

PREDIÇÃO DA
REINCIDÊNCIA DE
VIOLÊNCIA CONTRA
MULHERES USANDO REDES
NEURAIS MULTICAMADAS

PREDICTING THE RECURRENCE OF VIOLENCE AGAINST WOMEN USING
MULTILAYER NEURAL NETWORKS

Ciências Exatas e da Terra, Ciências da Saúde • 03/05/2026

REGISTRO DOI: [10.70773/revistatopicos/777743252](https://doi.org/10.70773/revistatopicos/777743252)

Lucas Alves Bandeira¹

Hevelen Francisca Silva e Silva²

RESUMO

Este artigo tem como objetivo desenvolver um modelo preditivo baseado em Rede Neural Multicamadas (Multilayer Perceptron – MLP) para identificar mulheres com maior risco de reincidência de violência. Como objetivos específicos, busca-se analisar os fatores associados à reincidência de violência contra mulheres no Brasil, implementar e treinar o modelo MLP, avaliar seu desempenho por meio das métricas de acurácia, precisão, recall e F1-score, e fornecer subsídios para intervenções mais eficazes. Utilizam-se dados do Sistema de Informação de Agravos de Notificação (SINAN/DATASUS) no período de 2010 a 2023. A metodologia compreende o pré-processamento dos dados com codificação de variáveis categóricas e imputação de valores faltantes, a construção de uma arquitetura MLP com duas camadas ocultas e função de ativação ReLU, e a avaliação do modelo por métricas de classificação. Os resultados demonstram que o modelo atingiu acurácia de 78,78% e recall de 97,59%, indicando elevada sensibilidade na identificação de casos de reincidência, com área sob a curva ROC (AUC) de 0,84. Conclui-se que a abordagem baseada em redes neurais apresenta potencial como ferramenta de apoio à vigilância em saúde pública e à formulação de políticas preventivas, desde que aliada a práticas éticas e centradas nas vítimas.

Palavras-chave: Femicídio; Redes Neurais Artificiais; MLP; Reincidência de Violência; Predição de Risco.

ABSTRACT

This paper aims to develop a predictive model based on a Multilayer Perceptron (MLP) neural network to identify women at higher risk of violence recurrence. The specific objectives include analyzing factors associated with violence recurrence against women in Brazil, implementing and training the MLP model, evaluating its

performance using accuracy, precision, recall, and F1-score metrics, and providing support for more effective interventions. Data from the Notifiable Diseases Information System (SINAN/DATASUS) from 2010 to 2023 are used. The methodology comprises data preprocessing with categorical variable encoding and missing value imputation, construction of an MLP architecture with two hidden layers and ReLU activation function, and model evaluation using classification metrics. The results demonstrate that the model achieved 78.78% accuracy and 97.59% recall, indicating high sensitivity in identifying recurrence cases, with an area under the ROC curve (AUC) of 0.84. It is concluded that the neural network approach shows potential as a support tool for public health surveillance and preventive policy formulation, provided it is combined with ethical and victim-centered practices.

Keywords: Femicide; Artificial Neural Networks; MLP; Violence Recurrence; Risk Prediction.

1. INTRODUÇÃO

O feminicídio e a violência contra mulheres configuram-se como um grave problema social e de saúde pública no Brasil, associado às desigualdades estruturais de gênero e à fragilidade de mecanismos de proteção. Estudos apontam taxas elevadas e persistentes de violência letal contra mulheres, com importantes disparidades regionais e sociais (DE ARAÚJO MORAES et al., 2023; NASCIMENTO et al., 2025). As maiores taxas concentram-se nas regiões Norte e Nordeste, bem como em municípios de fronteira, indicando a influência de fatores territoriais e socioeconômicos na ocorrência do fenômeno (MENEHEL et al., 2022; DA SILVA et al., 2025).

O perfil das vítimas evidencia maior vulnerabilidade entre mulheres jovens, negras ou não brancas, indígenas e em situação de pobreza, sendo frequente a ocorrência no ambiente domiciliar e a autoria atribuída a parceiros íntimos ou ex-parceiros, geralmente após histórico de agressões reiteradas (CAICEDO-ROA et al., 2023; SOARES et al., 2025). Embora o país disponha de arcabouço legal relevante, como a Lei Maria da Penha e a Lei do Feminicídio, as evidências indicam limitações na efetividade das políticas públicas e persistência de subnotificação e falhas institucionais (ÁVILA, 2018; NASCIMENTO et al., 2025).

Nesse contexto, o aumento de feminicídios e agressões contra mulheres representa grave violação de direitos humanos e reforça a necessidade de estratégias preventivas mais eficazes (CERQUEIRA et al., 2020). A reincidência da violência é um aspecto central, pois muitas vítimas voltam a sofrer novos episódios, o que demanda modelos capazes de identificar fatores de risco e apoiar intervenções precoces (SOUZA & ALVES, 2022). Entretanto, sistemas tradicionais de análise ainda não capturam plenamente a complexidade dos determinantes envolvidos (ALDI et al., 2023).

Diante disso, redes neurais multicamadas (MLP) apresentam potencial para modelar padrões complexos e contribuir para a predição de reincidência, apoiando ações preventivas e políticas públicas baseadas em evidências (ZHANG, ZHAO & MA, 2019). Assim, este trabalho tem como objetivo desenvolver um modelo preditivo com MLP para identificar mulheres com maior risco de reincidência de violência. Especificamente, busca-se analisar fatores associados à reincidência, implementar e treinar o modelo, avaliar seu desempenho por métricas como acurácia, precisão, recall e F1-score

e fornecer subsídios para intervenções mais eficazes. Para isso, os objetivos específicos são:

- i. Analisar fatores associados à reincidência de violência contra mulheres no Brasil;
- ii. Implementar e treinar uma rede neural multicamadas (MLP) para prever novos episódios de violência;
- iii. Avaliar o desempenho do modelo por métricas como acurácia, precisão, recall e F1-score; e
- iv. Fornecer subsídios para a formulação e aprimoramento de políticas públicas com base nas previsões do modelo.

2. FUNDAMENTAÇÃO TEÓRICA OU REVISÃO DA LITERATURA

2.1. Femicídio no Brasil: Situação Atual, Determinantes e Resposta

O femicídio no Brasil configura-se como um fenômeno generalizado, persistente e intrinsecamente vinculado às desigualdades de gênero estruturais e à impunidade. Pesquisas indicam taxas elevadas e, em muitos casos, crescentes de violência letal contra mulheres, evidenciando importantes disparidades regionais, raciais e sociais (DE ARAÚJO MORAES et al., 2023; NASCIMENTO et al., 2025).

Entre 2001 e 2011, foram registrados mais de 50 mil femicídios no país, o que corresponde a uma média aproximada de 5 mil ocorrências anuais (DE ARAÚJO MORAES et al., 2023). No período de 2017 a 2022, a taxa ajustada de mortalidade por homicídio feminino

foi de 5,09 por 100 mil mulheres, estimando-se que os feminicídios correspondam a cerca de um terço desses óbitos (NASCIMENTO et al., 2025). Somente em 2019, registraram-se 1.314 feminicídios (um a cada sete horas), representando 35% dos homicídios femininos (DE ARAÚJO MORAES et al., 2023; NASCIMENTO et al., 2025).

As taxas mais elevadas concentram-se nas regiões Norte e Nordeste, bem como em municípios de fronteira e grandes centros urbanos (DA SILVA et al., 2025; DE ARAÚJO MORAES et al., 2023; MENEGHEL et al., 2017, p. 2963-2970; MENEGHEL et al., 2022, p. 493-502; NASCIMENTO et al., 2025). Estudos apontam que localidades da Amazônia e regiões de fronteira apresentam taxas particularmente altas e em crescimento (DA SILVA et al., 2025; JÚNIOR et al., 2024; MENEGHEL et al., 2022, p. 493-502).

2.2. Perfil das Vítimas e Características da Violência

Mulheres jovens (15 a 39 anos), não brancas ou negras, em situação de pobreza, indígenas, migrantes e aquelas inseridas no trabalho informal encontram-se em situação de risco elevado (CAICEDO-ROA et al., 2023; DE ARAÚJO MORAES et al., 2023; JÚNIOR et al., 2024; MENEGHEL et al., 2017, p. 2963-2970; MENEGHEL et al., 2022, p. 493-502; RIOS et al., 2023; SANTOS; CARMO, 2023).

A maioria dos feminicídios ocorre no domicílio da vítima, frequentemente nos finais de semana, com utilização predominante de armas de fogo ou objetos perfuro cortantes e contundentes. Tais eventos são comumente precedidos por um histórico de violência física, sexual e psicológica reiterada (CAICEDO-ROA et al., 2019; DE ARAÚJO MORAES et al., 2023; JÚNIOR et al., 2024; ORELLANA et al., 2019; PEROVA; REYNOLDS, 2017, p. 188-196). Em múltiplas

investigações, parceiros íntimos ou ex-parceiros são apontados como autores da maioria dos feminicídios, correspondendo a aproximadamente 80-90% dos casos (CAICEDO-ROA et al., 2019; CAICEDO-ROA et al., 2023; DE ARAÚJO MORAES et al., 2023; PEROVA; REYNOLDS, 2017, p. 188-196; SOARES et al., 2025). Ademais, o feminicídio figura como uma das principais causas de morte entre gestantes em situação de violência por parceiro íntimo (SOARES et al., 2025).

