

MACHINE LEARNING NA SEGURANÇA PÚBLICA: UMA ANÁLISE DE POSSÍVEIS PROBLEMAS MECÂNICOS EM VIATURAS POLICIAIS

Ronnie Carlos Tavares Nunes¹
Bartholomeo Oliveira Barcelos²
Alexandre Leopoldo Gonçalves³

Abstract: *The purpose of this paper is to identify the feasibility of applying artificial intelligence tools to detect possible vehicular problems, reported by police officers, that have the potential to cause serious accidents. Machine learning was used as a tool to analyze textual data extracted from the system Computerized Daily Part, a system used by the Federal Highway Police that registers operational data. The methodology used employs the supervised learning approach. The results indicated the viability of the tool, and the Logistic Regression algorithm presented the best result, with an accuracy of 0.835. However, the study highlighted the need for a robust data set to train the machine learning algorithm.*

Keywords: *artificial intelligence; public security; operational vehicles; text analysis.*

Resumo: O objetivo deste artigo é identificar a viabilidade de aplicação das ferramentas da inteligência artificial para detecção de possíveis problemas veiculares, reportados pelos policiais, que possuem potencial para causar acidentes graves. Foi utilizado o aprendizado de máquina como ferramenta para análise de dados textuais extraídos do sistema Parte Diária Informatizada, um sistema utilizado pela Polícia Rodoviária Federal que registra dados operacionais. A metodologia utilizada emprega a abordagem de aprendizado supervisionado. Os resultados indicaram a viabilidade da ferramenta, sendo que o algoritmo de Regressão Logística apresentou o melhor resultado, com uma acurácia de 0,835. Entretanto, o estudo evidenciou a necessidade de um conjunto de dados robusto para realizar o treinamento do algoritmo de aprendizado de máquina.

Palavras-chave: inteligência artificial; segurança pública; viaturas operacionais; análise de texto.

1. INTRODUÇÃO

As ferramentas tecnológicas desenvolvidas pela área de Inteligência Artificial têm proporcionado suporte técnico para empregabilidade em diversas áreas, e no campo da segurança pública vem determinando o seu futuro (Luger, 2013; Ying, 2020). São exemplos de aplicações na

¹Mestre em Engenharia e Gestão do Conhecimento, Universidade Federal de Santa Catarina (UFSC), Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-2373-511X>. E-mail: rocatan@ig.com.br

²Mestre em Engenharia de Produção, Universidade Federal de Santa Catarina (UFSC), Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0003-1178-1212>. E-mail: barthobarcelos@gmail.com

³Professor Dr. do Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC), Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-6583-2807>. E-mail: a.l.goncalves@ufsc.br

área de segurança pública as aplicações relacionadas a reconhecimento de imagem e objetos (Machiraju et al., 2021); reconhecimento de faces heterogêneas (Fu et al., 2021); agentes inteligentes que interagem com a população através de chatbots (dos SANTOS et al., 2020) e monitoramento de vias (Ferreira, 2018).

A Polícia Rodoviária Federal (PRF), órgão permanente do Ministério da Justiça e Cidadania, foi criada em 1928 pelo então presidente Washington Luiz, sob a denominação de “Polícias de Estradas” (PRF, 2021). As viaturas policiais do órgão devem estar cadastradas previamente no sistema de Parte Diária Informatizada antes do seu efetivo uso operacional. Esse sistema possui o Cartão-Programa, destinado a direcionar as atividades de fiscalização da equipe e a Parte Diária da Viatura, destinada ao registro de deslocamentos, abastecimentos, troca de óleo, quilometragem percorrida e alterações que foram percebidas pelos policiais, antes ou durante o serviço.

São consideradas alterações quaisquer fatos observados que podem ou não comprometer o uso das viaturas, podendo ser registrado desde um simples amassado, a problemas mais graves, como funcionamento inadequado de freios ou problemas nos pneus.

