

What is the Profile of American Inmate Misconduct Perpetrators? A Machine Learning Analysis

F. M. de Oliveira¹, M. de S. Balbino^{1,2}, L. E. Zárate¹, C. N. Nobre¹

¹ Pontifícia Universidade Católica de Minas Gerais, Brasil

² Centro Federal de Educação Tecnológica de Minas Gerais, Brasil

fmartinssp@pucminas.br, marcelobalbino@gmail.com, zarate@pucminas.br, nobre@pucminas.br

Abstract. Correctional institutions often develop rehabilitation programs to reduce the likelihood of inmates committing internal offenses and criminal recidivism after release. Therefore, it is necessary to identify the profile of each offender, both for the appropriate indication of a rehabilitation program and the level of internal security to which he must be submitted. In this context, this work aims to discover, from Machine Learning methods and the SHAP approach, which are the most significant characteristics in the prediction of misconduct by prisoners. For this, a database produced in 2004 through the Survey of Inmates in State and Federal Correctional Facilities in the United States of America, which provides nationally representative data on prisoners in state and federal facilities, was used. The predictive model based on *Random Forest* had the best performance; therefore, SHAP was applied to it to interpret the results. In addition, the attributes related to the type of crime committed, age at first arrest, drug use, mental or emotional health problems, having children, and being abused before arrest are more relevant in predicting internal misconduct. Thus, it is expected to contribute to the prior classification of an inmate, on time, use of programs and practices that aim to improve the lives of offenders, their reintegration into society, and, consequently, the reduction of criminal recidivism.

CCS Concepts: • **Computing methodologies** → **Supervised learning by classification**; • **Applied computing** → **Law**.

Keywords: Misconduct, Crime, Recidivism, Machine Learning, SHAP

1. INTRODUÇÃO

A má conduta de detentos nas prisões desperta preocupações entre formuladores de políticas públicas sobre segurança, profissionais e pesquisadores afins. Além de contribuir com a perturbação da ordem social geral e afetar a reabilitação de outros detentos, a má conduta interna possui uma conexão com a reincidência. De acordo com García-Gomis et al. [2016], ela constitui uma experiência que: (a) pode contribuir para a reincidência; ou (b) fornecer informações adicionais sobre o risco de reincidência. Portanto, o estudo da má conduta potencializa os esforços para mitigar a reincidência criminal.

Enquanto estão presos, os infratores frequentemente participam de programas de reabilitação com o objetivo de reduzir a probabilidade de cometerem infrações internas e a reincidência após libertos, bem como garantir uma vida mais produtiva. Taylor [2017] afirma que, quando tais programas são idealizados e implementados de forma eficaz, eles podem reduzir o número de infratores que reincidem e as economias resultantes podem compensar os seus custos.

Este cenário evidencia uma importante tarefa, ou seja, identificar o perfil de cada infrator para que

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico do Brasil (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG). O trabalho foi desenvolvido na Pontifícia Universidade Católica de Minas Gerais, PUC Minas no laboratório de Inteligência Computacional Aplicada – LICAP.

Copyright©2022. Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

a indicação de participação em um programa de reabilitação específico seja feita de forma apropriada. Além disso, os sistemas correccionais geralmente tomam decisões em relação aos níveis de segurança ou custódia em que os presos devem ser mantidos, de acordo com o risco que cada um representa.

Os métodos de Aprendizado de Máquina (AM) mostram-se adequados ao problema mencionado pois têm atingido resultados satisfatórios na extração de conhecimento em conjuntos de dados, seja no suporte à análise de crimes e criminosos [Qayyum et al. 2018], bem como na predição da má conduta de detentos [Ngo et al. 2019]. No entanto, em cenários nos quais a decisão impacta na vida humana e na sociedade, ter um modelo com alto desempenho preditivo é apenas uma solução parcial do problema, pois o tomador de decisão pode se sentir inseguro sem uma explicação dos resultados.

Nesse sentido, Lundberg e Lee [2017] apresentam o *SHapley Additive exPlanations* (SHAP), um *framework* para interpretar modelos de AM. A abordagem utiliza os *SHAP values* como forma para medir a importância de cada atributo em uma predição. Cada atributo impacta uma dada instância em um valor que pode ser positivo, negativo ou zero. A soma dos efeitos de todos atributos corresponde a uma aproximação da predição $f(x)$ que se deseja explicar.