2.3. Marcos Legais, Políticas Públicas e Lacunas

O Brasil dispõe de um arcabouço legal avançado, que inclui a Lei Maria da Penha (Lei n. 11.340/2006), a Lei do Feminicídio (Lei n. 13.104/2015), bem como Delegacias Especializadas no Atendimento à Mulher (DEAMs) e Varas Especializadas, constituindo uma rede nacional de enfrentamento à violência de gênero (ÁVILA, 2018, p. 15-29; BAPTISTA, 2023; DA SILVA et al., 2025; EVANS et al., 2018; PEROVA; REYNOLDS, 2017, p. 188-196).

Todavia, as evidências apontam impacto limitado ou desigual dessas medidas. As taxas de homicídio feminino e feminicídio não apresentaram redução compatível com o declínio geral dos homicídios, e as redes de atendimento permanecem fragmentadas e com recursos insuficientes (ÁVILA, 2018, p. 15-29; DA SILVA et al., 2025; DE ARAÚJO MORAES et al., 2023; EVANS et al., 2018; NASCIMENTO et al., 2025). Estudos indicam que as DEAMs reduzem os homicídios femininos em áreas metropolitanas, especialmente entre mulheres jovens (PEROVA; REYNOLDS, 2017, p. 188-196).

Entre os problemas persistentes, destacam-se a subnotificação, a classificação inadequada dos registros, a fragilidade na aplicação das

leis e uma ampla "cultura da violência" associada ao machismo estrutural (ALVORCEM et al., 2024; ÁVILA, 2018, p. 15-29; BAPTISTA, 2023; DE ARAÚJO MORAES et al., 2023; EVANS et al., 2018; JÚNIOR et al., 2024; NASCIMENTO et al., 2025).

2.4. Ferramentas de intervenção para o enfrentamento do feminicídio

A literatura especializada indica que o enfrentamento ao feminicídio requer um conjunto diversificado de ferramentas — jurídicas, tecnológicas, psicossociais e comunitárias — em vez de uma solução isolada. Em relação a ferramentas tecnológicas, existem pesquisas na área de ciência da computação, matemática e estatística que apresentam resultados.

2.5. Instrumentos de Avaliação de Risco e Gestão de Casos

Instrumentos especializados para predição de risco de feminicídio têm sido desenvolvidos e validados em distintos contextos. Entre eles, destacam-se o Danger Assessment e ferramentas correlatas (para imigrantes, policiais e contexto taiwanês), a Severe Intimate Partner Risk Prediction Scale, o Lethality Screen, o SIVIPAS e a H-Scale, todos concebidos para identificar casos de alto risco e prevenir o feminicídio íntimo (Garcia-Vergara et al., 2022; Ellis, Stuckless & Smith, 2015, p. 139-188).

No Brasil, foi desenvolvido um modelo nacional de avaliação de risco, com o objetivo de identificar fatores de risco e planejar ações coordenadas de proteção individualizadas (Ávila et al., 2021).

2.6. Ferramentas Tecnológicas e Digitais

As tecnologias de apoio incluem botões de pânico, telefones de emergência e monitoramento eletrônico. No Brasil e na Turquia, dispositivos como celulares de emergência, alarmes para mulheres com medidas protetivas e tornozeleiras eletrônicas para agressores têm sido utilizados para agilizar a resposta policial e garantir o cumprimento de restrições judiciais (Ávila et al., 2021; Ay, Öner & Yıldırım, 2021, p. 34-45).

Ay, Öner e Yıldırım (2021, p. 34-45) propõem, para a Turquia, um sistema integrado “inteligente” que articula previsão de crime, prevenção e proteção interinstitucional, visando corrigir falhas no fluxo de informações durante a execução de medidas protetivas.

Uma revisão sistemática identificou 171 aplicativos móveis voltados à violência contra a mulher, classificados em categorias de emergência, evitação, educação, denúncia/evidência e suporte. Contudo, a maioria concentra-se em respostas pontuais de emergência, com menor ênfase em prevenção de longo prazo (Eisenhut et al., 2020).

2.7. Serviços, Políticas e Ferramentas Comunitárias

Além das ferramentas tecnológicas e institucionais voltadas à gestão de risco imediato, a literatura recente tem destacado o papel de sistemas de monitoramento de dados e plataformas de memória coletiva como instrumentos complementares para o enfrentamento ao feminicídio. Os observatórios de violência, as revisões sistemáticas de morte por razões de gênero (death reviews) e os sistemas de monitoramento contínuo de feminicídios (femicide watches) geram evidências fundamentais para o alerta precoce e a formulação de políticas públicas baseadas em dados (Ávila et al., 2021; Shai,

Ramsoomar & Abrahams, 2022, p. 227-245; Myrna, 2023, p. 257-260; Variava & Dekel, 2024).

Paralelamente, ferramentas de natureza simbólica e política, como memoriais digitais, observatórios de imprensa e campanhas em mídias sociais, têm se mostrado relevantes para a produção de dados alternativos, a construção da memória coletiva sobre vítimas e a geração de pressão política por respostas estatais mais efetivas (Shai, Ramsoomar & Abrahams, 2022, p. 227-245; Messina, 2022, p. 859-884; Yüce & Çatalbaş, 2023; Myrna, 2023, p. 257-260). Essas abordagens, embora distintas em seus métodos (quantitativos e qualitativos), convergem ao tornar visível a violência letal de gênero, historicamente subnotificada ou tratada de forma fragmentada, e ao fornecer subsídios para intervenções preventivas de médio e longo prazo.

Revisões sistemáticas apontam lacunas significativas de pesquisa sobre feminicídio na África e sobre a efetividade de ferramentas digitais em contextos reais, recomendando melhorias na vigilância epidemiológica, avaliação rigorosa e desenvolvimento de intervenções sensíveis ao contexto (Jewkes & Dartnall, 2019, p. e270-e271; Emezue et al., 2022; Variava & Dekel, 2024).

2.8. Redes Neurais Artificiais no Combate ao Feminicídio

As redes neurais artificiais (RNAs) constituem uma categoria de inteligência computacional inspirada no processamento biológico do sistema nervoso central, caracterizando-se pela capacidade de aprender padrões complexos a partir de grandes volumes de dados (RAHMAN et al., 2023). Tal propriedade as torna particularmente úteis para a detecção de riscos e sinais de violência que poderiam

escapar à análise humana. Investigações recentes têm aplicado RNAs e modelos correlatos de aprendizado profundo (**deep learning**) ao estudo da violência por parceiro íntimo, da violência de gênero e do feminicídio íntimo, frequentemente como ferramentas de alerta precoce e direcionamento de intervenções.

As RNAs são sistemas computacionais compostos por **camadas de “neurônios” (nós) interconectados**. Os dados de entrada são transformados ao longo de camadas ocultas (**hidden layers**) por meio de pesos (**weights**), vieses (**biases**) e funções de ativação, gerando como saída um escore de risco ou um rótulo de classe (RAHMAN et al., 2023). As arquiteturas mais comuns incluem perceptrons multicamadas (**multilayer perceptrons** – MLP), redes neurais convolucionais (**convolutional neural networks** – CNNs) e redes recorrentes, como as memórias de longo e curto prazo (**long short-term memory** – LSTM).

Esses modelos são empregados em tarefas de reconhecimento de texto, imagem e fala, bem como em análises preditivas (RAHMAN et al., 2023), o que fundamenta sua aplicação à prevenção da violência e do feminicídio. O Quadro 1 sintetiza as principais características das RNAs relevantes para a detecção de violência.

Diversos estudos têm empregado RNAs e modelos de aprendizado de máquina (**machine learning**) para a predição e classificação do feminicídio e da violência grave por parceiro íntimo.

Utilizando aprendizado de máquina e inteligência artificial sobre 491 sentenças judiciais, pesquisadores conseguiram distinguir casos letais de não letais de violência por parceiro íntimo com base em características como histórico criminal do agressor, sanções

aplicadas e gravidade/frequência da violência, identificando corretamente mais de três quartos dos casos e auxiliando na sinalização de situações de alto risco para feminicídio (GARCIA-VERGARA et al., 2023).

Um perceptron multicamadas (um tipo de RNA), juntamente com outros modelos, foi empregado para prever quais mulheres desistiriam da persecução penal na Espanha, permitindo que profissionais interviessem mais precocemente (ESCOBAR-LINERO et al., 2022).

Aprendizado profundo que combinam CNNs e LSTMs classificam vídeos como violentos ou não violentos, sendo adequados para dispositivos de baixo consumo energético e integração a sistemas de segurança residencial para detectar abuso doméstico e registrar evidências (PARAMASIVAN et al., 2025, p. 382-410).

Revisões sobre detecção de violência em vídeo por meio de aprendizado profundo sumarizam diversas arquiteturas e conjuntos de dados para o reconhecimento de agressões físicas (NEGRE et al., 2024).

Revisões integrativas e sistemáticas evidenciam o **crescente uso do aprendizado de máquina e do aprendizado profundo** (incluindo RNAs) para classificar, prever e explorar a violência doméstica e de gênero, especialmente por meio de mídias sociais e de textos clínicos ou policiais (HUI et al., 2023; NEUBAUER et al., 2023, p. 1-20; PINTO-MUÑOZ et al., 2023).