A manutenção preventiva da viatura é primordial para a segurança da equipe, pois por vezes é necessário o deslocamento em altas velocidades durante os acompanhamentos táticos, que exigem destreza e habilidade do motorista. Se em situações normais problemas mecânicos podem causar acidentes, em situações críticas, qualquer defeito apresentado pode desencadear um grave acidente, colocando em risco toda a equipe.

No dia dezoito de novembro de 2020, ocorreu um grave acidente com uma viatura da PRF. Três policiais estavam na viatura em um deslocamento sob intensa chuva, quando o motorista perdeu o controle e o veículo capotou. Dois policiais sofreram ferimentos leves, mas o terceiro veio a óbito no local. Após verificação da Parte Diária da Viatura, observou-se as seguintes observações no campo destinado ao registro das alterações do veículo: *“Borracha da porta lateral esquerda não encaixa; Intermitente de emergência apaga sozinho; Tampa inferior da caçamba amassada; Luzes auxiliares laterais em mau funcionamento; **Pneu traseiro direito com vazamento constante;***

barulho estranho vindo do sistema de freios, como se fosse disco arranhando; viatura desalinhada, puxando para a direita” (grifo nosso) (FENAPRF, 2020).

Esses relatos de problemas com uma suposta probabilidade de ocasionar acidentes graves merece intervenção imediata do gestor, no sentido de não disponibilizar o veículo para uso, de modo que sejam providenciadas as manutenções corretivas necessárias para solucionar os supostos problemas.

O sistema transaccional por si só, não consegue informar ao gestor este tipo de problema, em virtude de ser um campo texto, onde uma ou mais alterações menos significativas podem ser inseridas. Desta forma, é necessário o uso de técnicas adequadas para prospectar o texto inserido no campo para identificar se nas observações relatadas existe alguma alteração com capacidade de ocasionar um acidente grave, de modo a alertar o gestor para a necessidade de uma rápida intervenção.

Este artigo pretende analisar a viabilidade de aplicação do aprendizado de máquina, utilizando a abordagem de aprendizado supervisionado, para identificação de problemas relatados na Parte Diária de Viatura que têm o potencial de causar um acidente grave. O artigo foi organizado da seguinte forma: o primeiro capítulo corresponde a esta introdução; o capítulo dois faz uma breve revisão da literatura aplicada ao tema, discutindo os conceitos de IA, os paradigmas de aprendizagem e a descoberta de conhecimento em texto; o terceiro capítulo aborda os aspectos metodológicos; e por fim, o quarto e quinto capítulos apresentam os resultados, a discussão sobre esses resultados e as considerações finais.

2. INTELIGÊNCIA APLICADA

Esta seção reflete sobre os principais construtos que orientam os objetivos desta pesquisa, apresentando uma breve revisão sobre a Inteligência Artificial (IA), o Aprendizado de Máquina e a Descoberta de Conhecimento em Texto.

2.1. INTELIGÊNCIA ARTIFICIAL

O termo Inteligência Artificial (IA) possui uma complexidade em sua definição que acompanha a dificuldade de se definir o termo inteligência. (Franco, 2014) destaca que o ser humano consegue identificar se um comportamento é ou não inteligente quando parte dos seres

vivos (humanos ou animais), mas esta afirmação fica mais complexa quando se trata de observar softwares. É um domínio da Ciência e Engenharia, que Tecuci (2012) aborda como “a teoria e prática de desenvolver sistemas que exibem as características que são associadas à inteligência no comportamento humano, como: percepção, processamento de linguagem natural, solução e planejamento de problemas, aprendizagem e adaptação, e agindo sobre o meio ambiente”.

Dentre as definições de IA na literatura, Medeiros (2018) destaca que existem distintas interpretações da correlação dos processos de IA com os mecanismos do cérebro e da mente humana, enquanto Luger (2013) a define como um ramo da ciência da computação que trata da automação do conhecimento inteligente.

2.2. APRENDIZADO DE MÁQUINA

O grande volume de informações que hoje é possível ser processado por máquinas nas organizações é influenciado pelo avanço da Tecnologia da Informação e pelo fenômeno do *Big Data* em nossa sociedade. Neste contexto, Franco (2014) destaca que para as organizações é um fator competitivo desenvolver formas ágeis para processar grandes volumes de dados de forma confiável, sendo esta uma das áreas de atuação da *Machine Learning* (ML), uma das áreas da IA.