Assim, este trabalho tem como objetivo descobrir as características mais significativas que influenciam a má conduta de presos por meio de métodos de AM e o SHAP. A má conduta, neste contexto de aplicação, consiste na classificação de detentos em duas categorias: prisioneiros que quebram regras institucionais e aqueles que não o fazem. Para isso foi utilizada uma base de dados produzida em 2004 pelo *Bureau of Justice Statistics* [of Justice Statistics 2019] que fornece em nível nacional dados representativos sobre prisioneiros de instalações estaduais e federais dos Estados Unidos da América.

A partir da classificação prévia de um detento, acredita-se que os resultados desta pesquisa possam auxiliar os gestores de instituições correccionais na utilização de forma mais apropriada dos programas e práticas que visam a melhoria de vida dos infratores, a ressocialização e a reinserção social.

2. TRABALHOS RELACIONADOS

A má conduta interna é um problema universal nas prisões. Uma resposta chave é projetar e adotar procedimentos de classificação que identifiquem os reclusos propensos a se envolver em má conduta grave enquanto encarcerados. Dessa forma, será possível implementar estratégias de prevenção. Nesse contexto, pesquisadores têm empregado esforços para aplicar técnicas de AM tanto na predição da má conduta interna quanto na possibilidade de reincidência criminosa, como os trabalhos aqui citados.

Ngo et al. [2015], utilizando a mesma base de dados deste trabalho, compararam a acurácia de quatro métodos: regressão logística, árvore de regressão (CART), rede neural *Multilayer Perceptron* (MLP) e CHAID (*Chi-squared Automatic Interaction Detection*). O objetivo foi identificar métodos mais eficazes a serem usados na prevenção de riscos futuros relacionados à má conduta de um preso. Os autores selecionaram aleatoriamente 10.000 registros, escolheram 11 atributos da base de dados original e obtiveram de 61% a 66% de acurácia, sendo os melhores resultados obtidos com MLP.

Em continuidade ao trabalho publicado, e utilizando o mesmo conjunto de dados, Ngo et al. [2019] apresentaram um estudo sobre a eficácia dos métodos de regressão tradicionais versus *Random Forest* e redes neurais, de acordo com medidas de desempenho específicas, na predição da má conduta de detentos. Nesse trabalho foram utilizados 36 atributos preditores e um total de 10.328 registros. Os autores concluíram que cada método de classificação adotado é mais adequado para uma medida de desempenho preditiva específica. Por exemplo, para aumentar a acurácia na classificação de presos que vão se envolver em má conduta grave (ou seja, para maximizar a sensibilidade), a técnica *Expectation-Maximization* deve ser empregada, e para aumentar a acurácia na classificação de presos que não vão envolver-se em má conduta grave (ou seja, para maximizar a especificidade), *Random Forest* e redes neurais devem ser aplicadas. Por outro lado, para maximizar a acurácia geral da predição, as redes neurais são mais adequadas. Quanto à medida de desempenho da área sob a curva ROC (*Receiver*

Operating Characteristic), os três classificadores utilizados obtiveram comportamentos semelhantes.

Duwe [2020] propôs um sistema de classificação e predição de má conduta prisional grave a partir de dados do Departamento de Correções de Minnessota (MnDOC), que contém dados de 21.648 detentos entre os anos de 2006 e 2011. Os atributos preditores da base incluíam antecedentes criminais, características demográficas como idade na libertação e estado civil, tipo de admissão na prisão, tipo de crime, afiliação a gangues, dentre outros. O modelo de AM utilizado na classificação foi a regressão logística regularizada, que obteve uma curva ROC de 0,82. Segundo os autores, um sistema de classificação preciso pode ser empregado para melhorar segurança, não apenas identificando aqueles com maior risco, mas auxiliando na tomada de decisão sobre medidas para mitigá-lo. Além disso, reduzir a má conduta entre aqueles com maior risco também pode ser útil para reduzir a reincidência.

