datos disponibles sobre denuncias por violencia doméstica en Argentina para poder implementarlo en un sistema único de registro de denuncias.

De ser posible el desarrollo de dicha herramienta, esta podría ser utilizada por las comisarías locales, los organismos dependientes del Poder Judicial como las Oficina de Violencia Doméstica, los organismos de gobiernos provinciales que se ocupan de las problemáticas de violencia de género y las dependencias del Ministerio de las Mujeres, Géneros y Diversidad de la Nación. La posibilidad de unificar y sistematizar el ingreso, registro y evaluación de las denuncias o llamadas de ayuda por episodios de violencia doméstica beneficiaría a todos los organismos públicos y no gubernamentales que tratan con dicha problemática. De todas maneras, para la distribución de dicha herramienta sería necesario en primer lugar sistematizar, digitalizar y unificar el tratamiento de la información en los distintos niveles y jurisdicciones (comisarías, juzgados, gobiernos provinciales, etc.).

La principal limitación del trabajo son los datos disponibles. Si bien los datos de las denuncias por violencia doméstica de 2017 a 2020 se encuentran publicados (<http://datos.csjn.gov.ar/dataset/violencia-domestica>), estos datos refieren a lo que declaran las personas agredidas al momento de la denuncia. Para el trabajo no se cuenta con datos de antecedentes penales de los agresores ni información adicional que podría combinarse con los datos de denuncias para el desarrollo de un modelo más robusto.

6. Hipótesis

La evaluación del nivel de riesgo de violencia en el momento de la denuncia depende de un conjunto de criterios estandarizados que son evaluados subjetivamente por el funcionario que toma la denuncia y realiza la evaluación profesional. De esta manera sería posible predecir el nivel de riesgo de futuras denuncias en función de los datos y preguntas relevadas en el momento de la denuncia con el fin de agilizar los tiempos de evaluación, aumentar el volumen de casos analizados y priorizar los de mayor riesgo.

Al trabajar con datos públicos de denuncias de violencia doméstica, las variables disponibles son:

Variable dependiente o a predecir:

- Evaluación del nivel de riesgo de la denuncia efectuada por los equipos interdisciplinarios de la OVD (altísimo, alto, medio, moderado, bajo).

Variables independientes o predictoras:

- ID persona, ID legajo
- Año, mes y canal de ingreso de la denuncia

- Datos sociodemográficos de la persona afectada: sexo, edad, nacionalidad, provincia, barrio, comuna, localidad, nivel de instrucción, condición de actividad, categoría ocupacional, discapacidad
- Vínculo entre la persona afectada y la persona denunciada
- Cohabitación de la persona afectada con la persona denunciada
- Frecuencia de los episodios de violencia
- Tipos de violencia denunciados: física, psicológica, económica, social, sexual, ambiental, simbólica
- Datos de la persona denunciada: sexo, edad, condición de actividad, nivel de instrucción
- Derivación: si hubo derivación a la Justicia Nacional en lo Civil, a la Justicia Penal, Asesoramiento Jurídico, al sistema de salud, a la Dirección General de la Mujer, al Consejo de Derechos de Niñas, Niños y Adolescentes, a una instancia no judicial, a la Justicia Provincial, etc.

7. Objetivos

7.1. Objetivo general:

El objetivo del presente trabajo es desarrollar un modelo predictivo que permita definir de forma sistemática el nivel de riesgo o grado de peligro en el que se encuentran las personas que denuncian ser víctimas de violencia doméstica, con la finalidad de priorizar las denuncias con mayor riesgo y que puedan ser atendidas con mayor rapidez.

7.2. Objetivos específicos:

- Describir las características de las denuncias por violencia doméstica realizadas en los últimos años (2017-2020).
- Analizar qué variables inciden en la determinación del nivel de riesgo efectuada por el criterio profesional.
- Evaluar distintas técnicas y algoritmos para el desarrollo del modelo.
- Asignar un valor de criticidad para la definición del riesgo o grado de peligrosidad (alto, medio, bajo).
- Evaluar y proponer otras variables formadas con las variables y datos disponibles que mejoren la efectividad del modelo.

8. Metodología

Se trabajó con los datos abiertos de la OVD (2017-2020) que se encuentran disponibles en <http://datos.csjn.gov.ar/dataset/violencia-domestica>. Por cada presentación atendida la OVD confecciona un legajo digital en el cual se indican los datos de las personas afectadas y las

personas denunciadas, los indicadores con los que se realiza la evaluación de riesgo, las derivaciones y otros datos. Los datos disponibles corresponden a las personas afectadas que son atendidas por profesionales de la OVD en Argentina entre 2017 y 2020. En cada fila se identifica una persona y se incluyen datos sociodemográficos de la misma y de la persona denunciada principal, características de los hechos de violencia, el riesgo evaluado por los equipos de la oficina y las derivaciones realizadas. También se incluye un ID para cada persona y otro ID para cada legajo (dentro de un mismo legajo puede haber más de una persona afectada).

8.1. Técnicas

Para el presente trabajo se utilizó la metodología “CRISP-DM” (del inglés Cross Industry Standard Process for Data Mining). Esta metodología describe seis etapas del ciclo de vida de los proyectos de data mining, a saber:

- Definición de necesidades y comprensión del problema
- Estudio y comprensión de los datos
- Análisis de los datos y selección de características
- Modelado de datos
- Evaluación de resultados
- Despliegue y puesta en producción

Una vez definida la necesidad de predecir el riesgo de las denuncias de violencia doméstica, se realizó un análisis exploratorio de los datos con el fin de estandarizar y limpiar los datos que se encuentran en distintos formatos: se igualó la cantidad de columnas de los datasets de cada año, se igualaron los nombres de las variables y los valores que presentaban diferencias, y se unificaron los cuatro datasets en uno único. A continuación (Tabla 1) se observan las principales variables del dataset original, la cantidad de datos no nulos, el tipo de variable y una breve descripción de la variable. La descripción completa del dataset se encuentra en Anexo.