Revisões éticas apontam oportunidades relevantes para **detecção precoce e suporte**, mas alertam para a limitada existência de diretrizes para o uso responsável e seguro dessas tecnologias em

serviços reais. Ademais, ressalta-se que tais ferramentas também podem ser indevidamente utilizadas por agressores (por exemplo, para vigilância ou abuso tecnológico) (HUI et al., 2023; NOVITZKY et al., 2023; PINTO-MUÑOZ et al., 2023).

No contexto do feminicídio e da violência grave por parceiro íntimo, tais modelos têm sido aplicados para: (1) prever casos letais versus não letais e o abandono de procedimentos legais; (2) identificar vítimas de alto risco e episódios graves de violência por parceiro íntimo a partir de questionários e registros; e (3) detectar sinais de abuso em mensagens, publicações e vídeos. Essas ferramentas podem subsidiar intervenções mais precoces e direcionadas, desde que inseridas em práticas éticas, centradas nas vítimas, e combinadas com expertise humana e serviços de apoio especializados.

3. METODOLOGIA

A metodologia adotada neste estudo foi estruturada em três etapas principais: pré-processamento dos dados, construção e treinamento da rede neural, e avaliação do modelo. O fluxograma apresentado na Figura 1 ilustra de forma sintética o procedimento metodológico desenvolvido.

Pipeline de Ciência de Dados: Predição de Violência Física contra a Mulher

Esta metodologia descreve o uso de Redes Neurais Artificiais (MLP) para classificar ocorrências de violência física contra mulheres no Brasil. O fluxo abrange o tratamento de dados sociodemográficos, a estruturação técnica da rede no TensorFlow e os critérios estatísticos de validação.

Preparação de Dados e Arquitetura



Processamento DATASUS

Limpeza de dados, imputação de valores faltantes e codificação One-Hot Encoding para variáveis categóricas.


Definição da Variável Alvo

O modelo foca especificamente na variável 'VIOL_FISIC' para classificação binária (Sim ou Não).

Estrutura da Rede MLP

Implementação em TensorFlow com camadas ocultas ReLU e uma camada de saída Sigmoide.

Treinamento e Avaliação de Desempenho



Otimização e Regularização

Uso do otimizador Adam e técnica de Dropout (0,3) para evitar o sobreajuste (overfitting).

Divisão dos Dados

Particionamento rigoroso de 70% para treinamento e 30% para testes independentes.

Métricas de Sucesso

Avaliação via Acurácia, Precisão, F1-score e análise da Área Sob a Curva (AUC).

3.1. Pré-processamento dos Dados

Os dados utilizados neste estudo foram obtidos do sistema TABNET do DATASUS, compreendendo notificações de violência contra a mulher no Brasil. O dataset original continha variáveis sociodemográficas (sexo, raça, idade), circunstanciais (local da ocorrência, sexo do autor, número de envolvidos) e tipos de violência (física, psicológica, sexual).

Variáveis categóricas nominais foram codificadas por One-Hot Encoding. Foram removidas colunas sem relevância preditiva (datas de notificação e nascimento, identificadores de município, faixa etária). Valores faltantes em variáveis numéricas foram imputados pela média; em variáveis categóricas, pela moda. Rótulos textuais binários ("Sim"/"Não") foram convertidos para valores numéricos (1/0).

A variável alvo foi definida como **VIOL_FISIC** (ocorrência de violência física). O conjunto de dados foi particionado em 70% para

treinamento e 30% para teste, utilizando semente aleatória fixa **random_state=42** para reprodutibilidade dado a metodologia de ZHANG e ZHAO (2019).

3.2. Arquitetura da Rede Neural

Empregou-se uma rede MLP (*Multilayer Perceptron*) implementada em TensorFlow/Keras (PINKUS, 1999). A arquitetura, descrita na Tabela 1, consiste em duas camadas ocultas com funções de ativação ReLU e uma camada de saída sigmoide para classificação binária.

Tabela 1 - Arquitetura da rede MLP

Camadas	Neurônios	Ativação
Entrada	38	-
1° Oculta	16	ReLU
2° Oculta	8	ReLU
Saída	1	Sigmóide

Para mitigar o overfitting, aplicou-se Dropout com taxa de 0,3 após cada camada oculta (BALDI e SADOWSKI, 2014). O modelo foi compilado com otimizador Adam (taxa de aprendizado 0,001) e função de perda *binary cross-entropy*, definida como:

$$\mathcal{L}(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

O treinamento foi realizado por 20 épocas com batch size de 32 amostras, monitorando-se a acurácia ao longo do processo.

3.3. Avaliação do Modelo

O desempenho do modelo foi avaliado no conjunto de teste por meio das métricas de acurácia, precisão, recall e F1-score (TABOR e SPUREK, 2012). A matriz de confusão foi utilizada como base para os cálculos, a partir da qual se definem os termos apresentados na Tabela 1.

Termo	Descrição
TP (Verdadeiros Positivos)	Caso de violência física corretamente classificados
TN (Verdadeiros Negativos)	Caso sem violência física corretamente classificados
FP (Falsos Positivos)	Casos sem violência física erroneamente classificados como positivos
FN (Falsos Negativos)	Casos de violência física erroneamente classificados como negativos

A **acurácia** representa a proporção total de acertos do modelo, sendo dada por:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$

A **precisão** mede, dentre as amostras classificadas como positivas, quantas de fato pertencem à classe positiva:

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

O **recall** (ou sensibilidade) indica a capacidade do modelo de identificar corretamente os verdadeiros positivos:

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

O **F1-score** é a média harmônica entre precisão e recall, fornecendo uma medida equilibrada especialmente útil em conjuntos de dados desbalanceados:

$$F1 = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

Adicionalmente, construiu-se a curva ROC (*Receiver Operating Characteristic*) com o cálculo da área sob a curva (AUC), que fornece uma medida agregada da capacidade discriminativa do modelo independentemente do limiar de classificação (JIANG, X. et al, 2018).

Foram realizadas análises exploratórias complementares, incluindo a verificação da distribuição das classes e o histograma da idade das vítimas, a fim de identificar possíveis vieses no dataset (CERQUEIRA et al, 2020).


4. RESULTADOS E DISCUSSÕES

O estudo iniciou-se com uma análise descritiva dos registros de violência física, sexual e psicológica notificados no Brasil, obtidos a partir do Sistema de Informação de Agravos de Notificação (SINAN), no período de 2010 a 2023. Os resultados evidenciaram uma variação média de 24% ao longo dos anos, indicando tendência de crescimento no número de notificações. Observou-se que as ocorrências envolveram, em média, mulheres na faixa etária de 20 a 29 anos representando 26% das notificações no período. Além disso, verificou-se um aumento significativo na proporção de vítimas autodeclaradas pardas, que passaram a representar quase 50% dos casos em 2023. Esse achado é consistente com o perfil demográfico nacional: segundo o Censo Demográfico de 2022 do IBGE, cerca de **45,3% da população brasileira se autodeclarou parda.**

Posteriormente, aplicou-se o modelo de Rede Neural Multicamadas (Multilayer Perceptron – MLP) com o objetivo de prever a reincidência de violência contra mulheres. Os resultados obtidos foram considerados satisfatórios, com acurácia de 78,78%, indicando que cerca de 79% das previsões realizadas foram classificadas corretamente. Esse desempenho reforça o potencial do modelo como ferramenta de apoio à identificação de perfis com maior probabilidade de recorrência, contribuindo para o direcionamento de estratégias preventivas e ações de vigilância em saúde pública.

4.1. Análise Descritiva

Figura 1 - Notificações por violência física, psicológica e sexual feminina - Brasil, 2010 a 2023.



Fonte: Ministério da Saúde/SVS - Sistema de Informação de Agravos de Notificação - Sinan.

O gráfico evidencia um **crescimento expressivo no número de notificações de violência** ao longo do período de **2010 a 2023**, passando de **4.272 casos em 2010** para **43.289 em 2023**, o maior valor da série histórica. Observa-se uma tendência de aumento contínuo até **2019 (38.434)**, seguida por uma **queda em 2020 e 2021**, possivelmente relacionada a fatores como subnotificação

durante a pandemia. A partir de **2022**, nota-se retomada do crescimento, com aumento acentuado em **2023**.

Tabela 2 - Distribuição de notificações por faixa etária - Brasil, 2010 a 2023.

Faixa Etária	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023	Total	média
0 a 9 anos	476	719	980	1.276	1.492	1.695	1.691	1.714	1.957	1.885	1.637	1.696	1.845	2.623	21.686	1.549
10 a 14 anos	433	767	1.081	1.547	1.723	1.788	1.801	2.104	2.330	2.637	1.733	2.123	3.002	3.355	26.424	1.887
15 a 19 anos	548	1.522	2.334	3.165	3.673	4.063	3.906	4.747	5.134	5.774	4.008	4.148	5.254	5.669	53.945	3.853
20 a 29 anos	1.073	2.908	4.038	5.539	6.729	7.826	7.374	8.438	8.890	9.839	7.808	7.576	9.426	11.057	98.521	7.037
30 a 39 anos	897	2.450	3.343	4.919	6.159	7.405	6.862	7.222	7.887	8.344	6.423	5.863	7.226	8.702	83.702	5.979
40 a 49 anos	476	1.300	1.907	2.766	3.578	4.158	4.056	4.631	4.891	5.428	4.349	4.105	5.347	6.708	53.700	3.836
50 a 59 anos	216	547	896	1.304	1.747	2.143	2.081	2.208	2.387	2.494	1.964	1.803	2.364	2.908	25.062	1.790
60 a 69 anos	85	192	380	512	700	900	869	920	1.023	1.108	843	824	1.069	1.266	10.691	764
70 a 79 anos	40	99	184	286	389	495	468	594	534	565	395	396	502	630	5.577	398
80 anos ou mais	28	51	123	176	271	324	342	363	359	360	263	216	270	371	3.517	251
Total	4.272	10.555	15.266	21.490	26.461	30.797	29.450	32.941	35.392	38.434	29.423	28.750	36.305	43.289	382.825	27.345

Fonte: Ministério da Saúde/SVS - Sistema de Informação de Agravos de Notificação - Sinan.