Chongmin et al. [2021] compararam o desempenho da regressão logística e das redes neurais na predição da detenção de jovens americanos. Foi utilizada uma amostra de estudantes de 11 a 21 anos do ensino fundamental e médio dos EUA matriculados em meados da década de 1990. Os participantes foram reentrevistados em 2008, quando tinham entre 24 e 34 anos, e foram questionados se já haviam sido presos. Contrariamente à expectativa dos autores, não foram observadas diferenças consideráveis na precisão preditiva entre os modelos. Segundo os autores, a regressão logística funcionou igualmente bem ou até mesmo superou as redes neurais para todas as medidas de desempenho comparadas.

3. MATERIAIS E MÉTODOS

Nesta seção são descritas as etapas do processo metodológico adotado no desenvolvimento do trabalho, desde a coleta dos dados até a interpretação dos resultados. A Figura 1 ilustra essas etapas e as subseções seguintes detalham cada delas.

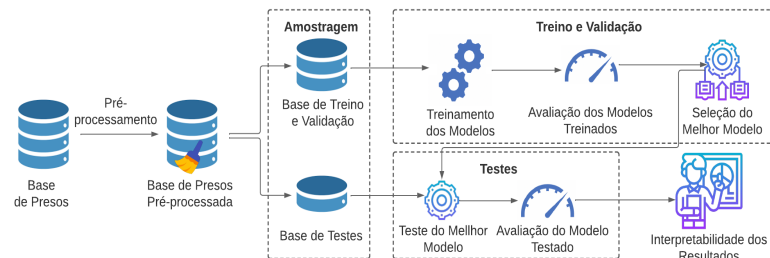


Fig. 1: Metodologia adotada no trabalho

3.1 Base de Dados de Presos

A base de dados utilizada neste trabalho foi produzida em 2004 por meio da pesquisa intitulada *Survey of Inmates in State and Federal Correctional Facilities* (SISFCF) [of Justice Statistics 2019], nos Estados Unidos da América, que fornece em nível nacional dados representativos sobre prisioneiros de instalações estaduais e federais. Ela contém 14.499 instâncias e 2.980 atributos organizados em 10 categorias, a saber: Características Individuais, Ofensa Atual Liberdade Condicional, Sentença Atual, Características do Incidente, Histórico Criminal, Características Socioeconômicas, Uso e Tratamento de Álcool e Drogas Condições Médicas, Saúde Mental e Deficiências e Programas Prisionais.

3.2 Pré-Processamento e Amostragem dos Dados

A partir do conjunto de dados de presos, foram realizadas as seguintes tarefas de pré-processamento:

- (1) *Redução da dimensionalidade*: considerou-se uma versão resumida do conjunto de dados original com 26 atributos. A escolha foi feita a partir da revisão sistemática de trabalhos publicados entre 1980 e 2013 que identificaram causas (variáveis preditoras) que podem levar à má conduta de detentos [Steiner et al. 2014]. Instâncias sem o atributo de classificação (258 de 14.499, ou 1,7%) foram eliminadas. Na sequência, instâncias com 12 ou mais atributos ausentes foram removidas, cerca de 4,5% dos registros. No final, 13.603 instâncias e 26 atributos (25 atributos de entrada e 1 de classe) foram utilizados¹;
- (2) *Conversão de tipos*: o atributo “*High Grade*” foi codificado com 1 até a quantidade de opções, os atributos “*Type of Offenses*” e “*Marital Status*” foram binarizados (detalhes mais adiante) e os dicotômicos receberam valor 0 (não) ou 1 (sim);
- (3) *Discretização de dados*: os atributos “idade” e “idade na primeira prisão” foram discretizados. O objetivo foi reduzir o número de valores para os respectivos atributos ao definir 6 categorias de idade (1: ≤ 24 anos; 2: 25-34 anos; 3: 35-44 anos; 4: 45-54 anos; 5: 55-64 anos; e 6: acima de 65 anos). Essa codificação foi baseada no trabalho de Shlafer et al. [2019], que utilizou a mesma base de dados aqui referenciada;
- (4) *Binarização de dados*: os atributos referentes ao estado civil (casado, solteiro, divorciado, viúvo e nunca se casou) e ao tipo de ofensa (violenta, propriedade, droga e ordem pública) foram binarizados, ou seja, cada categoria foi transformada em um novo atributo cujo valor correspondente é “0” ou “1”. Assim, a base de dados ficou com 33 atributos;
- (5) *Imputação de dados*: dos 352.277 dados, 96.622 são valores ausentes, cerca de 27% dos dados. Dos 33 atributos, 27 possuem dados ausentes. Para realizar as imputações, foi utilizado um método baseado em *Random Forest* descrito em Stekhoven e Bühlmann [2011]. Para a imputação foi utilizada a biblioteca em linguagem Python *Missingpy* que implementa o algoritmo *MissForest*. Ressalta-se que os métodos de imputação foram aplicados à base desconsiderando-se o rótulo de classe, para que nenhum viés pudesse ser adicionado aos dados.