Tabla 1: Principales variables (OVD, 2017-2020)

#	Variable	Datos	Tipo	Descripción
15	NIVEL_INSTRUCCION	55.369	Ordinal	Nivel de instrucción de la persona afectada
16	CONDICION_ACTIVIDAD	55.696	Nominal	Condición de actividad de la persona afectada
20	RELACION_AFECTADA_DENUNCIADA	55.838	Nominal	Vínculo entre la persona afectada y la persona denunciada
21	COHABITAN	55.776	Nominal	Indica si la persona afectada y la denunciada cohabitan o cohabitaron hasta una semana previa a la denuncia
22	FRECUENCIA_EPISODIOS	55.838	Ordinal	Indica la frecuencia de los episodios de violencia
23	V_FISICA	55.838	Nominal	Indica si se registró violencia física en la presentación
24	V_PSIC	55.838	Nominal	Indica si se registró violencia psicológica en la presentación
25	V_ECON	55.838	Nominal	Indica si se registró violencia económico patrimonial en la presentación

26	V_SEX	55.838	Nominal	Indica si se registró violencia sexual en la presentación
27	V_SOC	55.838	Nominal	Indica si se registró violencia social en la presentación
28	V_AMB	55.838	Nominal	Indica si se registró violencia ambiental en la presentación
29	V_SIMB	55.838	Nominal	Indica si se registró violencia simbólica en la presentación
30	EVALUACION_RIESGO	55.838	Ordinal	Indica la evaluación de riesgo efectuada por los Equipos Interdisciplinarios de la OVD

Luego, se analizaron los datos faltantes para evaluar la posibilidad de imputarlos en función de otras variables o excluir la variable del dataset final. Se utilizó la *EDAD* de la persona afectada para imputar como “Infancia” en los datos faltantes de *NIVEL_INSTRUCCIÓN* o *CONDICIÓN_ACTIVIDAD*. Por otra parte, se excluyeron las variables que solamente contenían datos para el año 2020 y aquellas que indican la derivación del caso; al ser variables que temporalmente son posteriores a la evaluación del riesgo no sería metodológicamente correcto utilizarlas para entrenar el modelo. Finalmente, se preparó el dataset para poder aplicar algoritmos de machine learning: las variables nominales se llevaron a numéricas (*dummies*), a las variables ordinales categóricas se les asignó un valor numérico, se crearon nuevos features (*feature engineering*) en base a las variables existentes y se definieron cuáles serían las variables predictoras y cuál la variable a predecir.

8.2. Herramientas

Se trabajó en el desarrollo de un modelo de aprendizaje supervisado de clasificación, con la finalidad de predecir las denuncias por episodios de violencia con un nivel de riesgo alto. Para lograr el mejor resultado, se utilizaron y evaluaron distintos algoritmos de clasificación. Como ejercicio inicial se utilizaron árboles de decisión. Luego se utilizaron algoritmos regresión logística, de ensemble como Random Forest y Gradient Boosting y redes neuronales. Todo el trabajo fue realizado en Python utilizando los algoritmos de la librería Scikit-learn.

Como primera iteración se utilizó el algoritmo Árbol de decisión (Decision Tree) para visualizar las principales variables que inciden en la clasificación aprovechando su fácil interpretación y velocidad de procesamiento. Los árboles de decisión se componen de nodos, ramas y hojas. Cada nodo representa un atributo, las ramas representan una regla o una decisión y las hojas el resultado de estas reglas. En otras palabras, los árboles de decisión intentan agrupar y etiquetar las observaciones que son similares entre ellos y buscan las mejores reglas que dividen las observaciones que son diferentes entre ellos hasta que alcanzan cierto grado de similitud. Sin embargo difícilmente se logren los mejores resultados utilizando solamente árboles de decisión.


El segundo método utilizado fue Random Forest que, como su nombre indica, consiste en muchos árboles de decisión individuales que operan en conjunto (ensemble). Cada árbol que compone el bosque devuelve una predicción de clase y la clase con más votos se convierte en la predicción del modelo. La razón por la cual este algoritmo suele funcionar mejor que los árboles

de decisión se debe a que una gran cantidad de modelos aleatorios no correlacionados que funcionan en conjunto superan a cualquiera de los modelos individuales que lo componen. El algoritmo de Gradient Boosting es otro tipo de ensemble con el cual, a diferencia del Random Forest, los predictores no se crean de forma independiente sino secuencialmente. Esta técnica de *ensemble* del Random Forest es llamada *bagging*, mientras que en Gradient Boosting se la llama *boosting*. En esta última, los predictores aprenden de los errores de los predictores anteriores por lo cual las observaciones tienen distinta probabilidad de aparecer en iteraciones posteriores en tanto que las que tienen mayor error aparecen más. El riesgo en este tipo de modelos si no se define bien cuándo detener las iteraciones es el sobreajuste (*overfitting*).

La regresión logística busca determinar la probabilidad de ocurrencia de un hecho (0,1) en función del impacto que tiene cada una de las variables explicativas en la probabilidad de que ocurra el suceso en estudio. Cuando la variable dependiente es dicotómica la recta de regresión lineal es corregida con la función logística. En otras palabras, la regresión logística equivaldría a una regresión lineal corregida por la función logística cuando la variable a predecir es la probabilidad de ocurrencia de un hecho. Por último, se utilizó un algoritmo de redes neuronales: MLPClassifier que significa Multi-Layer Perceptron Classifier. Las redes neuronales buscan imitar el funcionamiento de las neuronas de los organismos vivos: un conjunto de neuronas conectadas entre sí y que trabajan en conjunto, sin que haya una tarea concreta para cada una. Con la experiencia, las neuronas van creando y reforzando ciertas conexiones para aprender algo que queda fijo en el tejido. Las redes neuronales son un modelo para encontrar la combinación de parámetros que mejor predice un resultado y aplicarla al mismo tiempo.