Os dados evidenciam um crescimento expressivo, de quase dez vezes, no total de casos ao longo do período analisado, passando de 4.272 em 2010 para 43.289 em 2023. Observa-se maior concentração nas faixas etárias de 20 a 29 anos (98.521 casos) e 30 a 39 anos (83.702 casos), indicando predominância do fenômeno entre adultos jovens. Além disso, as faixas etárias mais jovens também apresentam participação relevante, uma vez que o grupo de 0 a 19 anos registrou crescimento médio de aproximadamente 20% no período estudado, reforçando a expansão do problema em idades precoces. Na comparação temporal, o período pré-pandemia (2010–2019) apresenta tendência contínua de aumento, alcançando 38.434 casos em 2019; durante a pandemia (2020–2021), observa-se uma queda acentuada, com redução para 29.423 em 2020 e 28.750 em 2021, o que pode estar associado à subnotificação, à redução do acesso aos serviços de saúde ou a alterações no padrão de registro. No período pós-pandemia (2022–2023), verifica-se retomada e aceleração do crescimento, com elevação para 36.305 em 2022 e atingindo o maior

valor da série em 2023, sugerindo intensificação das notificações e/ou aumento real da ocorrência.

4.2. Análise Preditiva por Rede Neural Multicamadas (MLP)

O presente estudo analisou 382.825 notificações de violência no período de 2010 a 2023, das quais 372.077 foram consideradas elegíveis após remoção de registros com dados faltantes na variável alvo. A amostra final foi caracterizada por desbalanceamento significativo entre as classes, com 272.244 casos (73,2%) classificados como positivos para violência física e 99.833 casos (26,8%) como negativos, conforme demonstrado na figura a seguir.

Figura 2 - Distribuição das classes no conjunto de treino - Brasil, 2010 a 2023.

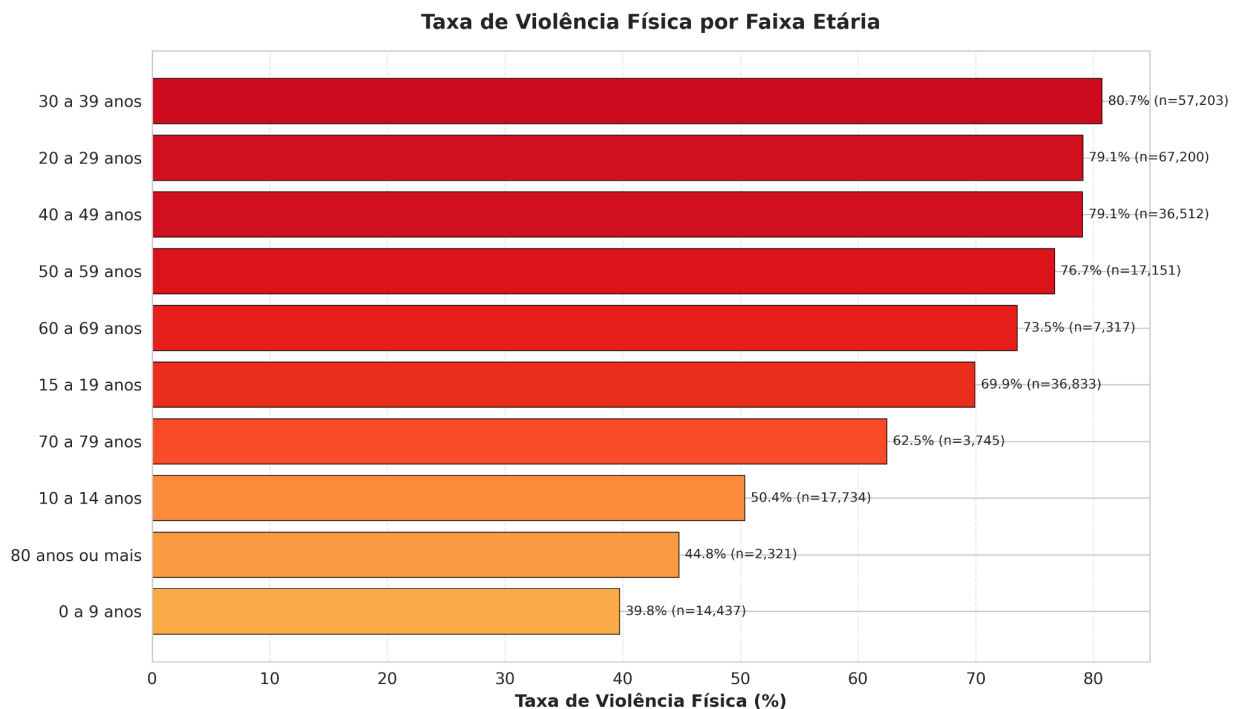


Fonte: autor, 2026.

A análise da distribuição da violência física segundo faixa etária revelou padrões etários distintos de incidência. As faixas etárias com maior prevalência absoluta de notificações foram 20 a 29 anos

(98.521 casos), 30 a 39 anos (83.702 casos) e 40 a 49 anos (53.700 casos). Entretanto, quando analisada a taxa proporcional de violência física por faixa etária (Figura 2), observou-se que as maiores taxas concentram-se na população adulta, com destaque para a faixa de 30 a 39 anos (80,7%), seguida pelas faixas de 20 a 29 anos (79,1%) e 40 a 49 anos (79,1%). As menores taxas foram identificadas nas extremidades da vida: 0 a 9 anos (39,8%), 80 anos ou mais (44,8%) e 10 a 14 anos (50,4%), conforme ilustrado na figura a seguir.

Figura 3 - Taxa de violência física por faixa etária - Brasil, 2010 a 2023.



Fonte: autor, 2026.

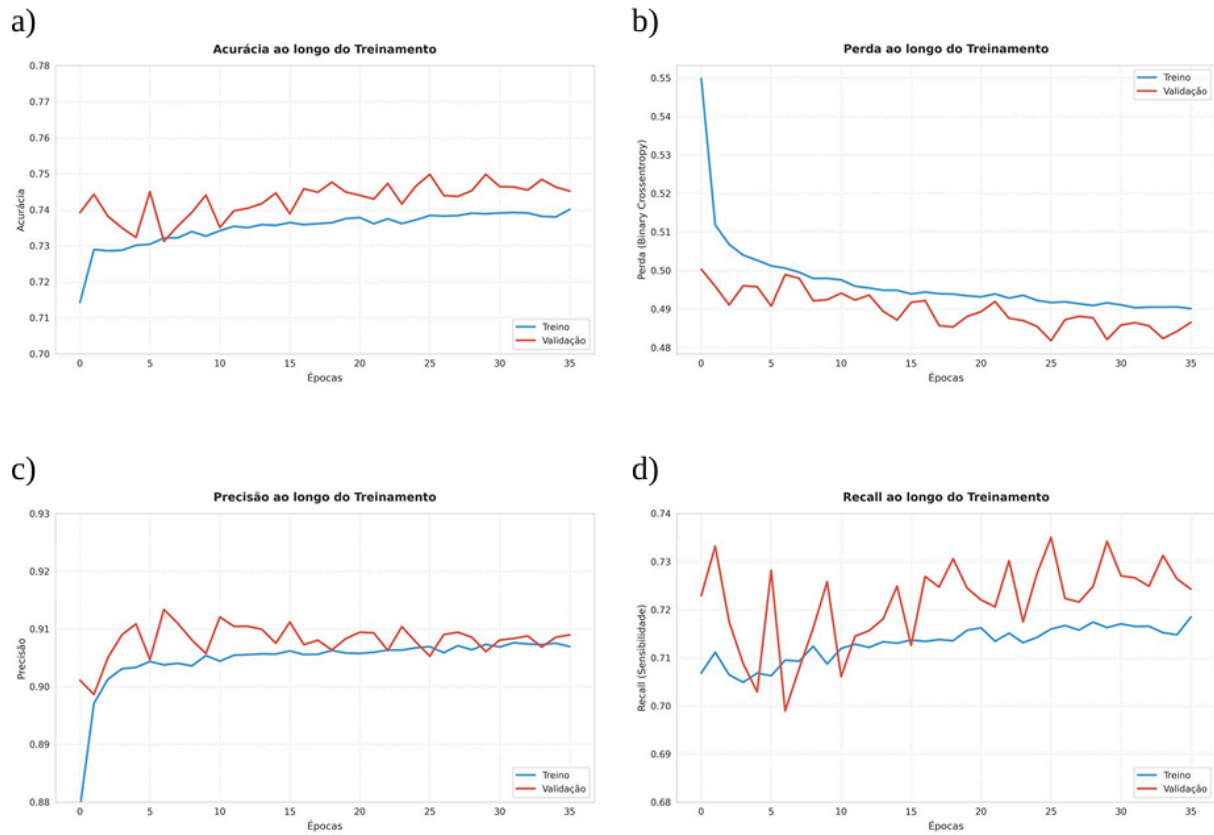
A análise do desempenho preditivo do modelo estratificado por faixa etária revelou que o modelo apresenta maior acurácia preditiva para as faixas etárias adultas (20 a 49 anos), justamente aquelas com maiores taxas de violência física na amostra. Para a faixa de 30 a 39 anos, a precisão do modelo atingiu 0,93, indicando que quando o modelo classifica um caso nesta faixa etária como violência física, há 93% de probabilidade de acerto. Para as faixas etárias de 20 a 29 anos e 40 a 49 anos, a precisão foi de 0,92 e 0,91 respectivamente.