Nas reflexões de Luger (2013), a ML envolve o desenvolvimento de programas que aprendem, por meio de uma generalização oriunda de uma experiência de treinamento ligada a uma tarefa, bem como em experiências de tarefas semelhantes dentro do mesmo domínio analisado.

Conforme Alloghani et al. (2020), a maioria dos artigos reconhecem duas abordagens de aprendizado de máquina: a supervisionada e a não supervisionada. O que diferencia essas duas classes é a existência de rótulos no subconjunto de dados de treinamento. Sobre essas duas classes de aprendizagem, Franco (2014) e Russell e Norvig (2013), refletem:

- Aprendizagem não supervisionada: o agente inteligente aprende padrões na entrada dos dados, embora não seja fornecido nenhum feedback explícito sobre as saídas esperadas pelo algoritmo, assim, a máquina deve identificar novos padrões para a geração das saídas corretas.
- Aprendizagem supervisionada: o agente observa os dados de entrada e saída, e aprende uma função a partir de um banco de dados de treinamento, que faz o mapeamento das

entradas para a saída de dados, no qual o objetivo da máquina é aprender a produzir as saídas corretas para a entrada de novos dados.

Referente a estes dois tipos de aprendizado, Berry et al. (2020) reforçam que, na aprendizagem não supervisionada, o algoritmo faz uso de dados de entrada que não foram classificados e categorizados para treinamento, devendo extrair os parâmetros ideais (características e semelhanças) para o modelo. Na aprendizagem supervisionada, o algoritmo recebe um conjunto de dados de entrada com informações *à priori* (rotuladas) para orientar o processo de aprendizagem, a fim de evidenciar a capacidade do algoritmo de generalizar o conhecimento dos dados de entrada para prever novos casos (não rotulados).

Em uma revisão sistemática da literatura para mapear os principais algoritmos utilizados como técnicas na *Data Science*, Alloghani et al. (2020), identificaram que os algoritmos de aprendizagem não supervisionada mais discutidos foram: *K-means*, *Hierarchical Clustering*, and *Principal Component Analysis*, e os algoritmos de aprendizagem supervisionada mais comumente utilizados foram: *Decision Tree*, *Naïve Bayes*, e *Support Vector Machine*.

2.3. KNOWLEDGE DISCOVERY IN DATA (KDD)

A *Knowledge Discovery in Data* (KDD) é também conhecida pelo nome *Data Mining* (DM), e possui como objetivo “extrair conhecimento potencialmente útil e previamente desconhecido de grandes quantidades de dados” (Kodratoff, 1999, p. 5). O KDD, também pode ser definido como o processo não trivial de identificar padrões novos, válidos, potencialmente úteis e compreensíveis nos dados (Piatetsky-Shapiro et al., 1992).

Ainda na década de 1990, Feldman e Dagan (1995) destacaram que para a realização de tarefas em KDD era necessário que os dados estivessem estruturados, bem como esta estrutura deveria refletir a forma como o usuário conceitua o domínio descrito pelos dados.

Dessa forma, destaca-se que o KDD é a descoberta de conhecimento em base de dados estruturados, enquanto que para a descoberta de conhecimento em base de dados não estruturados, normalmente em textos, é chamada de *Knowledge Discovery from Text* (KDT) (Da Silva, 2020).