Para definir los hiperparámetros óptimos de cada modelo se utilizó el algoritmo GridSearchCV. Este algoritmo realiza una búsqueda exhaustiva entre una lista de parámetros predefinidos y todas sus posibles combinaciones para optimizar una métrica definida. A su vez realiza validación cruzada (*Cross Validation*), es decir que entrena y valida el modelo en distintos cortes o datasets de entrenamiento y testeo para evitar posibles sesgos.

Para evaluar los resultados obtenidos con los distintos métodos se utilizó la matriz de confusión (*Confusion Matrix*) y las métricas *precision* y *recall*. La matriz de confusión permite visualizar el desempeño de un algoritmo de aprendizaje supervisado. En las columnas de la matriz se ubican las predicciones de cada clase del dataset de testeo mientras que en las filas se colocan los valores reales de cada clase. En este sentido, la matriz nos permite ver qué tipo de aciertos y errores presenta el modelo. El objetivo último es que el modelo acierte bien tanto los casos positivos como los casos negativos pero esto es difícil de conseguir con modelos de aprendizaje automático. Por este motivo, para evaluar la performance de los distintos modelos se utilizan la *precision* y el *recall*.



La *precision* indica qué tan preciso es el modelo al predecir los valores de la clase minoritaria, en nuestro caso el riesgo alto. Se calcula tomando los casos que se aciertan (TP) sobre el total de casos predichos como positivos (TP+FP). El *recall* o sensibilidad indica qué tan bien predice los casos positivos (TP) del total de casos positivos reales (TP+FN). En un problema como el que aborda el presente trabajo, el *recall* es la métrica más importante dado que en caso de obtener una gran cantidad de falsos negativos, concretamente implicaría muchos casos de alto riesgo de violencia que no serían identificados.

9. Resultados

9.1. Análisis exploratorio y creación de variables

Para una mejor comprensión y entendimiento de las denuncias por violencia doméstica que son registradas por la OVD, se llevó a cabo un análisis exploratorio de los datos. En primer lugar se analizaron las frecuencias de todas las variables para tener una primera aproximación a los datos, estudiar la oportunidad de agrupar categorías y definir el tratamiento de las variables dummies.


Tabla 2: Tabla de frecuencias de las principales variables

VARIABLE	CATEGORÍA	FRE. ABS.	FRE. REL.
SEXO	FEMENINO	42.474	76,1%
	MASCULINO	13.364	23,9%
DOMICILIO_PROVINCIA	CIUDAD DE BS. AS.	50.669	90,7%
	BUENOS AIRES	3.244	5,8%
	OTRAS	1.925	3,4%
COHABITAN	NO	34.081	61,0%
	SI	21.695	38,9%


FRECUENCIA_EPISODIOS	SEMANAL	19.332	34,6%
	DIARIO	13.676	24,5%
	ESPORÁDICO	10.982	19,7%
	MENSUAL	3.997	7,2%
	QUINCENAL	3.452	6,2%
	PRIMER EPISODIO	2.699	4,8%
	NO CORRESPONDE	1.700	3,0%
V_AMB	NO	37.377	66,9%
	SI	18.461	33,1%
V_ECON	NO	38.778	69,4%
	SI	17.060	30,6%
V_FISICA	SI	31.292	56,0%
	NO	24.546	44,0%
V_PSIC	SI	53.863	96,5%
	NO	1.975	3,5%
V_SEX	NO	50.348	90,2%
	SI	5.490	9,8%
V_SIMB	SI	30.787	55,1%
	NO	25.051	44,9%
V_SOC	NO	47.365	84,8%
	SI	8.473	15,2%

Analizando la Tabla 2, se puede observar que el 76% de las personas afectadas por episodios de violencia doméstica son mujeres y el 91% reside en la Ciudad de Buenos Aires. En cuanto a la relación con la persona denunciada, el 39% de las personas afectadas cohabita con la persona denunciada. El 25% de los casos denuncian que sufren violencia diariamente, en tanto que el 35% lo hace semanalmente. La violencia psicológica es el principal tipo de violencia denunciado por el 96% de los casos. Luego, la violencia física es sufrida por el 56% y la violencia simbólica por el 55%. Por otra parte, el 33% sufre violencia ambiental y el 30% violencia económica. Por último, el 15% denuncia violencia social y el 10% violencia sexual.

Los principales vínculos entre personas afectadas y denunciadas son ex-parejas (33%) y relación filial (33%), en estrecha relación con la edad y sexo de las personas afectadas. En el Gráfico 1.1 se observa la distribución de la edad de las personas afectadas: si bien el 52% tiene entre 22 y 49 años, es relevante la proporción que tiene entre 0 y 14 años (27%).

Gráfico 1.1: Edad de las personas afectadas


Por otra parte, el Gráfico 1.2 muestra que entre las personas afectadas más jóvenes (0 a 10 años) no hay distinción de sexo, en tanto que a partir de los 11 años en adelante, las mujeres tienen mayor proporción. Por otra parte, se destaca que del grupo etario preponderante (30 a 39 años), el 87% son mujeres.