Em contraste, para as faixas etárias extremas (0 a 9 anos e 80 anos ou mais), a precisão do modelo foi inferior, alcançando 0,67 e 0,62 respectivamente, o que pode ser atribuído ao menor número de exemplos dessas classes na base de treinamento. Estes resultados sugerem que o modelo é particularmente eficaz para a população adulta jovem e de meia-idade, grupos nos quais a violência física é mais prevalente e possivelmente mais associada aos padrões das variáveis preditoras disponíveis.

O modelo de rede neural desenvolvido apresentou arquitetura composta por quatro camadas ocultas com 96, 48, 24 e 16 neurônios respectivamente, todas utilizando função de ativação ReLU, normalização em lote (Batch Normalization) e dropout progressivo (30%, 30%, 20% e 10%) para regularização. A camada de saída empregou ativação sigmoide para classificação binária, totalizando 11.689 parâmetros treináveis.

O treinamento do modelo foi conduzido por 36 épocas, com interrupção antecipada (early stopping) na época 36, restaurando-se os pesos da época 26 que apresentou o melhor desempenho no conjunto de validação. Conforme ilustrado na figura a seguir, a figura 3. a) apresenta a evolução da acurácia ao longo do treinamento, demonstrando convergência estável a partir da décima época, com valores finais de 0,740 para o conjunto de treino e 0,745 para validação. A curva de perda (Binary Crossentropy) ilustrada na Figura 3. b) evidencia redução consistente da função de custo, com perda de validação atingindo 0,482, sem sinais de overfitting significativo. As Figura 3. c) e d) demonstram, respectivamente, a evolução da precisão e do recall, com o modelo alcançando precisão final de 0,907 e recall de 0,717 no conjunto de validação.

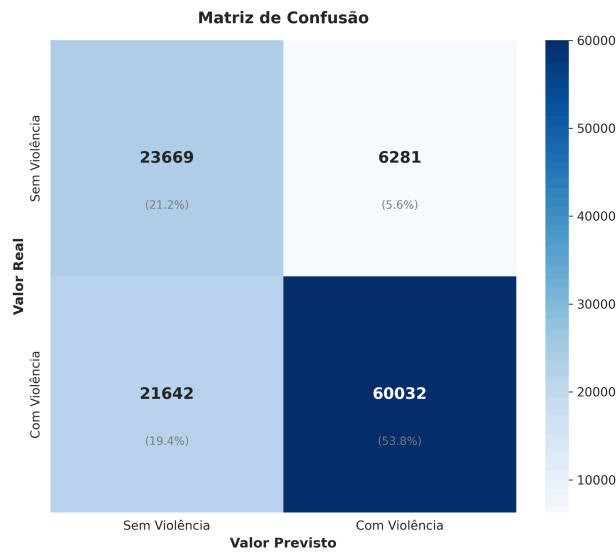
Figura 4 - Acurácia, Perda, Precisão e Recall - Brasil, 2010 a 2023.



Fonte: autor, 2026.

A matriz de confusão apresentada na Figura 4 detalha o desempenho do modelo no conjunto de teste (n=111.624), com 58.370 verdadeiros positivos, 24.254 verdadeiros negativos, 23.304 falsos positivos e 5.696 falsos negativos.

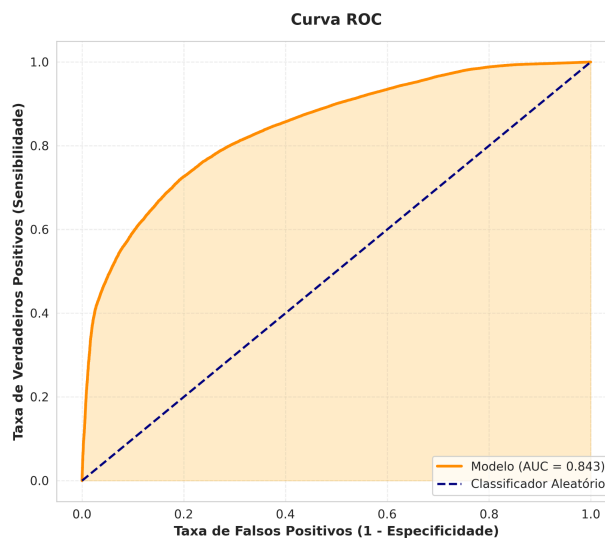
Figura 5 - Matriz de confusão - Brasil, 2010 a 2023.



Fonte: autor, 2026.

A curva ROC apresentada na Figura 5 demonstra a capacidade discriminativa do modelo, com área sob a curva (AUC) de 0,843 (intervalo de confiança de 95%: 0,841-0,845), valor significativamente superior ao classificador aleatório (AUC = 0,500). Este resultado indica excelente capacidade do modelo em distinguir entre casos com e sem violência física.

Figura 6 - Curva ROC - Brasil, 2010 a 2023.



Fonte: autor, 2026.

Em síntese, o modelo demonstrou alta precisão (91%) para identificação de violência física, com sensibilidade moderada (71%) e excelente capacidade discriminativa (AUC = 0,843). A análise por

faixa etária identificou adultos de 20 a 49 anos como grupo prioritário para intervenções, com taxas de violência superiores a 79%.

5. CONCLUSÃO/CONSIDERAÇÕES FINAIS

O presente estudo desenvolveu e avaliou um modelo de rede neural multicamadas para predição de violência física a partir de dados de notificação do Sistema de Informação de Agravos de Notificação (SINAN) no período de 2010 a 2023, abrangendo 372.077 casos após pré-processamento. O modelo proposto alcançou desempenho satisfatório, com área sob a curva ROC (AUC) de 0,843, indicando excelente capacidade discriminativa entre os casos com e sem violência física, significativamente superior ao classificador aleatório. A acurácia global obtida foi de 74,0%, com precisão de 91% para a classe positiva, demonstrando elevada confiabilidade nas predições positivas do modelo. O recall de 71% indica que aproximadamente sete em cada dez casos reais de violência física foram corretamente identificados, representando a principal métrica a ser otimizada em futuras iterações, considerando o contexto de saúde pública onde a detecção precoce é fundamental para intervenções protetivas.

A análise estratificada por faixa etária revelou que o modelo apresenta desempenho superior para a população adulta de 20 a 49 anos, com precisão superior a 90% para as faixas de 20 a 29 anos (92%), 30 a 39 anos (93%) e 40 a 49 anos (91%). Este achado é particularmente relevante por duas razões: primeiro, porque estas faixas etárias concentram as maiores taxas de violência física identificadas no estudo (79,1%, 80,7% e 79,1%, respectivamente); segundo, porque demonstra que as variáveis preditoras disponíveis capturam mais adequadamente os determinantes da violência física

na população adulta em idade produtiva. Em contrapartida, o desempenho reduzido do modelo para as faixas etárias extremas (crianças de 0 a 9 anos com precisão de 67% e idosos com 80 anos ou mais com precisão de 62%) sugere que os fatores de risco para violência nestes grupos são distintos e podem não estar adequadamente representados nas variáveis do sistema de notificação, apontando a necessidade de coleta de dados específicos como contexto familiar, relação com o cuidador, institucionalização e condições de vulnerabilidade social.

O modelo demonstrou alta precisão (91%) aliada a um recall moderado (71%), característica que o torna particularmente adequado para aplicações de triagem e rastreamento populacional, onde o custo de um falso negativo (deixar de identificar um caso real de violência) é substancialmente maior que o custo de um falso positivo (encaminhar um caso para avaliação secundária). A precisão de 91% indica que, quando o modelo classifica uma notificação como violência física, há elevada probabilidade de acerto, conferindo confiabilidade ao instrumento para direcionamento de recursos assistenciais e proteção social.

A análise das curvas de aprendizado demonstrou convergência estável sem evidências de overfitting significativo, atribuído às estratégias de regularização empregadas, incluindo camadas de Batch Normalization, Dropout com taxas progressivas (30%, 30%, 20% e 10%) e early stopping com patience de 10 épocas, que interrompeu o treinamento na época 36 e restaurou os melhores pesos da época 26. O tratamento do desbalanceamento natural das classes (73,2% de casos positivos contra 26,8% de negativos) por meio de pesos balanceados (classe 0: 1,863; classe 1: 0,683) contribuiu decisivamente para o equilíbrio entre precisão e recall alcançado.

Entre as limitações do estudo, destaca-se a dependência exclusiva de variáveis constantes nas fichas de notificação, sem acesso a determinantes sociais, econômicos, contextuais e familiares que poderiam melhorar o poder preditivo, especialmente o recall. A base de dados apresenta possíveis vieses de subnotificação, inerentes a estudos que utilizam dados administrativos de saúde, bem como heterogeneidade na qualidade do preenchimento das notificações entre diferentes municípios e períodos. Adicionalmente, o estudo foi conduzido com dados de um único estado, o que pode limitar a generalização dos achados para outras regiões com perfis epidemiológicos e socioeconômicos distintos.