2.3.1. Knowledge Discovery in Texts (KDT)

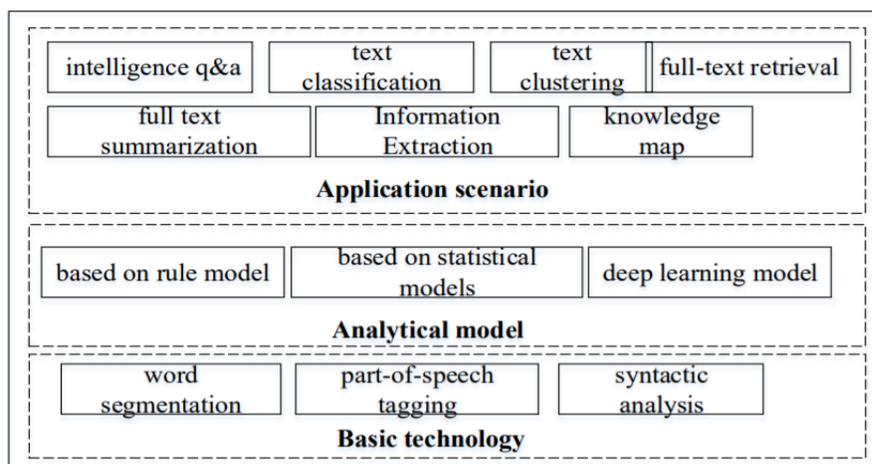
O KDT para Feng et al. (2017) é o processo de derivar informações úteis do texto. Para

Gupta et al. (2009), o mesmo termo pode também ser conhecido como *Text Mining* (TM), *Intelligent Text Analysis* ou *Text Data Mining*, definições que se referem ao processo de extração de informações e conhecimentos interessantes e não triviais de texto não estruturado, sendo considerado um campo interdisciplinar que se baseia na recuperação de informações, utilizando *Data Mining*, *Machine Learning*, estatística e *computational linguistics*.

Sobre a utilização de textos que são dados não estruturados, Feldman e Dagan (1995) destacaram que o pesquisador é quem deve decidir qual estrutura irá impor aos dados. Porém, na década de 1990, existiam limitações tecnológicas que dificultavam um processamento mais robusto de base de dados em texto de forma automatizada.

Portanto, o processo de KDT consiste no pré-processamento do texto, extração de recursos do texto e descoberta de conhecimento (Li et al., 2018). A Figura 1, apresenta os cenários de aplicação, os modelos analíticos e as técnicas básicas de aplicação.

Figura 1 - Técnicas de Text Mining, modelos e cenários de aplicação



Fonte: Li et al. (2018)

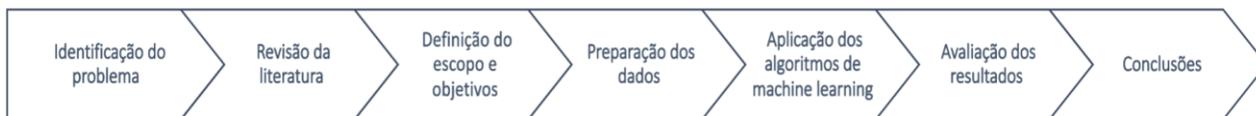
Sobre a utilização de *Text Mining* (TM) na identificação de problemas e falhas, alinhados aos objetivos desta pesquisa, podemos destacar os estudos de Blanco-M et al. (2019), que utilizaram a TM em ordens de serviço para detectar, por meio de ferramentas de aprendizado de máquina, as palavras essenciais utilizadas pelo pessoal de manutenção no reparo de turbinas empregando os algoritmos *Decision Tree* e *Random Forest*. Outro estudo foi o de Li et al. (2018) empregou algoritmos de TM para estudo dos relatórios de análise de acidentes e falhas ferroviárias

que inclui informações como hora, local, trem e a análise da causa do acidente ou falha, lições aprendidas e corretivas. Considerou aspectos que podem auxiliar os gestores na tomada de decisão com medidas específicas para evitar acidentes e falhas.

3. ASPECTOS METODOLÓGICOS

Para que o objetivo de identificar possíveis problemas veiculares com potencial para causar acidentes graves seja alcançado, foram utilizadas técnicas de aprendizado de máquina como ferramenta para análise de dados textuais extraídos do sistema denominado “Parte Diária Informatizada” da PRF. Essa pesquisa pode ser considerada como exploratória, com abordagem quantitativa de origem tecnológica. O processo de pesquisa é representado pelo fluxo na Figura 2:

Figura 2 - Fluxo metodológico



Fonte: Os autores

Como suporte para a preparação dos dados, aplicação dos algoritmos e avaliação dos resultados, foi utilizada a ferramenta *Orange Data Mining* (Demšar et al., 2013).