Gráfico 1.2: Edad de las personas afectadas según sexo

En cuanto a la evaluación de riesgo de las denuncias efectuada por los equipos interdisciplinarios de la OVD, el 7% de las denuncias fueron clasificadas como riesgo altísimo, el 32% como riesgo alto y el 61% restante como riesgo medio, moderado, bajo o sin riesgo. El gráfico 1.3 permite visualizar la relación entre las variables frecuencia de los episodios y la evaluación de riesgo. Se observa que existe una relación lineal de manera que a mayor frecuencia, mayor es la probabilidad del riesgo evaluado, y viceversa. De las denuncias que presentan violencia diariamente, el 62% fueron evaluadas como riesgo alto o altísimo, en tanto

que de las denuncias que presentan algún tipo de violencia esporádicamente, el 23% fueron evaluadas como tal. Este análisis da cuenta de la correlación entre las variables relevadas y el riesgo asignado.

Gráfico 1.3: Frecuencia de episodios de violencia según evaluación de riesgo



Como paso siguiente y en función del análisis presentado, se calcularon nuevas variables a partir de las variables originales. En particular fueron creadas seis variables que resultaron de importancia para el modelo.

SUM_VIOLENCIAS: la suma de los distintos tipos de violencia denunciados.

CANT_DENUNCIAS: la cantidad de denuncias o de personas afectadas que se presentan por cada legajo.

VIOLENCIAS X FREC: la suma de violencias multiplicado por la frecuencia de los episodios, luego de codificar la frecuencia de la siguiente forma:

FRECUENCIA	VALOR
Diario	30
Semanal	4
Quincenal	2
Mensual	1
Esporádico	0.5
Primer episodio	1
No corresponde	0

DENUNCIAS X FREC: la cantidad de denuncias por legajo multiplicado por la frecuencia de los episodios.

SUM_VIOLENCIAS_POND: la suma ponderada de los tipos de violencia. Para realizar la ponderación se realizó una regresión logística utilizando como variables predictoras los siete tipos de violencia y como variable a predecir el riesgo altísimo. Los resultados de los coeficientes se utilizaron para realizar la suma ponderada de la siguiente manera:


VARIABLE	COEFICIENTE	PONDERACIÓN
V_{SEX_SI}	0.931	*7
V_{SOC_SI}	0.664	*6
V_{PSIC_SI}	0.598	*5
V_{FISICA_SI}	0.498	*4
V_{AMB_SI}	0.414	*3
V_{ECON_SI}	0.328	*2
V_{SIMB_SI}	0.224	*1

$SUM_VIOLENCIAS_POND_X_FRE$: la suma ponderada de los tipos de violencia multiplicado por la frecuencia de los episodios.

9.2. Primeras aproximaciones

El primer objetivo consistió en desarrollar un modelo que permita predecir o clasificar correctamente las denuncias que presentan riesgo altísimo (7% del dataset). Para esto se definió como variable a predecir $RIESGO_ALTISIMO$, marcando como 1 las denuncias clasificadas con dicho riesgo y con 0 el resto. En primer lugar se realizaron Árboles de decisión sencillos para visualizar qué variables son más importantes en la predicción del riesgo altísimo.

Gráfico 2.1: Árbol de decisión (Riesgo altísimo)




En el Gráfico 2.1 se observa cómo las variables creadas en función de los distintos tipos de violencia son de importancia para la clasificación del riesgo. La suma de violencias ponderadas, la cantidad de denuncias por legajo y la cantidad de violencias por frecuencia son las variables que mayor incidencia tienen.

Luego, se realizaron distintos ejercicios con algoritmos de clasificación como Random Forest. Como se puede ver en el Gráfico 2.2, si bien el modelo obtiene un *accuracy* de 0.94 y alcanza una aceptable *precision* logrando clasificar correctamente la clase mayoritaria y obteniendo una *precision* de 0.79 para la clase minoritaria, se observa que el *recall* alcanzado es muy bajo (0.15). En otras palabras, una gran cantidad de denuncias con riesgo altísimo no se

pueden identificar como tal. Para este problema de clasificación es de vital importancia priorizar el *recall* por sobre la *precision* dado que es preferible equivocarse al clasificar más casos como riesgosos, que pasar por alto casos que tienen riesgo.

Gráfico 2.2: Matriz de confusión (Random forest riesgo altísimo)



A raíz de los resultados obtenidos en este primer ejercicio, se probaron distintas estrategias para conseguir un modelo más robusto y con mejor *recall*: Grid Search para la optimización de hiper parámetros priorizando el *recall*, cambiar los cortes de probabilidad, eliminar registros con los datos iguales pero evaluación de riesgo diferente, lo cual podría confundir al modelo. Dado que los datos se encuentran desbalanceados, se evaluaron también algoritmos de Oversampling de la clase minoritaria y Subsampling de la clase mayoritaria, además de algoritmos de Random Forest para datasets desbalanceados. Si bien las distintas pruebas mejoraron los resultados iniciales, ninguno de los ejercicios alcanzó métricas robustas (*Recall* = 0.27) .

A su vez, bajo el supuesto de que el la evaluación del riesgo es diferente de acuerdo a la población afectada, se entrenó el modelo en distintas subpoblaciones del dataset. En particular se repitió el ejercicio en tres subpoblaciones con los siguientes resultados:

- Violencia infantil: personas afectadas de 0 a 17 años con vínculo filial con la persona denunciada. *Recall* = 0.32

- Violencia de género: personas afectadas mujeres mayores de 17 años. *Recall* = 0.04
- Años 2017-2018-2019: se filtraron las denuncias del 2020 por ser un año atípico con largos periodos de cuarentena por la pandemia de COVID-19. *Recall* = 0.18


En conclusión, no fue posible desarrollar un modelo predictivo que permita clasificar las denuncias de riesgo altísimo. El hecho de que el *accuracy* y la *precision* presentan resultados aceptables pero no así el *recall* nos habla de que no hay en los datos criterios claros para la clasificación del riesgo altísimo. Este problema abre algunos interrogantes: las evaluaciones de riesgo altísimo en los casos en que los datos no ven riesgo podrían deberse a una evaluación más completa por parte del profesional que identifica factores de riesgo pero que no se ven reflejados en los datos. ¿Podrían ser más objetivos y definidos los criterios de evaluación y factores de riesgo? ¿Podría solucionarse el problema contando con más datos relevados de la denuncia (otras preguntas realizadas por el profesional, el texto de la denuncia, observaciones del profesional, etc.)?