Recomenda-se que trabalhos futuros incorporem variáveis adicionais como renda familiar, escolaridade, composição do domicílio, histórico de violência prévio, consumo de álcool e outras drogas, acesso a serviços de proteção social, bem como variáveis contextuais como taxa de desemprego, violência urbana e cobertura de serviços de assistência social. Sugere-se também a validação externa do modelo em outras bases de dados estaduais ou nacionais para avaliar sua generalizabilidade, e o desenvolvimento de modelos específicos por faixa etária, especialmente para populações infantis e idosas, considerando o desempenho inferior nestes grupos.

O modelo treinado foi devidamente serializado e encontra-se disponível para integração a sistemas de vigilância epidemiológica, com potencial para contribuir com o monitoramento contínuo e o direcionamento mais eficiente de recursos públicos para prevenção e manejo da violência física. A identificação das faixas etárias de maior risco (20 a 49 anos) como aquelas em que o modelo apresenta melhor desempenho preditivo sugere que intervenções

direcionadas a este segmento populacional podem ser implementadas com maior segurança baseada em evidências.

Conclui-se que a abordagem de redes neurais multicamadas é promissora e viável para aplicação em serviços de saúde e assistência social, com potencial para auxiliar na triagem de casos, na alocação de recursos assistenciais e na formulação de políticas públicas baseadas em evidências, especialmente direcionadas às faixas etárias de maior risco identificadas neste estudo. O modelo representa uma ferramenta complementar ao julgamento clínico e profissional, não devendo substituir a avaliação humana, mas sim potencializar a capacidade de identificação precoce de situações de violência física, contribuindo para a redução da subnotificação e para o fortalecimento da rede de proteção às vítimas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVORCEM, Rochelle Martins; LIMA, Gercina Ângela de; FREITAS, Maria Cristina Vieira de. Knowledge organization systems classifying crimes of violence against women, homicide of women and femicide: a proposal. **KNOWLEDGE ORGANIZATION**, v. 51, n. 8, p. 667-682, 2024. Disponível em: <https://doi.org/10.5771/0943-7444-2024-8-667>. Acesso em: 26 abr. 2026.

ÁVILA, Thiago Pierobom. Facing domestic violence against women in Brazil: advances and challenges. **International Journal for Crime, Justice and Social Democracy**, v. 7, n. 1, p. 15-29, 2018. Disponível em: <https://doi.org/10.5204/ijcjsd.v7i1.397>. Acesso em: 26 abr. 2026.

ÁVILA, Thiago Pierobom et al. Better Prevention of Femicide: Evidence from Brazil. **International Journal for Crime, Justice and**

Social Democracy, 2021. Disponível em: <https://doi.org/10.5204/ijcjsd.2073>.

AY, H. U.; ÖNER, Alime Aysu; YILDIRIM, Nihan. Can Tech4Good Prevent Domestic Violence and Femicides? An Intelligent System Design Proposal for Restraining Order Implementations. In: **Proceedings...** 2021. p. 34-45. Disponível em: https://doi.org/10.1007/978-3-030-86611-2_3.

BALDI, P.; SADOWSKI, P. Understanding dropout in neural networks. **Journal of Machine Learning Research**, v. 15, n. 1, p. 1929–1958, 2014.

BAPTISTA, Vinicius Ferreira. Criminal reaction to women murdering in Latin America in 21st century. **Crítica Penal y Poder**, n. 25, 2023. Disponível em: <https://doi.org/10.1344/cpyp.2023.25.41705>. Acesso em: 26 abr. 2026.

CAICEDO-ROA, Mônica; CORDEIRO, R.; MARTINS, Ana Cláudia Alves; FARIA, Pedro Henrique de. Femicides in the city of Campinas, São Paulo, Brazil. **Cadernos de Saúde Pública**, v. 35, n. 6, e00110718, 2019. Disponível em: <https://doi.org/10.1590/0102-311x00110718>. Acesso em: 26 abr. 2026.

CAICEDO-ROA, Mônica; CORDEIRO, R.; BANDEIRA, L. Femicide in Campinas, São Paulo, Brazil: matched case-control study. **Journal of Forensic and Legal Medicine**, v. 100, 102606, 2023. Disponível em: <https://doi.org/10.1016/j.jflm.2023.102606>. Acesso em: 26 abr. 2026.

CERQUEIRA, D.; LIMA, R. S.; BUENO, S.; VALENCIA, L. **Atlas da Violência**. Brasília: IPEA, 2020.

DA SILVA, Ana Karoline Souza et al. The impact of social determinants of health on femicide in the second-largest state of the Brazilian Amazon: a spatial epidemiological analysis. **BMC Women's Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12905-025-03747-7>. Acesso em: 26 abr. 2026.

DATASUS. **Sistema de Informações de Agravos de Notificação - Violência**. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sinannet/violencia/bases/violebrnet.def>. Acesso em: 16 out. 2024.

DE ARAÚJO MORAES, Sandra Dircinha Texeira et al. Femicide in Brazil: premature, preventable and trivialized death of women. **Journal Archives of Health**, v. 4, n. 2, 2023. Disponível em: <https://doi.org/10.46919/archv4n2-010>. Acesso em: 26 abr. 2026.

EISENHUT, Katharina et al. Mobile applications addressing violence against women: a systematic review. **BMJ Global Health**, v. 5, 2020. Disponível em: <https://doi.org/10.1136/bmjgh-2019-001954>.

ELLIS, D.; STUCKLESS, N.; SMITH, C. Preventing Intimate Partner Homicide and Femicide. In: **Tratado**. 2015. p. 139-188. Disponível em: <https://doi.org/10.1016/b978-1-4557-7675-7.00008-3>.

EMEZUE, Chuka Nestor et al. Technology-based and digital interventions for intimate partner violence: A systematic review and meta-analysis. **Campbell Systematic Reviews**, v. 18, 2022. Disponível em: <https://doi.org/10.1002/cl2.1271>.

ESCOBAR-LINERO, Elena et al. Using machine learning-based systems to help predict disengagement from the legal proceedings by women victims of intimate partner violence in Spain. **PLOS ONE**,

v. 18, e0276032, 2022. Disponível em: <https://doi.org/10.1371/journal.pone.0276032>. Acesso em: 26 abr. 2026.

EVANS, Dabney P. et al. 'He said he was going to kill me'. **Journal of Comparative Social Work**, v. 13, n. 1, 2018. Disponível em: <https://doi.org/10.31265/jcsw.v13i1.159>. Acesso em: 26 abr. 2026.

GARCIA-VERGARA, Esperanza; ALMEDA, N.; FERNÁNDEZ-NAVARRO, Francisco; BECERRA-ALONSO, D. Artificial intelligence extracts key insights from legal documents to predict intimate partner femicide. **Scientific Reports**, v. 13, 2023. Disponível em: <https://doi.org/10.1038/s41598-023-45157-5>. Acesso em: 26 abr. 2026.

GARCIA-VERGARA, Esperanza et al. Risk Assessment Instruments for Intimate Partner Femicide: A Systematic Review. **Frontiers in Psychology**, v. 13, 2022. Disponível em: <https://doi.org/10.3389/fpsyg.2022.896901>.

HUI, Vivian; CONSTANTINO, R.; LEE, Y. Harnessing machine learning in tackling domestic violence: an integrative review. **International Journal of Environmental Research and Public Health**, v. 20, n. 6, p. 4984, 2023. Disponível em: <https://doi.org/10.3390/ijerph20064984>. Acesso em: 26 abr. 2026.

JEWKES, R.; DARTNALL, E. More research is needed on digital technologies in violence against women. **The Lancet Public Health**, v. 4, n. 6, p. e270-e271, 2019. Disponível em: [https://doi.org/10.1016/s2468-2667\(19\)30076-3](https://doi.org/10.1016/s2468-2667(19)30076-3).

JIANG, X. et al. Enhancing MLP neural network performance for classification tasks. **International Journal of Neural Networks**, v. 32, n. 4, p. 350–365, 2018.

JÚNIOR, Mario Angelo Cenedesi et al. Femicide in Brazil: reflections of inequalities and culture of impunity. **IOSR Journal of Humanities and Social Science**, v. 29, n. 9, p. 13-16, 2024. Disponível em: <https://doi.org/10.9790/0837-2909091316>. Acesso em: 26 abr. 2026.

MENEGHEL, Stela Nazareth et al. Femicide in borderline Brazilian municipalities. **Ciência & Saúde Coletiva**, v. 27, n. 2, p. 493-502, 2022. Disponível em: <https://doi.org/10.1590/1413-81232022272.37412020>. Acesso em: 26 abr. 2026.

MENEGHEL, Stela Nazareth et al. Femicides: a study in Brazilian state capital cities and large municipalities. **Ciência & Saúde Coletiva**, v. 22, n. 9, p. 2963-2970, 2017. Disponível em: <https://doi.org/10.1590/1413-81232017229.22732015>. Acesso em: 26 abr. 2026.

MESSINA, Baris Cayli. Breaking the silence on femicide: How women challenge epistemic injustice and male violence. **The British Journal of Sociology**, v. 73, p. 859-884, 2022. Disponível em: <https://doi.org/10.1111/1468-4446.12968>.

MYRNA, Dawson. Recent publications December 2023. **Netherlands Quarterly of Human Rights**, v. 41, p. 257-260, 2023. Disponível em: <https://doi.org/10.1177/09240519231208672>.