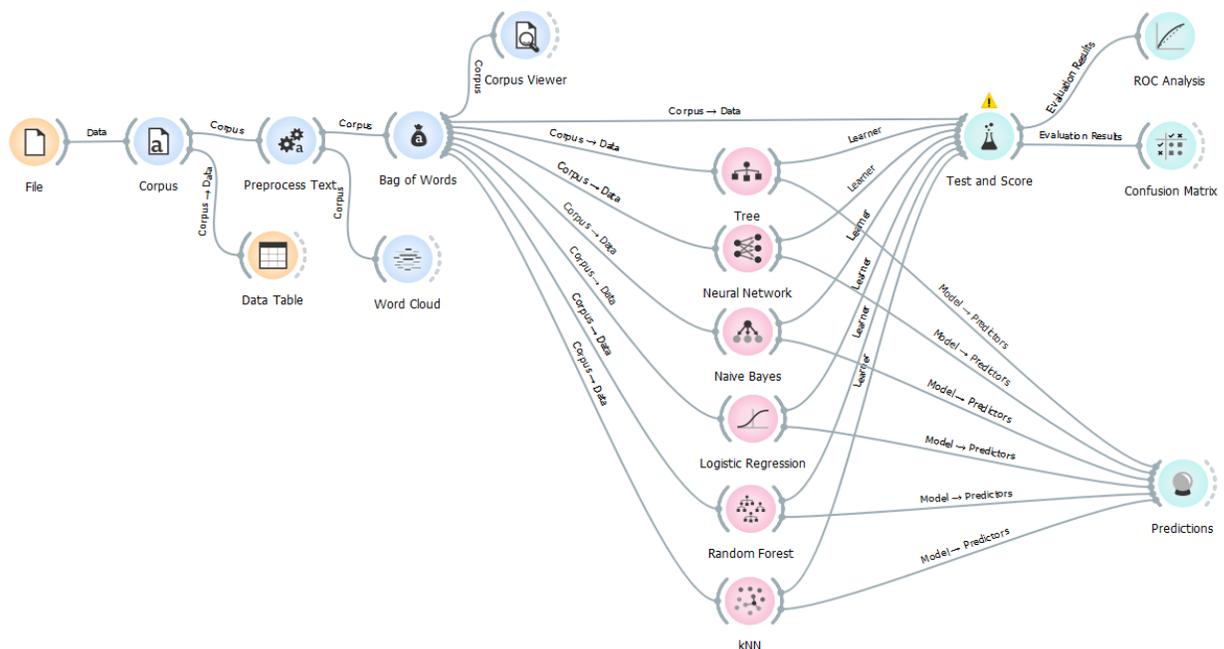
A coleta de dados foi realizada com a extração dos dados do sistema “Parte Diária Informatizada” resultando em cerca de 40.000 registros. Esses registros são relatos textuais livres de anotações realizadas pelos policiais rodoviários federais no sistema, como fatos observados que podem ou não comprometer o uso das viaturas, podendo ser registrado textualmente desde um simples amassado, a problemas mais graves, como funcionamento inadequado de freios ou problemas nos pneus.

Como etapa de pré-processamento destes dados, foi realizada inicialmente uma limpeza manual dos dados, para a exclusão de caracteres especiais e registros duplicados que pudessem comprometer a classificação do modelo. Posteriormente, observou-se a necessidade de criação de um *script* em *Python* para realização automática das tarefas de limpeza. Esta etapa reduziu significativamente o *dataset*, pela existência de inúmeros registros duplicados, restando para análise cerca de 2.490 registros.