9.3. Desarrollo de la solución: riesgo altísimo + alto

Los siguientes ejercicios consistieron en el desarrollo del modelo predictivo para identificar los casos de riesgo altísimo + alto (de ahora en adelante llamado riesgo alto). Si bien estos casos representan el 39% de las denuncias del dataset, de poder predecir estos casos se obtendría un buen priorizador o primer filtro de las denuncias para que sean atendidas con mayor rapidez.

En primer lugar se puede observar el árbol de decisión (Gráfico 3.1) que comienza a clasificar mejor los casos. Las variables más relevantes son la suma ponderada de violencias, la edad de la persona afectada y la cantidad de denuncias. Cabe destacar que surgen también el sexo varón de la persona denunciada y la presencia de violencia sexual en la denuncia.


Gráfico 3.1: Árbol de decisión (Riesgo alto)




Con Grid Search y Cross Validation se entrenó el modelo de Random Forest Classifier con la variable a predecir *RIESGO_ALTO*, con el objetivo de encontrar los hiper parámetros que

maximicen el *recall*. Con dichos hiper parámetros (`max_depth = 25`, `max_features = 1.0`, `n_estimators = 150`) se obtuvieron los siguientes resultados (Gráfico 3.2). Si bien se obtuvieron mejores resultados, el *recall* de 0.62 para la clase que queremos predecir continúa siendo bajo.

Gráfico 3.2: Matriz de confusión (Random forest riesgo alto)




De acuerdo con el problema que se quiere abordar, se definió priorizar el *recall* por sobre la *precision*, y definir como riesgo alto a una mayor cantidad de casos para tener una mejor cobertura. En este sentido, una posibilidad es analizar la probabilidad de corte para priorizar un mayor *recall* por sobre la *precision*. Se definió utilizar la probabilidad de corte > 0.35 identificando así más casos de riesgo alto ($Recall = 0.79$) aunque perdiendo *precision* ($Precision = 0.61$).

Gráfico 3.3: Matriz de confusión (Random forest riesgo alto, prob > 0.35)

Una vez que se obtuvo un modelo robusto se procedió a analizar las features importantes en la identificación del riesgo alto (Gráfico 3.4). Al igual que en los ejercicios de árboles de decisión, se puede observar que las principales variables que utiliza el modelo son las creadas en función de los tipos de violencia, particularmente *SUM_VIOLENCIAS_POND_X_FRE*, *CANT_DENUNCIAS*, *DENUNCIAS_X_FREC* y *VIOLENCIAS_X_FREC*. En los distintos ejercicios resultaron variables importantes, mejorando levemente los scores analizados (*recall* y *precision*).

En el Gráfico 3.4 se pueden ver las variables del dataset ordenadas de mayor a menor peso. Se destacan la suma ponderada de las violencias por la frecuencia, la cantidad de denuncias por legajo, la presencia de violencia física y sexual, la edad de la persona afectada, el nivel de instrucción de la persona denunciada y de la persona afectada y el sexo varón de la persona denunciada. A continuación se analizará el modo en que dichas variables influyen en la determinación del riesgo.


Gráfico 3.4: Features importantes

En el gráfico 3.5 se observan las veinte variables con mayor impacto, de qué modo influyen en el riesgo alto y su distribución en el score. Se observa que las variables que correlacionan directamente, es decir a mayor valor mayor es la probabilidad de riesgo alto son la suma ponderada de violencias por la frecuencia de los episodios, lo cual indica que a mayor cantidad de violencias presentes en la denuncia, ponderando por las que más influyen en el riesgo altísimo y multiplicado por la frecuencia de los episodios se obtiene una mayor probabilidad de riesgo alto. En segundo lugar se encuentra la cantidad de denuncias por legajo, la presencia de violencia física, la violencia sexual y el hecho de que la persona denunciada sea varón. Más abajo se ubican la presencia de violencia ambiental, social y simbólica, y el hecho de si las personas cohabitan al momento de la denuncia o en los siete días previos. Por último, cabe señalar que los casos que se ubican en comunas del sur de la Ciudad de Buenos Aires tienden a corresponder con un mayor riesgo. Este dato se explica por una mayor vulnerabilidad de las personas que habitan en el sur de la ciudad, área donde la población presenta un menor nivel socioeconómico y donde se acumula la mayor cantidad de denuncias (44% de las denuncias).

En cuanto a las variables que correlacionan inversamente a la probabilidad de riesgo alto se encuentran la edad de la persona afectada, es decir que los niños que sufren episodios de violencia doméstica tienen mayor probabilidad de riesgo. Esto se debe a que las personas adultas que sufren episodios de violencia tienen una mayor capacidad de agencia que los niños, ya sea de pedir ayuda o solamente visibilizar el riesgo en que se encuentran. Los casos de denuncias de

niños son probablemente presentados por otras personas adultas. En esta misma línea, se encuentra el nivel de instrucción de la persona afectada y de la persona denunciada, de manera que a un menor nivel de instrucción alcanzado de ambas partes mayor es el riesgo. Por otra parte se señalan las variables relacionadas con la condición laboral de la persona denunciada: las personas denunciadas desocupadas conllevan un riesgo mayor en tanto que las personas ocupadas remuneradas tienden a una menor probabilidad de riesgo alto.