Sobre a distribuição das instâncias de acordo as classes, a base de dados possui 6.604 que não quebraram regras e 6.998 que quebraram. Para a amostragem dos dados, a base de dados foi particionada em dois conjuntos estratificados, ou seja, mantendo as proporções de acordo com o rótulo de classe: 90% dos dados foram reservados para treino e validação dos modelos e 10% para os testes.

3.3 Treinamento, Testes e Interpretabilidade dos Modelos de AM

Dos 33 atributos resultantes, “*Breaking Any Rules*” representa a classe que indica se o preso foi citado ou considerado culpado de quaisquer violações da prisão. Assim, o objetivo da aplicação dos modelos de AM foi prever se um detento quebrará ou não regras institucionais.

Foram utilizados três modelos de classificação, sendo o primeiro de caixa branca e portanto interpretável, e os demais de caixa preta, reconhecidamente bons em contextos variados. São eles: árvore de decisão, *Random Forest* e rede neural do tipo MLP².

Para a árvore de decisão e *Random Forest* foi utilizado o critério de entropia para a escolha dos atributos, profundidade máxima igual a 10 e o número de atributos a serem utilizados deixado como padrão do objeto, ou seja, $max_features = \sqrt{n_features}$ ³. Para *Random Forest* foi ainda definido

¹Os atributos utilizados são: *Atributos quantitativos discretos*: Age, Age At First Arrest; *Atributos qualitativos nominais binários*: Race And Hispanic, Physically Abused, Mental Or Emotional Condition, Personality Disorder, Heroin and other opiates, Sex, Stimulants, Religious Activities, Depressants, Cocaine or crack, Prior Incarceration As Juvenile, Hallucinogens, Incarcerated For Sex Offense, Marijuana, Inhalants, Any other drug, Any Children, Previous Incarcerated, Job Or Business, Pressured You Sexual Contact, Breaking Any Rules (atributo de classe); *Atributos qualitativos nominais*: Type Of Offenses, Marital Status; *Atributos qualitativos ordinários*: High Grade.

²Esses modelos foram implementados em linguagem Python, versão 3.8.8, no ambiente *Jupyter Notebook* a partir das classes *DecisionTreeClassifier*, *RandomForestClassifier* e *MLPClassifier* disponibilizadas pelo pacote *Scikit-learn*.

³Disponível em <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>

um número máximo de 100 árvores para o classificador. Para a rede neural MLP foi utilizada uma única camada oculta com 15 neurônios, *learning rate* (taxa de aprendizado) igual a 0,2 e *momentum* de 0,3.

A partir do conjunto de treino e validação, a capacidade de generalização dos modelos foi avaliada com a validação cruzada de 10 partições ($K=10$). Para cada algoritmo foi realizado um comparativo das métricas Precisão (P)⁴, Sensibilidade (S)⁵ e *F1 Score* (F1)⁶ para as classes “Não” (não quebrou regras) e “Sim” (quebrou regras).

A abordagem SHAP foi utilizada para interpretar os resultados do classificador de melhor desempenho. O modelo de explicação gerado pelo SHAP pode receber uma amostra de dados como entrada e identificar os atributos que impactaram cada predição. Optou-se por aplicar o modelo de explicação ao mesmo conjunto de instâncias utilizados para os testes do classificador. Como resultado, o SHAP gera gráficos que aprofundam a compreensão do modelo e identificam os atributos mais relevantes na predição da má conduta.