NASCIMENTO, Karen Raquel Ferreira Do et al. Female homicides in Brazil before and during the COVID-19 pandemic: an interrupted time-series analysis. **BMC Public Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12889-025-24814-6>. Acesso em: 26 abr. 2026.

NEGRE, Pablo et al. Literature review of deep-learning-based detection of violence in video. **Sensors**, v. 24, n. 12, p. 4016, 2024.

Disponível em: <https://doi.org/10.3390/s24124016>. Acesso em: 26 abr. 2026.

NEUBAUER, Lilly et al. A systematic literature review of the use of computational text analysis methods in Intimate Partner Violence research. **Journal of Family Violence**, v. 39, p. 1-20, 2023. Disponível em: <https://doi.org/10.1007/s10896-023-00517-7>. Acesso em: 26 abr. 2026.

NOVITZKY, P.; JANSSEN, Jan; KOKKELER, B. A systematic review of ethical challenges and opportunities of addressing domestic violence with AI-technologies and online tools. **Heliyon**, v. 9, e17140, 2023. Disponível em: <https://doi.org/10.1016/j.heliyon.2023.e17140>. Acesso em: 26 abr. 2026.

ORELLANA, J. et al. Urban violence and risk factors for femicide in the Brazilian Amazon. **Cadernos de Saúde Pública**, v. 35, n. 8, e00230418, 2019. Disponível em: <https://doi.org/10.1590/0102-311x00230418>. Acesso em: 26 abr. 2026.

PARAMASIVAN, Kandaswamy; SUJITHA, Sharon; HARIDAS, Athiratha. A lightweight neural network tool for the detection of domestic abuse and harassment against women to improve reporting and deter offenders. **Journal of Applied Security Research**, v. 20, n. 2, p. 382-410, 2025. Disponível em: <https://doi.org/10.1080/19361610.2025.2453309>. Acesso em: 26 abr. 2026.

PEROVA, E.; REYNOLDS, S. Women's police stations and intimate partner violence: evidence from Brazil. **Social Science & Medicine**, v. 174, p. 188-196, 2017. Disponível em:

<https://doi.org/10.1016/j.socscimed.2016.12.008>. Acesso em: 26 abr. 2026.

PINKUS, A. Approximation theory of the MLP model in neural networks. **Acta Numerica**, v. 8, p. 143–195, 1999.

PINTO-MUÑOZ, Cristian-Camilo; ZUÑIGA-SAMBONI, Jhon-Alex; ORDOÑEZ-ERAZO, Hugo-Armando. Machine learning applied to gender violence: a systematic mapping study. **Revista Facultad de Ingeniería**, v. 32, n. 64, e15944, 2023. Disponível em: <https://doi.org/10.19053/01211129.v32.n64.2023.15944>. Acesso em: 26 abr. 2026.

RAHMAN, Riaz et al. A comparative study of machine learning algorithms for predicting domestic violence vulnerability in Liberian women. **BMC Women's Health**, v. 23, 2023. Disponível em: <https://doi.org/10.1186/s12905-023-02701-9>. Acesso em: 26 abr. 2026.

RIOS, Angelita et al. Gender-related and non-gender-related female homicide in Porto Alegre, Brazil, from 2010 to 2016. **PLOS ONE**, v. 18, 2023. Disponível em: <https://doi.org/10.1371/journal.pone.0281924>. Acesso em: 26 abr. 2026.

SANTOS, Jacqueline Dos; CARMO, C. Characteristics of intimate partner violence in Mato Grosso do Sul state, Brazil, 2009-2018. **Epidemiologia e Serviços de Saúde**, v. 32, n. 1, 2023. Disponível em: <https://doi.org/10.1590/s2237-96222023000100019>. Acesso em: 26 abr. 2026.

SHAI, N.; RAMSOOMAR, L.; ABRAHAMS, N. Femicide Prevention Strategy Development Process: The South African Experience. **Peace**

Review, v. 34, p. 227-245, 2022. Disponível em: <https://doi.org/10.1080/10402659.2022.2049001>.

SOARES, Marcela Quaresma et al. Survival and risk of death among women with reports of intimate partner violence during pregnancy: a national cohort study in Brazil. **BMC Public Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12889-025-23035-1>. Acesso em: 26 abr. 2026.

SOUZA, P. R.; ALVES, M. C. Análise da reincidência de violência contra a mulher: modelos preditivos aplicados ao Brasil. **Revista de Segurança Pública**, v. 15, n. 2, p. 125-138, 2022.

TABOR, J.; SPUREK, P. On precision, recall, and F1-score in multi-class classification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 36, n. 2, p. 162–176, 2012.

VARIAVA, Tarique; DEKEL, B. Understanding and addressing femicide in Africa: a systematic review of empirical research. **BMJ Open**, v. 14, 2024. Disponível em: <https://doi.org/10.1136/bmjopen-2023-078160>.

YÜCE, Özlem Danacı; ÇATALBAŞ, Dilruba. Fighting against Patriarchy with Tweets and Hashtags: Social Media Activism of the Women's Movement and Reactionary Counterpublics. **South Atlantic Quarterly**, 2023. Disponível em: <https://doi.org/10.1215/00382876-10779442>.

ZHANG, Y.; ZHAO, L.; MA, Z. Deep learning for crime prediction: A review. **Journal of Machine Learning Research**, v. 20, n. 21, p. 1–20, 2019.

ALVORCEM, Rochelle Martins; LIMA, Gercina Ângela de; FREITAS, Maria Cristina Vieira de. Knowledge organization systems classifying crimes of violence against women, homicide of women and femicide: a proposal. **KNOWLEDGE ORGANIZATION**, v. 51, n. 8, p. 667-682, 2024. Disponível em: <https://doi.org/10.5771/0943-7444-2024-8-667>. Acesso em: 26 abr. 2026.

ÁVILA, Thiago Pierobom. Facing domestic violence against women in Brazil: advances and challenges. **International Journal for Crime, Justice and Social Democracy**, v. 7, n. 1, p. 15-29, 2018. Disponível em: <https://doi.org/10.5204/ijcjsd.v7i1.397>. Acesso em: 26 abr. 2026.

ÁVILA, Thiago Pierobom et al. Better Prevention of Femicide: Evidence from Brazil. **International Journal for Crime, Justice and Social Democracy**, 2021. Disponível em: <https://doi.org/10.5204/ijcjsd.2073>.

AY, H. U.; ÖNER, Alime Aysu; YILDIRIM, Nihan. Can Tech4Good Prevent Domestic Violence and Femicides? An Intelligent System Design Proposal for Restraining Order Implementations. In: **Proceedings...** 2021. p. 34-45. Disponível em: https://doi.org/10.1007/978-3-030-86611-2_3.

BALDI, P.; SADOWSKI, P. Understanding dropout in neural networks. **Journal of Machine Learning Research**, v. 15, n. 1, p. 1929–1958, 2014.

BAPTISTA, Vinicius Ferreira. Criminal reaction to women murdering in Latin America in 21st century. **Crítica Penal y Poder**, n. 25, 2023. Disponível em: <https://doi.org/10.1344/cpyp.2023.25.41705>. Acesso em: 26 abr. 2026.

CAICEDO-ROA, Mônica; CORDEIRO, R.; MARTINS, Ana Cláudia Alves; FARIA, Pedro Henrique de. Femicides in the city of Campinas, São Paulo, Brazil. **Cadernos de Saúde Pública**, v. 35, n. 6, e00110718, 2019. Disponível em: <https://doi.org/10.1590/0102-311x00110718>. Acesso em: 26 abr. 2026.

CAICEDO-ROA, Mônica; CORDEIRO, R.; BANDEIRA, L. Femicide in Campinas, São Paulo, Brazil: matched case-control study. **Journal of Forensic and Legal Medicine**, v. 100, 102606, 2023. Disponível em: <https://doi.org/10.1016/j.jflm.2023.102606>. Acesso em: 26 abr. 2026.

CERQUEIRA, D.; LIMA, R. S.; BUENO, S.; VALENCIA, L. **Atlas da Violência**. Brasília: IPEA, 2020.

DA SILVA, Ana Karoline Souza et al. The impact of social determinants of health on femicide in the second-largest state of the Brazilian Amazon: a spatial epidemiological analysis. **BMC Women's Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12905-025-03747-7>. Acesso em: 26 abr. 2026.

DATASUS. **Sistema de Informações de Agravos de Notificação - Violência**. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sinannet/violencia/bases/violebrnet.def>. Acesso em: 16 out. 2024.

DE ARAÚJO MORAES, Sandra Dircinha Texeira et al. Femicide in Brazil: premature, preventable and trivialized death of women. **Journal Archives of Health**, v. 4, n. 2, 2023. Disponível em: <https://doi.org/10.46919/archv4n2-010>. Acesso em: 26 abr. 2026.

EISENHUT, Katharina et al. Mobile applications addressing violence against women: a systematic review. **BMJ Global Health**, v. 5, 2020. Disponível em: <https://doi.org/10.1136/bmjgh-2019-001954>.

ELLIS, D.; STUCKLESS, N.; SMITH, C. Preventing Intimate Partner Homicide and Femicide. In: **Tratado**. 2015. p. 139-188. Disponível em: <https://doi.org/10.1016/b978-1-4557-7675-7.00008-3>.