Gráfico 3.5: Features importantes e impacto en el modelo



Por último, se realizaron ejercicios con otros algoritmos de clasificación para analizar su performance y elegir el que tenga un mejor resultado. Se utilizó la curva ROC y el área bajo la curva (AUC) para comparar los algoritmos. La curva ROC se construye con la Tasa de Falsos Positivos en el eje X y la Tasa de Verdaderos Positivos en el eje Y. Es una buena medida para comparar la performance de los algoritmos y para analizar el trade off entre especificidad y sensibilidad (o *recall*). A mayor Tasa de Falsos Positivos se espera lógicamente una mayor Tasa de Verdaderos Positivos. Un buen modelo es aquel que alcanza un alto valor de la Tasa de Verdaderos Positivos con un menor valor de Tasa de Falsos Positivos. El AUC ROC indica el área bajo la curva, siendo 1 el valor ideal.


$$\text{True Positive Rate} = \text{Sensitivity} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

$$\text{False Positive Rate} = (1 - \text{Specificity}) = \frac{\text{False Positives}}{\text{False Positives} + \text{True Negatives}}$$

A continuación se observa la curva ROC para los distintos algoritmos evaluados: Random Forest Classifier, Gradient Boosting Classifier, Logistic Regression y Neural Network (MLPClassifier).

Gráfico 3.6: Curva ROC

Azar: ROC AUC=0.500
 Random Forest Classifier: ROC AUC=0.815
 Gradient Boosting Classifier: ROC AUC=0.821
 Logistic Regression: ROC AUC=0.801
 Neural Network: ROC AUC=0.749



En primer lugar se observa que tanto el modelo de Random Forest como el de Gradient Boosting presentan muy buenos y similares resultados con un ROC AUC de 0.81 y 0.82 respectivamente. Le sigue el algoritmo de Logistic Regression con una performance aceptable (AUC = 0.80) y por último se encuentra el algoritmo de MLP Classifier.

Por último, se analizó la Curva de Precision-Recall. Esta curva se construye con el *Recall* o sensibilidad en el eje X y la *Precision* en el eje Y.


$$precision = PPV = \frac{TP}{TP+FP} \quad recall = sensitivity = \frac{TP}{TP+FN}$$

Este gráfico muestra el trade off entre *precision* y *recall* y sirve para encontrar el punto de corte ideal. En este caso habíamos definido la probabilidad de corte > 0.35 la cual nos permite obtener un *recall* de 0.79 y una *precision* de 0.61.

En el Gráfico 3.7 se observa que si quisiéramos obtener un *recall* mayor a 0.79 con los modelos de Random Forest o Gradient Boosting perderíamos mucha *precision*. Por otra parte, el gráfico nos muestra cómo se pierde casi linealmente el *recall* cuando se beneficia la *precision*.

Gráfico 3.7: Curva Precision-Recall

Random Forest: f1=0.659 auc=0.747
 Gradient Boosting: f1=0.579 auc=0.756
 Logistic Regression: f1=0.037 auc=0.717
 Neural Network: f1=0.374 auc=0.666



10. Principales hallazgos y conclusiones

En primer lugar, en relación con las características de las personas que sufren episodios de violencia doméstica cabe señalar que el 76% son mujeres y el 39% cohabita con la persona denunciada. Por otra parte, el 25% de los casos denuncian que sufren violencia diariamente, en

tanto que el 35% lo hace semanalmente. En cuanto a la edad de las víctimas, si bien el 52% tiene entre 22 y 49 años, es relevante la proporción que tiene entre 0 y 14 años (27%). En otras palabras, las mujeres y los niños son las principales víctimas de violencia doméstica. Esto se puede observar en la distribución por sexo y edad, donde se puede ver que entre las personas afectadas de 0 a 10 años no hay distinción de sexo (50% mujeres y 50% varones), en tanto que a partir de los 11 años en adelante, las mujeres cuantan con una mayor proporción (85% mujeres y 15% varones).

En cuanto a la evaluación de riesgo, el 7% de las denuncias son evaluadas como riesgo altísimo, el 32% riesgo alto y el 61% restante como riesgo medio, moderado, bajo o sin riesgo. Existe una relación lineal entre la frecuencia de los episodios y la evaluación de riesgo: de las denuncias que presentan violencia diariamente, el 62% es de riesgo alto o altísimo.

En relación a los objetivos del presente trabajo, la principal conclusión es que es posible predecir o asignar de manera sistémica el nivel de riesgo alto de las personas que denuncian episodios de violencia doméstica en función de los datos relevados en esa denuncia. En términos generales, con los datos que se relevan actualmente por la OVD es factible desarrollar un modelo predictivo que asigne con una asertividad aceptable ($AUC = 0.82$) el riesgo alto (alto + altísimo), de manera que respondiendo algunas preguntas (ya sea de manera presencial, telefónica o vía web) se podría generar un score que funcione como priorizador o agilizador de dichas denuncias. En otras palabras, si existiera un sistema único de ingreso de denuncias por violencia doméstica podría segmentarse automáticamente el 50% de mayor riesgo para que sean atendidos con mayor urgencia.

Los principales factores de riesgo que se hallaron como incidentes en su evaluación fueron la cantidad de tipos de violencia denunciados, contando con mayor peso la violencia sexual, física, ambiental y social, en estrecha relación con una alta frecuencia de dichos episodios. También es importante la cantidad de denuncias o de personas afectadas que ingresan en una sola presentación o legajo. Por otra parte, los niños/as de menos de 17 años que sufren episodios de violencia doméstica o personas con un mejor nivel de instrucción alcanzado tienden a ser evaluados con mayor riesgo. En cuanto a las características de las personas denunciadas, se observa mayor riesgo cuando el agresor es varón, sin trabajo estable, con menor nivel de instrucción alcanzado y cuando convive con la/s personas/s agredida/s.