4. RESULTADOS E DISCUSSÕES

Os resultados da validação cruzada e dos testes para cada classificador estão sumarizados na Figura 2. Como pode ser observado, o modelo *Random Forest* obteve os melhores resultados médios, com *F1-score* de 63% na validação cruzada e 64% nos testes.

Ao analisar um intervalo de confiança de 95% na validação cruzada de 10 partições em cada um dos modelos, os resultados foram os seguintes: (0,58; 0,61) para árvore de decisão, (0,61; 0,63) para *Random Forest* e (0,54; 0,59) para MLP. Assim, conclui-se que existe 95% de chances de encontrar um *F1 Score* entre 61% e 63% quando a amostra de dados mudar. Dessa forma, foi realizada a interpretabilidade com SHAP para esse modelo. Os atributos mencionados na descrição dos experimentos estão listadas na Tabela I, assim como a transformação numérica de seus valores.

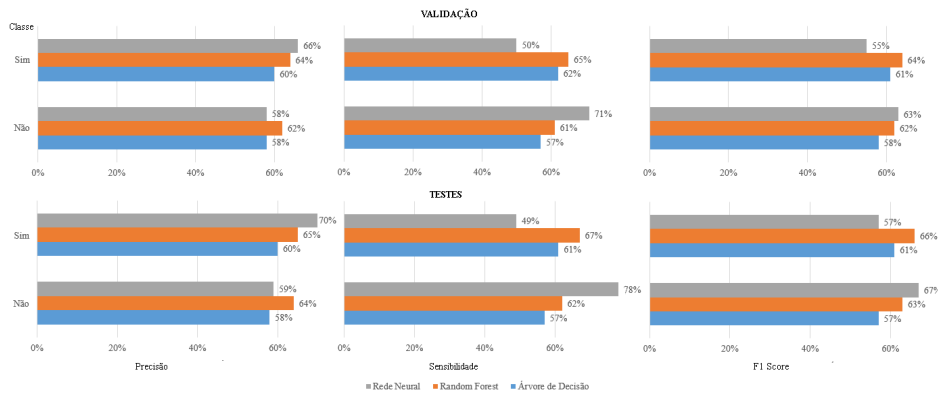


Fig. 2: Comparativo de desempenho na validação cruzada e nos testes.

A Figura 3 apresenta um dos gráficos do SHAP, que exhibe uma visão geral dos impactos dos principais atributos, por ordem de importância, na predição da má conduta. Cada ponto presente na linha de um determinado atributo representa uma instância impactada por ele. Se um ponto estiver do lado direito em relação ao eixo central, tal atributo aproxima o preso da classe “Sim” para má conduta. A cor do ponto representa o valor do atributo na instância (vermelho para os valores mais

$$^4 \text{Precisão} = \frac{VP}{VP+FP}$$

$$^5 \text{Sensibilidade} = \frac{VP}{VP+FN}$$

$$^6 \text{F1 Score} = \frac{(w+1) \times \text{Sensibilidade} \times \text{Precisão}}{\text{Sensibilidade} + w \times \text{Precisão}}, \text{ onde } VP=\text{Verdadeiro Positivo}, FP=\text{Falso Positivo} \text{ e } FN=\text{Falso Negativo}$$

Tabela I: Atributos destacados nos modelos de explicação.

Atributo	Descrição	Domínio
TypeOfOffensesViolent	Crime violento	Sim(1) Não(0)
Marijuana	Uso de drogas: marijuana	Sim(1) Não(0)
AgeFirstArrest	Idade na primeira prisão	7..70
TypeOfOffensesDrug	Crime por uso de drogas	Sim(1) Não(0)
Marital_NeverMarried	Nunca foi casado	Sim(1) Não(0)
AnyChildren	Tem filhos	Sim(1) Não(0)
EverDiagnosedAnyMentalOrEmotionalCondition	Problemas mentais/emocionais	Sim(1) Não(0)
BefAdmissionPhysicallyAbused	Fisicamente abusado antes da prisão	Sim(1) Não(0)
TypeOfOffensesProperty	Crime contra propriedade privada	Sim(1) Não(0)
Stimulants	Uso de drogas: estimulantes	Sim(1) Não(0)

altos e azul para os mais baixos). Ressalta-se que, quanto mais distante do eixo central do gráfico, mais significativo é o impacto desse atributo para uma determinada instância.