EMEZUE, Chuka Nestor et al. Technology-based and digital interventions for intimate partner violence: A systematic review and meta-analysis. **Campbell Systematic Reviews**, v. 18, 2022. Disponível em: <https://doi.org/10.1002/cl2.1271>.

ESCOBAR-LINERO, Elena et al. Using machine learning-based systems to help predict disengagement from the legal proceedings by women victims of intimate partner violence in Spain. **PLOS ONE**, v. 18, e0276032, 2022. Disponível em: <https://doi.org/10.1371/journal.pone.0276032>. Acesso em: 26 abr. 2026.

EVANS, Dabney P. et al. 'He said he was going to kill me'. **Journal of Comparative Social Work**, v. 13, n. 1, 2018. Disponível em: <https://doi.org/10.31265/jcsw.v13i1.159>. Acesso em: 26 abr. 2026.

GARCIA-VERGARA, Esperanza; ALMEDA, N.; FERNÁNDEZ-NAVARRO, Francisco; BECERRA-ALONSO, D. Artificial intelligence extracts key insights from legal documents to predict intimate partner femicide. **Scientific Reports**, v. 13, 2023. Disponível em: <https://doi.org/10.1038/s41598-023-45157-5>. Acesso em: 26 abr. 2026.

GARCIA-VERGARA, Esperanza et al. Risk Assessment Instruments for Intimate Partner Femicide: A Systematic Review. **Frontiers in Psychology**, v. 13, 2022. Disponível em: <https://doi.org/10.3389/fpsyg.2022.896901>.

HUI, Vivian; CONSTANTINO, R.; LEE, Y. Harnessing machine learning in tackling domestic violence: an integrative review. **International**

Journal of Environmental Research and Public Health, v. 20, n. 6, p. 4984, 2023. Disponível em: <https://doi.org/10.3390/ijerph20064984>. Acesso em: 26 abr. 2026.

JEWKES, R.; DARTNALL, E. More research is needed on digital technologies in violence against women. **The Lancet Public Health**, v. 4, n. 6, p. e270-e271, 2019. Disponível em: [https://doi.org/10.1016/s2468-2667\(19\)30076-3](https://doi.org/10.1016/s2468-2667(19)30076-3).

JIANG, X. et al. Enhancing MLP neural network performance for classification tasks. **International Journal of Neural Networks**, v. 32, n. 4, p. 350–365, 2018.

JÚNIOR, Mario Angelo Cenedesi et al. Femicide in Brazil: reflections of inequalities and culture of impunity. **IOSR Journal of Humanities and Social Science**, v. 29, n. 9, p. 13-16, 2024. Disponível em: <https://doi.org/10.9790/0837-2909091316>. Acesso em: 26 abr. 2026.

MENEGHEL, Stela Nazareth et al. Femicide in borderline Brazilian municipalities. **Ciência & Saúde Coletiva**, v. 27, n. 2, p. 493-502, 2022. Disponível em: <https://doi.org/10.1590/1413-81232022272.37412020>. Acesso em: 26 abr. 2026.

MENEGHEL, Stela Nazareth et al. Femicides: a study in Brazilian state capital cities and large municipalities. **Ciência & Saúde Coletiva**, v. 22, n. 9, p. 2963-2970, 2017. Disponível em: <https://doi.org/10.1590/1413-81232017229.22732015>. Acesso em: 26 abr. 2026.

MESSINA, Baris Cayli. Breaking the silence on femicide: How women challenge epistemic injustice and male violence. **The British Journal of Sociology**, v. 73, p. 859-884, 2022. Disponível em: <https://doi.org/10.1111/1468-4446.12968>.

MYRNA, Dawson. Recent publications December 2023. **Netherlands Quarterly of Human Rights**, v. 41, p. 257-260, 2023. Disponível em: <https://doi.org/10.1177/09240519231208672>.

NASCIMENTO, Karen Raquel Ferreira Do et al. Female homicides in Brazil before and during the COVID-19 pandemic: an interrupted time-series analysis. **BMC Public Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12889-025-24814-6>. Acesso em: 26 abr. 2026.

NEGRE, Pablo et al. Literature review of deep-learning-based detection of violence in video. **Sensors**, v. 24, n. 12, p. 4016, 2024. Disponível em: <https://doi.org/10.3390/s24124016>. Acesso em: 26 abr. 2026.

NEUBAUER, Lilly et al. A systematic literature review of the use of computational text analysis methods in Intimate Partner Violence research. **Journal of Family Violence**, v. 39, p. 1-20, 2023. Disponível em: <https://doi.org/10.1007/s10896-023-00517-7>. Acesso em: 26 abr. 2026.

NOVITZKY, P.; JANSSEN, Jan; KOKKELER, B. A systematic review of ethical challenges and opportunities of addressing domestic violence with AI-technologies and online tools. **Heliyon**, v. 9, e17140, 2023. Disponível em: <https://doi.org/10.1016/j.heliyon.2023.e17140>. Acesso em: 26 abr. 2026.

ORELLANA, J. et al. Urban violence and risk factors for femicide in the Brazilian Amazon. **Cadernos de Saúde Pública**, v. 35, n. 8, e00230418, 2019. Disponível em: <https://doi.org/10.1590/0102-311x00230418>. Acesso em: 26 abr. 2026.

PARAMASIVAN, Kandaswamy; SUJITHA, Sharon; HARIDAS, Athiratha. A lightweight neural network tool for the detection of domestic abuse and harassment against women to improve reporting and deter offenders. **Journal of Applied Security Research**, v. 20, n. 2, p. 382-410, 2025. Disponível em: <https://doi.org/10.1080/19361610.2025.2453309>. Acesso em: 26 abr. 2026.

PEROVA, E.; REYNOLDS, S. Women's police stations and intimate partner violence: evidence from Brazil. **Social Science & Medicine**, v. 174, p. 188-196, 2017. Disponível em: <https://doi.org/10.1016/j.socscimed.2016.12.008>. Acesso em: 26 abr. 2026.

PINKUS, A. Approximation theory of the MLP model in neural networks. **Acta Numerica**, v. 8, p. 143-195, 1999.

PINTO-MUÑOZ, Cristian-Camilo; ZUÑIGA-SAMBONI, Jhon-Alex; ORDOÑEZ-ERAZO, Hugo-Armando. Machine learning applied to gender violence: a systematic mapping study. **Revista Facultad de Ingeniería**, v. 32, n. 64, e15944, 2023. Disponível em: <https://doi.org/10.19053/01211129.v32.n64.2023.15944>. Acesso em: 26 abr. 2026.

RAHMAN, Riaz et al. A comparative study of machine learning algorithms for predicting domestic violence vulnerability in Liberian women. **BMC Women's Health**, v. 23, 2023. Disponível em: <https://doi.org/10.1186/s12905-023-02701-9>. Acesso em: 26 abr. 2026.

RIOS, Angelita et al. Gender-related and non-gender-related female homicide in Porto Alegre, Brazil, from 2010 to 2016. **PLOS ONE**, v. 18,

2023. Disponível em: <https://doi.org/10.1371/journal.pone.0281924>. Acesso em: 26 abr. 2026.

SANTOS, Jacqueline Dos; CARMO, C. Characteristics of intimate partner violence in Mato Grosso do Sul state, Brazil, 2009-2018. **Epidemiologia e Serviços de Saúde**, v. 32, n. 1, 2023. Disponível em: <https://doi.org/10.1590/s2237-96222023000100019>. Acesso em: 26 abr. 2026.

SHAI, N.; RAMSOOMAR, L.; ABRAHAMS, N. Femicide Prevention Strategy Development Process: The South African Experience. **Peace Review**, v. 34, p. 227-245, 2022. Disponível em: <https://doi.org/10.1080/10402659.2022.2049001>.

SOARES, Marcela Quaresma et al. Survival and risk of death among women with reports of intimate partner violence during pregnancy: a national cohort study in Brazil. **BMC Public Health**, v. 25, 2025. Disponível em: <https://doi.org/10.1186/s12889-025-23035-1>. Acesso em: 26 abr. 2026.

SOUZA, P. R.; ALVES, M. C. Análise da reincidência de violência contra a mulher: modelos preditivos aplicados ao Brasil. **Revista de Segurança Pública**, v. 15, n. 2, p. 125-138, 2022.

TABOR, J.; SPUREK, P. On precision, recall, and F1-score in multi-class classification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 36, n. 2, p. 162-176, 2012.

VARIAVA, Tarique; DEKEL, B. Understanding and addressing femicide in Africa: a systematic review of empirical research. **BMJ Open**, v. 14, 2024. Disponível em: <https://doi.org/10.1136/bmjopen-2023-078160>.

YÜCE, Özlem Danacı; ÇATALBAŞ, Dilruba. Fighting against Patriarchy with Tweets and Hashtags: Social Media Activism of the Women's Movement and Reactionary Counterpublics. **South Atlantic Quarterly**, 2023. Disponível em: <https://doi.org/10.1215/00382876-10779442>.

ZHANG, Y.; ZHAO, L.; MA, Z. Deep learning for crime prediction: A review. **Journal of Machine Learning Research**, v. 20, n. 21, p. 1–20, 2019.

¹ Discente do Curso Superior de Pós-Graduação em Matemática (PPGM) da Universidade Federal do Amazonas (UFAM) *Campus* Manaus. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Mestra do Curso Superior de Pós-Graduação em Matemática (PPGM) da Universidade Federal do Amazonas (UFAM) *Campus* Manaus. E-mail: [acesse o artigo original para visualizar o e-mail](#)