Las limitaciones que surgieron se deben a trabajar con datos sociales de característica subjetiva. Si bien en la determinación del riesgo alto (altísimo + alto) por parte del criterio profesional parecería haber criterios definidos que permitieron el desarrollo del modelo, lo mismo no sucede con la evaluación del riesgo altísimo el cual no fue posible predecir con técnicas de machine learning. Para lograr un modelo más preciso que logre identificar los casos de riesgo altísimo deberían ser más claros los criterios utilizados en la evaluación de dicho riesgo. Por otra parte, si existiera una valoración definida sería interesante robustecer el dataset con más datos de diversa índole, por ejemplo el tiempo de convivencia, la presencia de hijos en común, antecedentes de la persona denunciada, antecedentes de denuncias previas por violencia

doméstica, etc. Otra posibilidad a futuro es cruzar los datos de las denuncias con datos de otras instituciones como pueden ser antecedentes penales de las personas denunciadas o la historia médica de las personas afectadas, a modo de ejemplo. En cuanto a la subjetividad del relato de la persona que eleva la denuncia y la subjetividad de la persona que escucha dicha denuncia y evalúa el riesgo, sería interesante analizar la posibilidad de desarrollar modelos de NLP o Text Mining para evaluar si los casos con riesgo altísimo que no se ven reflejados en los datos, tienen alguna característica particular en el relato o en la presentación del caso.

Por último, cabe destacar la utilidad de investigar la aplicación de nuevos métodos de machine learning a problemáticas socialmente complejas y estructurales. En un futuro dichas técnicas podrían ser de gran utilidad para la aplicación de políticas públicas de prevención de violencia doméstica.

11. Anexo

Descripción del dataset (OVD, 2017-2020)

#	Variable	Datos	Tipo	Descripción
0	ID_DATOS_ABIERTOS_LEGAJO	55.838	Nominal	Código identificador del legajo al que pertenece la persona afectada
1	ID_DATOS_ABIERTOS_PERSONA	55.838	Nominal	Código identificador de la persona afectada
2	AÑO	55.838	Nominal	Año en el que fue realizada la presentación
3	MES	55.838	Nominal	Mes en el que fue realizada la presentación
4	INGRESO	55.838	Nominal	Indica por quién o a través de qué institución fue derivada a la OVD
5	LEG_TERCERA	55.838	Nominal	Identifica si el legajo al que pertenece la persona afectada fue iniciado por una tercera persona
6	SEXO	55.838	Nominal	Indica el sexo de la persona afectada
7	GENERO	9.426	Nominal	Indica el género de la persona afectada (sólo disponible en las bases a partir del año 2020)
8	GRUPO_EDAD	55.838	Ordinal	Indica el grupo de edad de la persona afectada
9	EDAD	55.698	Númerica	Edad de la persona afectada
10	NACIONALIDAD	55.838	Nominal	Nacionalidad de la persona afectada
11	DOMICILIO_PROVINCIA	53.975	Nominal	Provincia en la que se domicilia la persona afectada
12	BARRIO	50.669	Nominal	Barrio en el que se domicilia la persona afectada
13	COMUNA	50.631	Nominal	Comuna en la que se domicilia la persona afectada
14	LOCALIDAD_OTRAS_PROVINCIAS	3.307	Nominal	Detalle de localidad extra jurisdiccional en la que se domicilia la persona afectada
15	NIVEL_INSTRUCCION	55.369	Ordinal	Nivel de instrucción de la persona afectada
16	CONDICION_ACTIVIDAD	55.696	Nominal	Condición de actividad de la persona afectada
17	CATEGORIA_OCUPACIONAL	25.366	Nominal	Categoría ocupacional de la persona afectada -sólo para personas ocupadas remuneradas
18	CATEGORIA_OCUPACIONAL_DETALLE	15.859	Nominal	Detalle de la categoría ocupacional de la persona afectada
19	DISCAPACIDAD	9.883	Nominal	Indica si la persona afectada tiene algún tipo de discapacidad (sólo disponible en las bases a partir del año 2020)
20	RELACION_AFECTADA_DENUNCIADA	55.838	Nominal	Vínculo entre la persona afectada y la persona denunciada
21	COHABITAN	55.776	Nominal	Indica si la persona afectada y la denunciada cohabitan o cohabitaron hasta una semana previa a la denuncia
22	FRECUENCIA_EPISODIOS	55.838	Ordinal	Indica la frecuencia de los episodios de violencia
23	V_FISICA	55.838	Nominal	Indica si se registró violencia física en la presentación
24	V_PSIC	55.838	Nominal	Indica si se registró violencia psicológica en la presentación
25	V_ECON	55.838	Nominal	Indica si se registró violencia económico patrimonial en la presentación
26	V_SEX	55.838	Nominal	Indica si se registró violencia sexual en la presentación
27	V_SOC	55.838	Nominal	Indica si se registró violencia social en la presentación
28	V_AMB	55.838	Nominal	Indica si se registró violencia ambiental en la presentación
29	V_SIMB	55.838	Nominal	Indica si se registró violencia simbólica en la presentación