Fig. 3: Impacto dos atributos na previsão da má conduta.

Percebe-se que o atributo “*TypeOfOffensesViolent*”, que inclui homicídio, pornografia infantil ou abuso sexual de crianças, roubo a mão armada, estupro, extorsão, entre outros, é o que mais contribui para um comportamento de má conduta. Craig e Trulson [2019] mostraram que cometer um crime violento é um importante preditor de envolvimento em má conduta institucional. Para Steiner [2018], o comportamento de um detento pode ser uma manifestação de cultura latente ou experiências de pré-encarceramento. Como mostrou o estudo realizado por Steiner et al. [2014], as prisões com maior densidade de detentos encarcerados por ofensas violentas e com menos de 25 anos de idade, frequentemente tinham taxas mais altas de má conduta. Os resultados também evidenciaram atributos referentes a crimes relacionados a drogas (“*TypeOfOffensesDrug*”: posse ilegal, fabricação, distribuição, venda ou uso de uma droga ou substância controlada e alteração ilegal de prescrições) e propriedades (“*TypeOfOffensesProperty*”: crime no qual uma propriedade é tomada, danificada ou destruída por fraude ou engano). No entanto, esses não foram associados a má conduta.

Ao analisar a associação entre o uso de drogas (atributo “*Marijuana*”) e a má conduta, a literatura mostra uma relação positiva [Steiner et al. 2014] [Rowell-Cunsolo et al. 2016] [Leigey 2019] [Kuo 2020] [Nguyen et al. 2021]. A teoria da importação afirma que os indivíduos importam as suas características para um centro correcional. Assim, as violações de regras por uso de substâncias ilícitas, por exemplo, podem ser causadas/explicadas pela experiência antes da prisão. Além disso, o estudo realizado por Jiang e Fisher-Giorlando [2002] indicou que os internos que relataram maior uso de drogas e álcool antes do encarceramento tiveram maior número de incidentes violentos enquanto presos.

Conforme estudo realizado por Berk et al. [2006], a má conduta interna tem o seu maior impacto nos reclusos detidos muito jovens, como apontado na Figura 3 (“*AgeFirstArrest*”). Houser e Welsh [2014] reforçam que o envolvimento anterior com o sistema de justiça criminal e a idade na primeira ocorrência estão positivamente relacionadas à má conduta. Cihan et al. [2017] afirmam que a idade na primeira prisão está significativamente associada à má conduta, e reforçam que os presos com longas fichas criminais são mais propensos a continuar cometendo crimes enquanto encarcerados.

Como observado na Figura 3, o fato de não ser casado (atributo “*Marital_NeverMarried*”) influenciou positivamente para a quebra de regras institucionais. Estudos apontam que o estado civil do

detento afeta o seu comportamento interno; nesse caso presos casados têm menor envolvimento com a má conduta [Tewksbury et al. 2014] [Dâmboeanu e Nieuwbeerta 2016] [Cihan e Sorensen 2019].

A saúde mental também é uma característica relevante na predição da má conduta (atributo “*Ever-DiagnosedAnyMentalOrEmotionalCondition*”). De acordo com Severson [2019], a má conduta está relacionada com a história de vida de problemas de saúde mental do detento. Houser et al. [2012] concluíram que o risco de mau comportamento é maior para presos com doença mental, principalmente aqueles com transtorno de dependência/abuso de drogas.

Os resultados mostraram a influência de não ter filhos na predição de má conduta (atributo “*Any-Children*”). As conclusões apontadas por Swanson et al. [2012] indicam que o relacionamento dos detentos com seus filhos contribuiu positivamente para um suporte social e tem um papel importante na prevenção de crimes.

Uma correlação positiva entre a vítima de abuso físico (atributo “*BefAdmissionPhysicallyAbused*”) e a má conduta interna de detentos foi evidenciada neste trabalho. Esse fato corrobora com o estudo realizado por Meade et al. [2021], que concluiu que presos abusados fisicamente antes do encarceramento tiveram maior envolvimento com agressões a funcionários ou outros detentos.