Para a tarefa de classificação dos dados considerou-se a abordagem de distinção dicotômica entre as duas classes, onde são atribuídos rótulos de classe 0 ou 1 a um item de dados desconhecido, como destacado no estudo de Dreiseitl e Ohno-Machado (2002). Na sequência foi realizada a atribuição de rótulos aos dados, sendo que foi atribuído o rótulo 1, para registros que apresentam alguma alteração que possa indicar um problema com potencial para causar um acidente grave e o rótulo 0 para os demais registros onde as alterações observadas não foram consideradas como relevantes.

Após o tratamento e preparação da base de dados, os 2490 registros serviram de *input* para o Orange, onde desenvolveu-se o modelo de classificação para predição de possíveis problemas veiculares com potencial para causar acidentes graves. Na Figura 3 é apresentado o *workflow* com as etapas realizadas para treinamento de cada um dos algoritmos, de modo que se possa analisar qual gerou a melhor resultado de predição.

Figura 3 - Workflow



Fonte: Os autores.

Destaca-se que o conjunto de dados foi submetido a uma nova etapa de pré-processamento do texto no Orange devido à necessidade de *tokenização* e retirada das *stop-words*. Após isso,

utilizou-se a configuração padrão do software para todas as fases, pois não faz parte do escopo deste trabalho avaliar cada parâmetro específico do software. Ainda assim, é possível que algumas alterações em diferentes parâmetros possam contribuir para uma melhor performance. O componente “*Bag of Words*” foi empregado para criar um conjunto com a contagem das palavras para cada instância de dados, gerando 25394 *tokens* a partir dos 2491 registros.

Na sequência, foram testados os algoritmos de predição: Árvore de Decisão, Redes Neurais, *Naive Bayes*, Regressão Logística, *Random Forest* e kNN, a fim de avaliar qual destes apresenta o melhor resultado para o conjunto de dados. O desempenho do treinamento do *dataset* foi avaliado utilizando o componente “*Test and score*”, analisando-se três parâmetros técnicos em cada algoritmo testado: *Accuracy*, *Precision* e *Recall*. Estes parâmetros auxiliam na identificação do algoritmo que melhor identifica os possíveis problemas veiculares com potencial para causar acidente grave na frota de viaturas.

4. DISCUSSÃO E RESULTADOS

Para se explorar o potencial das ferramentas de inteligência artificial na detecção de possíveis problemas veiculares, com chances de causar acidentes graves, o conjunto de dados foi obtido do Sistema de Parte Diária, área onde são inseridas as informações, em formato de texto, da Parte Diária da Viatura, especificamente, no campo “Observações”, sendo um requisito do sistema o seu preenchimento obrigatório.

O conjunto de dados exigiu um denso pré-processamento, uma vez que os registros realizados pelos seus usuários, apresentam por vezes valores repetidos, utilização de caracteres diversos para indicar a inexistência de algum problema, ou mesmo siglas como “s/a”, que significa “sem alteração”. Ainda, alguns registros possuem um registro detalhado de todos os itens veiculares analisados e não somente as alterações, de forma desnecessária. Essa etapa do estudo permitiu identificar os termos que apresentam maior ocorrência no conjunto de dados (Figura 4). A análise se estes relatos retratam um problema que tem potencial para causar um acidente grave foi possível através do auxílio dos policiais rodoviários que são especialistas neste domínio. Os registros com o rótulo 1, indicavam um problema com potencial para causar um acidente grave, e os registros com rótulo 0 indicavam que as alterações foram consideradas não relevantes.

No entanto, foi identificado uma falta de balanceamento entre os rótulos do conjunto de dados, como pode ser analisado na Figura 6, já que a quantidade de dados que foram rotulados com “1” foram consideravelmente menores do que os dados rotulados com “0”. Dessa forma, o conjunto foi ajustado de modo que a quantidade de registros rotulados com “0” ficassem próximos da quantidade de registros rotulados com “1”. Esse ajuste gerou uma mudança nos resultados indicando o algoritmo de Regressão Logística como melhor resultado. Este algoritmo calcula a probabilidade de associação de uma classe para uma das categorias no conjunto de dados, estimando a probabilidade de a variável dependente assumir um determinado valor em função dos dados conhecidos de outras variáveis, bem com é indicado quando o método de pesquisa é focado em se um evento ou não ocorreu (Dreiseitl & Ohno-Machado, 2002).

