

Uso de PLN e Aprendizado de Máquina na Identificação de Incidentes para Otimizar o Atendimento Médico de Emergência

Marcelo Chamy Machado
*Instituto Federal de Educação, Ciência
e Tecnologia do Amazonas - IFAM*
Manaus, Amazonas, Brasil
marcelo.chamy@ifam.edu.br

Ismael Ferreira da Silva
*Secretaria Municipal de Saúde de
Manaus - SEMSA*
Manaus, Amazonas, Brasil
ismael.dev@gmail.com

Saymon Erickson da Silva Souza
*Secretaria Municipal de Saúde de
Manaus - SEMSA*
Manaus, Amazonas, Brasil
saymon.dm@gmail.com

Marcio Aurélio dos Santos Alencar
*Instituto Federal de Educação, Ciência
e Tecnologia do Amazonas - IFAM*
Manaus, Amazonas, Brasil
marcio.alencar@ifam.edu.br

Eulanda Miranda dos Santos
*Universidade Federal do Amazonas -
UFAM*
Manaus, Amazonas, Brasil
emsantos@icomp.ufam.edu.br

Resumo—O atendimento pré-hospitalar é crucial para garantir a eficácia no socorro a emergências médicas. A escolha adequada do tipo de ambulância impacta diretamente na qualidade do atendimento e na otimização dos recursos disponíveis. Este estudo propõe a utilização de modelos de Inteligência Artificial para auxiliar na decisão sobre o envio de ambulâncias, com base nos registros do Sistema de Atendimento Móvel de Urgência (SAMU). No experimento foram aplicadas técnicas de Processamento de Linguagem Natural (PLN) e aprendizado de máquina para analisar os dados coletados, visando melhorar a precisão na recomendação do tipo de ambulância. Os resultados indicam que a aplicação de Inteligência Artificial pode reduzir erros na alocação de recursos e aprimorar o tempo de resposta no atendimento pré-hospitalar. Este trabalho contribui para a modernização dos serviços de emergência, promovendo uma abordagem mais eficiente e baseada em dados para a tomada de decisões críticas.

Palavras-chave— PLN, Machine Learning, SAMU

I. INTRODUÇÃO

O atendimento pré-hospitalar desempenha um papel fundamental na assistência a emergências médicas, sendo responsável por fornecer os primeiros cuidados aos pacientes antes de sua chegada ao ambiente hospitalar. A eficiência nesse atendimento está diretamente relacionada à adequada alocação de recursos, especialmente na escolha correta do tipo de ambulância a ser despachada para cada ocorrência. Decisões inadequadas nesse processo podem resultar em subutilização ou sobrecarga dos recursos disponíveis, comprometendo a qualidade e a efetividade do atendimento prestado, e principalmente, afetam diretamente no resultado do atendimento, podendo resultar em consequências fatais para o paciente [1].

No contexto do Serviço de Atendimento Móvel de Urgência SAMU, a definição do tipo de ambulância ocorre após uma triagem inicial, definida por um médico regulador. Essa decisão tem como base a análise clínica realizada a partir das informações fornecidas durante a ligação, que é feita geralmente por um familiar, testemunha ou pelo próprio paciente. O SAMU opera com dois tipos principais de ambulâncias: a Unidade de Suporte Avançado (USA),

destinada às ocorrências de maior complexidade e equipada com recursos de Unidade de Terapia Intensiva (UTI); e a Unidade de Suporte Básico (USB), com capacidade para atendimentos menos críticos. Cada unidade conta com equipamentos e equipes dimensionadas de acordo com o grau de gravidade da ocorrência, e o objetivo é que sempre esteja assegurado o direcionamento mais eficiente dos recursos disponíveis.

Considerando a necessidade da correta alocação dos recursos nos atendimentos de urgência, a aplicação de Inteligência Artificial (IA) no atendimento pré-hospitalar é uma alternativa promissora, que pode agregar muitas vantagens na forma como os serviços de emergência prestam assistência aos pacientes [2]. Por meio de algoritmos avançados e análise de dados em tempo real, a IA pode auxiliar na triagem rápida de pacientes, no diagnóstico precoce e na priorização de casos mais graves, otimizando o tempo de resposta e aumentando as chances de sobrevivência. Além disso, sistemas inteligentes podem prever a necessidade de recursos com base em padrões históricos, direcionando ambulâncias e equipes médicas de forma mais eficiente. As tecnologias relacionadas à IA também podem auxiliar na comunicação entre os socorristas e os centros médicos, garantindo que o hospital receba as informações do paciente ainda durante o deslocamento e de forma automatizada. Com essas vantagens, a IA contribui significativamente para a melhoria da qualidade do atendimento e para a redução da mortalidade em emergências [3].