5. CONCLUSÃO

A proposta de classificação de presos entre aqueles que quebram regras e os que não o fazem é relevante para o contexto da aplicação, seja para indicação em um programa de reabilitação ou mesmo na identificação do nível de segurança ao qual o detento deve ser submetido.

Alguns métodos de AM foram testados para prever má conduta de presos e o *Random Forest* mostrou-se o mais adequado para o cenário em questão. Além disso, a abordagem SHAP provou ser essencial para entender as decisões do modelo e destacar os atributos mais importantes.

As pesquisas apontam fatores distintos que influenciam o comportamento interno de detentos e, como discutido neste artigo e consolidado por outros trabalhos, a má conduta pode estar relacionada ao tipo de crime cometido, idade na primeira prisão, uso de drogas, não possuir filhos, não ser casado e ter sido vítima de abuso. Como forma de preparar para o retorno à sociedade e reduzir a reincidência, os detentos devem receber oportunidades enquanto encarcerados para atender as necessidades de saúde e desenvolver habilidades de vida e trabalho. Logo, acredita-se que programas voltados para a reinserção na sociedade, educacionais e profissionais tanto para jovens quanto adultos, cuidados com a saúde mental, família e tratamento contra o uso de drogas, entre outros, são fundamentais para mitigar o problema da má conduta.

Os atributos e ações quando percebidos merecem atenção das autoridades correccionais. Assim, espera-se que os resultados obtidos possam contribuir para que as autoridades e instituições envolvidas atuem de forma preventiva, desenvolvendo ações e/ou campanhas para garantir uma boa conduta dos detentos, a sua reinserção na sociedade e reduzir, posteriormente, a reincidência.

Como trabalho futuro sugere-se o enriquecimento da base de dados, já que outros atributos se fazem presentes no conjunto original. Dessa forma, os modelos resultantes poderão evidenciar interpretações distintas a serem comparadas com aquelas aqui apresentadas. Além disso, trata-se de um problema complexo e esforços futuros deverão ser empregados para melhorar o desempenho dos modelos de AM.

REFERÊNCIAS

- BERK, R. A., KRIEGLER, B., AND BAEK, J. H. Forecasting dangerous inmate misconduct: An application of ensemble statistical procedures. *Journal of Quantitative Criminology* 22 (2): 131–145, 2006.
- CHONGMIN, N., GYEONGSEOK, O., JUYOUNG, S., AND HYOUNGAH, P. Do machine learning methods outperform traditional statistical models in crime prediction? a comparison between logistic regression and neural networks. *Korean Journal of Policy Studies* 36 (1): 1–13, 2021.