Figura 7 - Avaliação dos resultados

Model	AUC	CA	F1	Precision	Recall
kNN	0.822	0.736	0.733	0.747	0.736
Tree	0.767	0.779	0.779	0.779	0.779
Random Forest	0.885	0.800	0.800	0.801	0.800
Neural Network	0.877	0.804	0.804	0.804	0.804
Naive Bayes	0.867	0.774	0.772	0.785	0.774
Logistic Regression	0.904	0.834	0.834	0.835	0.834

Fonte: Os autores.

Figura 8 - Nova Matriz de Confusão

	0.0	1.0	Σ
0.0	84.6 %	15.4 %	700
1.0	17.7 %	82.3 %	719
Σ	719	700	1419

Fonte: Os autores.

Após o novo treinamento do modelo com os dados balanceados, a Figura 7 evidencia que o algoritmo de Regressão Logística apresentou melhor assertividade em relação aos outros modelos testados. A Figura 8, apresenta a nova Matriz de Confusão, com uma distribuição mais equilibrada em relação aos acertos em ambas as classes.

5. CONSIDERAÇÕES FINAIS

Observou-se que a predição dos registros que possuem potencial para causar um acidente grave foi consideravelmente menor do que os registros que não tem esse potencial, quando o conjunto de dados para treinamento não estava devidamente balanceado. Após o balanceamento, houve melhora na assertividade de ambos os rótulos. Um incremento na quantidade de registros

pode ser também considerado para melhorar a eficácia da predição, já que a quantidade representa um aspecto importante para o treinamento do algoritmo de aprendizagem de máquina. Quanto maior a quantidade de dados rotulados (ou seja, o conjunto de dados), maior a assertividade do algoritmo de predição.

Após a limpeza dos dados a quantidade inicial de registros caiu drasticamente. Esse fato sugere que os policiais muitas vezes replicam as alterações da escala anterior, no intuito de que as alterações apresentadas pela viatura não sejam esquecidas.

O algoritmo de Regressão Logística apresentou o melhor resultado para o conjunto de dados, mas a assertividade da predição talvez ainda pode ser melhorada através da alteração do idioma do conjunto de dados para o inglês, de modo a verificar se haveria uma melhora na ocorrência de falsos positivos.

Os parâmetros de cada ferramenta do *Orange* foram utilizados em sua configuração padrão. Futuramente se faz necessário outros testes com a alteração de alguns desses parâmetros, de modo a avaliar se haverá ou não ganho de assertividade.

Consideramos relevante e promissora a utilização de técnicas de aprendizado de máquina para informar quando um problema registrado na Parte Diária de Viatura tem potencial para causar um acidente grave, caso nenhuma ação imediata seja tomada. Assim, a implementação dessa funcionalidade no Sistema de Parte Diária pode ajudar aos gestores a identificarem prontamente os problemas mais graves com as viaturas, de modo a evitar que acidentes causados por problemas mecânicos venham a ceifar a vida daqueles que visam promover a segurança pública.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., & Aljaaf, A. J. (2020). A systematic review on supervised and unsupervised machine learning algorithms for data science. *Supervised and Unsupervised Learning for Data Science*, 3–21.