30	EVALUACION_RIESGO	55.838	Ordinal	Indica la evaluación de riesgo efectuada por los Equipos Interdisciplinarios de la OVD
31	LESIONES	2.125	Nominal	Indica si se constataron lesiones (solo disponible en las bases a partir del año 2020, para las personas que accedieron a ser atendidas por el Servicio Médico de la OVD)
32	DENUNCIADA_SEXO	55.830	Nominal	Indica el sexo de la persona denunciada
33	DENUNCIADA_EDAD	55.830	Nominal	Indica el grupo de edad de la persona denunciada
34	DENUNCIADA_COND_LAB	53.791	Nominal	Indica la condición de actividad de la persona denunciada
35	DENUNCIADA_NIVEL_INSTRU	53.729	Nominal	Indica el nivel de instrucción de la persona denunciada
36	JNCIVIL	55.838	Nominal	Indica si en dicho legajo hubo derivación a la Justicia Nacional en lo Civil
37	JPENAL	55.838	Nominal	Indica si en dicho legajo hubo derivación a la Justicia Penal
38	ASJURIDICO	55.838	Nominal	Indica si en dicho legajo hubo derivación a Asesoramiento Jurídico
39	SISTSALUD	55.838	Nominal	Indica si en dicho legajo hubo derivación al sistema de salud
40	DGM	55.838	Nominal	Indica si en dicho legajo hubo derivación a la Dirección General de la Mujer (C.A.B.A.)
41	CONDNNYA	55.838	Nominal	Indica si en dicho legajo hubo derivación al Consejo de Derechos de Niñas, Niños y Adolescentes (C.A.B.A.)
42	INSTNOJUDICIAL	55.838	Nominal	Indica si en dicho legajo hubo derivación a instancia no judicial
43	JUSPROV	55.838	Nominal	Indica si en dicho legajo hubo derivación a la Justicia Provincial
44	PROTEGER	55.838	Nominal	Indica si en dicho legajo hubo derivación al Programa Proteger (C.A.B.A.)
45	SZYPDN	55.838	Nominal	Indica si en dicho legajo hubo derivación al Servicio Zonal de Promoción y Protección Integral de los derechos de los niños
46	DGMREFUGIO	55.838	Nominal	Indica si en dicho legajo hubo derivación a la Dirección General de la Mujer – Refugio- (C.A.B.A.)

12. Referencias-Bibliografía

- Berk, R., Sorenson, S., & Barnes, G. (2016), “*Forecasting Domestic Violence: A Machine Learning Approach to Help Inform Arraignment Decisions*”. Journal of Empirical Legal Studies Volume 13, Issue 1, 94–115, March 2016
- Corte Suprema de Justicia de la Nación (CSJN, 2020), “*Registro Nacional de Femicidios de la Justicia Argentina. Edición 2020*”. Oficina de la Mujer, Corte Suprema de la Nación. Disponible en: <https://www.csjn.gov.ar/omrecopilacion/docs/informefemicidios2020.pdf>
- Dutton, D. G., & Kropp, P. R. (2000). “*A review of domestic violence risk instruments*”. Trauma, violence, & abuse, 1(2), 171-181.
- Flury, M., Nyberg, E., Riecher-Rössler, A. (2010), “*Domestic violence against women: definitions, epidemiology, risk factors and consequences*”. Swiss Med Wkly. 2010;140:w13099. Disponible en: <https://smw.ch/article/doi/smw.2010.13099>
- Granados, O. (2021), “*La inteligencia artificial ayuda a prevenir la violencia de género*”. Diario El País, 18/02/2021. Disponible en: <https://elpais.com/tecnologia/haz-cosas-extraordinarias/2021-02-18/la-inteligencia-artificial-ayuda-a-prevenir-la-violencia-de-genero.html>
- Grogger, J., Ivandic, R., & Kirchmaier, T. (2020). “*Comparing Conventional and Machine-Learning Approaches to Risk Assessment in Domestic Abuse Cases*”. Centre for Economic Performance London School of Economics and Political Science. Disponible en: <https://cep.lse.ac.uk/pubs/download/dp1676.pdf>
- Grover, P. (2017). “*Gradient Boosting from scratch*”. Disponible en: <https://blog.mlreview.com/gradient-boosting-from-scratch-1e317ae4587d>
- INDEC (2019), “*Registro Único de Casos de Violencia contra las Mujeres (RUCVM). Resultados 2013-2018*”. Instituto Nacional de Estadística y Censos (INDEC). Disponible en: https://www.indec.gob.ar/uploads/informesdeprensa/rucvm_03_19.pdf
- Kropp, R. (2008), “*Intimate Partner Violence Risk Assessment and Management*”. Violence and victims, 23(2), 202-220.
- Ley 26.485 (2009). “*Ley de protección integral a las mujeres*”. Promulgada el 1 de abril de 2009. Disponible en: <http://servicios.infoleg.gob.ar/infolegInternet/anexos/150000-154999/152155/norma.htm>
- Lopez Yse, D. (2019). “*The Complete Guide to Decision Trees*”. Disponible en: <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>

OVD (2021), “*Informe Estadístico Anual 2020*”. Disponible en:

<http://www.ovd.gov.ar/ovd/noticias.do?method=iniciar&idTema=114>

Pandey, P. (2019). “*Simplifying the ROC and AUC metrics.*” Disponible en:

<https://towardsdatascience.com/understanding-the-roc-and-auc-curves-a05b68550b69>

Resolución 408/2020 (2020), “*Sistema Nacional De Denuncias Por Violencia De Género*”.

Disponible en:

<http://servicios.infoleg.gob.ar/infolegInternet/anexos/340000-344999/344107/norma.htm>

Van der Put, C., Gubbels, J., Assink, M. (2019), “*Predicting domestic violence: A meta-analysis on the predictive validity of risk assessment tools*”. Aggression and Violent Behavior. Disponible

en: <https://www.sciencedirect.com/science/article/pii/S1359178918302076>

Yiu, T. (2019). “*Understanding Random Forest*”. Disponible en:

<https://towardsdatascience.com/understanding-random-forest-58381e0602d2>