- CIHAN, A., DAVIDSON, M., AND SORENSEN, J. Analyzing the heterogeneous nature of inmate behavior: Trajectories of prison misconduct. *The Prison Journal* 97 (4): 431–450, 2017.
- CIHAN, A. AND SORENSEN, J. R. Examining developmental patterns of prison misconduct: An integrated model approach. *International Journal of Offender Therapy and Comparative Criminology* 63 (14): 2406–2421, 2019. PMID: 31088194.
- CRAIG, J. M. AND TRULSON, C. R. Continuity of the delinquent career behind bars: Predictors of violent misconduct among female delinquents. *Aggression and Violent Behavior* vol. 49, pp. 101301, 2019. Longitudinal studies linking early risk factors to violence and/or prevention/intervention strategies.
- DUWE, G. The development and validation of a classification system predicting severe and frequent prison misconduct. *The Prison Journal* 100 (2): 173–200, 2020.
- DĂMBOEANU, C. AND NIEUWBEERTA, P. Importation and deprivation correlates of misconduct among romanian inmates. *European Journal of Criminology* 13 (3): 332–351, 2016.
- GARCÍA-GOMIS, A., VILLANUEVA, L., AND JARA, P. Risk factors and youth recidivism prediction in general and property offenders. *Psychiatry, Psychology and Law* vol. 24, pp. 1–11, 11, 2016.
- HOUSER, K. A., BELENKO, S., AND BRENNAN, P. K. The effects of mental health and substance abuse disorders on institutional misconduct among female inmates. *Justice Quarterly* 29 (6): 799–828, 2012.
- HOUSER, K. A. AND WELSH, W. Examining the association between co-occurring disorders and seriousness of misconduct by female prison inmates. *Criminal Justice and Behavior* 41 (5): 650–666, 2014.
- JIANG, S. AND FISHER-GIORLANDO, M. Inmate misconduct: A test of the deprivation, importation, and situational models. *The Prison Journal* 82 (3): 335–358, 2002.
- KUO, S.-Y. The effects of mental health and substance abuse/dependence disorders on prison misconduct among male inmates in taiwan. *International Journal of Offender Therapy and Comparative Criminology* 64 (9): 953–976, 2020. PMID: 31884841.
- LEIGEY, M. E. Female institutional misconduct: A test of deprivation, importation, and gendered importation theories. *The Prison Journal* 99 (3): 343–362, 2019.
- LUNDBERG, S. M. AND LEE, S.-I. A unified approach to interpreting model predictions. In *Proceedings of the 31st international conference on neural information processing systems*. pp. 4768–4777, 2017.
- MEADE, B., WASILESKI, G., AND HUNTER, A. The effects of victimization prior to prison on victimization, misconduct, and sanction severity during incarceration. *Crime & Delinquency* 67 (12): 1856–1878, 2021.
- NGO, F., GOVINDU, R., AND AGARWAL, A. Traditional regression methods versus the utility of machine learning techniques in forecasting inmate misconduct in the united states: An exploration of the prospects of the techniques. *International Journal of Criminal Justice Sciences* vol. 13, pp. 420–437, 06, 2019.
- NGO, F. T., GOVINDU, R., AND AGARWAL, A. Assessing the predictive utility of logistic regression, classification and regression tree, chi-squared automatic interaction detection, and neural network models in predicting inmate misconduct. *American Journal of Criminal Justice* 40 (1): 47–74, 2015.
- NGUYEN, H., MIDGETTE, G., LOUGHRAN, T., AND ZHANG, Y. Random drug testing in prisons: Does a little testing go a long way? *Criminology & Public Policy* 20 (2): 329–349, 2021.
- OF JUSTICE STATISTICS, U. S. B. Survey of inmates in state and federal correctional facilities, [united states], 2004, 2019.
- QAYYUM, S., HAFSA, S., AND DAR, H. Survey of data mining techniques for crime detection. *University of Sindh Journal of Information and Communication Technology (USJICT)* 2 (1): 1–6, 2018.
- ROWELL-CUNSOLO, T. L., SAMPONG, S. A., BEFUS, M., MUKHERJEE, D. V., AND LARSON, E. L. Predictors of illicit drug use among prisoners. *Substance Use & Misuse* 51 (2): 261–267, 2016. PMID: 26789438.
- SEVERSON, R. E. Gender differences in mental health, institutional misconduct, and disciplinary segregation. *Criminal Justice and Behavior* 46 (12): 1719–1737, 2019.
- SHLAFER, R., DUWE, G., AND HINDT, L. Parents in prison and their minor children: Comparisons between state and national estimates. *The Prison Journal* 99 (3): 310–328, 2019.
- STEINER, B. Measuring and explaining inmate misconduct. *The Oxford handbook of prisons and imprisonment*, 2018.
- STEINER, B., BUTLER, H., AND ELLISON, J. Causes and correlates of prison inmate misconduct: A systematic review of the evidence. *Journal of Criminal Justice* vol. 42, pp. 462–470, 12, 2014.
- STEKHOVEN, D. J. AND BÜHLMANN, P. MissForest—non-parametric missing value imputation for mixed-type data. *Bioinformatics* 28 (1): 112–118, 10, 2011.
- SWANSON, C., LEE, C.-B., SANSONE, F. A., AND TATUM, K. M. Prisoners' perceptions of father-child relationships and social support. *American Journal of Criminal Justice* 37 (3): 338–355, 2012.
- TAYLOR, M. Improving in-prison rehabilitation programs. *Legislative Analyst's Office*, 2017. Accesso: 29-03-2018.
- TEWKSBURY, R., CONNOR, D., AND DENNEY, A. Disciplinary infractions behind bars: An exploration of importation and deprivation theories. *Criminal Justice Review* vol. 39, pp. 201–218, 04, 2014.