- Berry, M. W., Mohamed, A., & Yap, B. W. (2020). *Supervised and Unsupervised Learning for Data Science* (M. W. Berry, A. Mohamed, & B. W. Yap (eds.)). Springer International Publishing. <https://doi.org/10.1007/978-3-030-22475-2>
- Blanco-M, A., Marti-Puig, P. M., Gibert, K., Cusidó, J., & Solé-Casals, J. (2019). A text mining approach to assess the failure condition of wind turbines using maintenance service history. *Energies*, *12*(10), 1982.
- Da Silva, L. R. A. B. (2020). Inteligência artificial em processos de extração de conhecimento KDD e KDT. *Revista de Estudos Universitários - REU*, *46*(1), 161–180. <https://doi.org/10.22484/2177-5788.2020v46n1p161-180>
- Demšar, J., Curk, T., Erjavec, A., Gorup, Č., Hočevar, T., Milutinovič, M., Možina, M., Polajnar, M., Toplak, M., Starič, A., & others. (2013). Orange: data mining toolbox in Python. *The Journal of Machine Learning Research*, *14*(1), 2349–2353.
- Dos Santos, J. E. L., Neto, M. F., & Pereira, F. D. (2020). Boletim de Ocorrência Eletrônico no Estado de São Paulo: Inteligência Artificial como Proposta de Inovação. *Revista Juridica*, *3*(60), 426–446.
- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of Biomedical Informatics*, *35*(5–6), 352–359.
- Feldman, R., & Dagan, I. (1995). Knowledge Discovery in Textual Databases (KDT). *KDD*, *95*, 112–117.
- FENAPRF. (2020). Luto - PRF perde a vida em acidente de viatura no Pará. Homepage. <https://fenaprf.org.br/novo/luto-prf-perde-a-vida-em-acidente-de-viatura-no-para/>
- Feng, L., Chiam, Y. K., & Lo, S. K. (2017). Text-mining techniques and tools for systematic literature reviews: A systematic literature review. *2017 24th Asia-Pacific Software Engineering Conference (APSEC)*, 41–50.
- Ferreira, L. N. (2018). Comparing Brazilian Platforms for Monitoring Roads, Designed to Support Law Enforcement. *2018 International Carnahan Conference on Security Technology (ICCST)*, 1–5.

- Franco, C. R. (2014). *Inteligência Artificial*. Londrina: Educational Publisher and Distributor S.A.
- Fu, C., Wu, X., Hu, Y., Huang, H., & He, R. (2021). Dvg-face: Dual variational generation for heterogeneous face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Gupta, V., Lehal, G. S., & others. (2009). A survey of text mining techniques and applications. *Journal of Emerging Technologies in Web Intelligence*, 1(1), 60–76.
- Kodratoff, Y. (1999). Comparing machine learning and knowledge discovery in databases: An application to knowledge discovery in texts. *Advanced Course on Artificial Intelligence*, 1–21.
- Li, X. Q., Shi, T. Y., Li, P., Gao, F., & Xiang, W. G. (2018). Application of text mining techniques in railway safety supervision system. *IOP Conference Series: Earth and Environmental Science*, 189(6), 62009.
- Luger, G. F. (2013). *Artificial intelligence* (6 ed.). Pearson education of Brazil.
- Machiraju, G. S. R., Kumari, K. A., & Sharif, S. K. (2021). Object Detection and Tracking for Community Surveillance using Transfer Learning. *2021 6th International Conference on Inventive Computation Technologies (ICICT)*, 1035–1042.
- Medeiros, L. F. de. (2018). Inteligência artificial aplicada: uma abordagem introdutória. *Curitiba: Intersaberes*, 158.
- Piatetsky-Shapiro, G., Frawley, W. J., & Matheus, C. J. (1992). Knowledge discovery in databases: An overview. *AI Magazine*, 13(3), 57.
- PRF. (2021). *Institucional*. <https://www.gov.br/prf/pt-br/aceso-a-informacao/institucional/institucional-2>
- Russell, S., & Norvig, P. (2013). *Artificial Intelligence* (R. C. Simille (ed.)). Elsevier.
- Tecuci, G. (2012). Artificial intelligence. *WIREs Computational Statistics*, 4(2), 168–180. <https://doi.org/10.1002/wics.200>
- Ying, S. (2020). Research on the application of artificial intelligence technology in the field of urban security. *IOP Conference Series: Earth and Environmental Science*, 608(1), 12027.



MONTERREY, MEXICO
7 Y 8 DE NOVIEMBRE 2022

INNOVACIÓN E INCLUSIÓN: GENERANDO
VALOR PARA EL DESARROLLO SOCIAL

XII Congreso Internacional
de Conocimiento e Innovación

ciki@oui-iohe.org

www.congresociki.org