Diante dessa necessidade, este estudo propõe a implementação de modelos de aprendizado de máquina para apoiar a decisão em relação aos tipos de ambulâncias a serem mobilizadas em atendimentos do SAMU. Inicialmente, a proposta considerou três classes clínicas que foram definidas em conjunto com a equipe médica: Acidente Vascular Cerebral (AVC), Parada Cardiorrespiratória (PCR) e Incidente com Múltiplas Vítimas (IMV). Caso a ocorrência em andamento seja analisada e classificada como uma das duas primeiras, é feita a indicação de envio de uma ambulância do

tipo USA, enquanto para o cenário de IMV é requerida a mobilização coordenada de múltiplas ambulâncias.

A abordagem proposta visa mitigar erros na alocação de recursos e reduzir o tempo de resposta dos atendimentos. Para isso, utilizou-se uma abordagem híbrida, a partir de uma análise em tempo real da avaliação clínica textual informada pelo médico regulador durante o atendimento, por meio de um agente que captura o texto digitado, uso de técnicas de Processamento de Linguagem Natural (PLN) integradas a modelos de aprendizado de máquina. A partir da identificação de padrões textuais associados à classe alvo, é indicado se um dos três casos iniciais é identificado, dessa forma, apoiando o profissional na tomada de decisão.

II. TRABALHOS RELACIONADOS

Os sistemas de recomendação têm desempenhado um papel fundamental na modernização da área da saúde, auxiliando na tomada de decisões clínicas e na alocação eficiente de recursos. Com o avanço das técnicas e modelos de aprendizado de máquina, diversas pesquisas têm explorado a aplicação dessas tecnologias para melhorar o atendimento médico, desde a triagem de pacientes até a otimização do envio de ambulâncias.

A pesquisa de Lamy e Malta (2024) [4] descreve uma aplicação de IA na triagem hospitalar, focando na classificação de risco de pacientes em serviços de urgência e emergência. O sistema avalia dados como sinais vitais, idade e histórico médico para determinar a gravidade das condições dos pacientes usando algoritmos de aprendizado de máquina e redes neurais para melhorar a precisão e rapidez na alocação de recursos médicos, incluindo a recomendação do tipo de ambulância necessária. O impacto do sistema é uma triagem mais eficiente e a redução de erros humanos, agilizando o atendimento de emergência e a alocação de ambulâncias especializadas.

O processo de triagem do departamento de emergência (EDs) do Hospital Yonsei Severance, em Seul, Coreia do Sul é baseado na avaliação subjetiva dos profissionais de saúde, tornando-o pouco confiável em certos aspectos. Para melhorar a precisão da triagem, o trabalho de Son et al. (2023) [5] usou algoritmos avançados de síntese de dados, aprendizado de máquina (ML) e modelos de *ensemble* para prever a mortalidade de pacientes, identificando aqueles em estado crítico que necessitam de intervenção imediata.

Os pesquisadores O'dwyer et al. (2016) [6] desenvolveram o "Smart SAMU", um sistema inteligente projetado para otimizar a alocação de ambulâncias no SAMU. O sistema analisa dados históricos de atendimentos e informações em tempo real para determinar a localização e o tipo de atendimento necessário, visando reduzir o tempo de resposta e melhorar a eficiência dos serviços de emergência, usando algoritmos de aprendizado de máquina, como redes neurais artificiais e modelos de regressão logística.

A investigação conduzida por Costa et al. (2025) [7] apresenta a aplicação de algoritmos de aprendizado de máquina para prever a demanda por serviços de emergência e otimizar a alocação de ambulâncias no SAMU. A pesquisa utiliza técnicas de IA para analisar padrões históricos de chamadas de emergência, permitindo uma distribuição mais

eficiente dos recursos disponíveis e redução do tempo de resposta.

O estudo de Smith et al. (2025) [8] explora o uso da Inteligência Artificial na medicina de emergência, abordando conceitos fundamentais de aprendizado de máquina e aprendizado profundo. A pesquisa destaca aplicações em diagnósticos, interpretação de imagens e tomada de decisões clínicas em cenários críticos. Além disso, o estudo enfatiza a necessidade de os profissionais de saúde compreenderem essas tecnologias para integrá-las de forma eficaz à prática clínica. Também são discutidos desafios e considerações éticas, incluindo a importância da validação rigorosa e da avaliação contínua dos sistemas para garantir a segurança e a eficácia no atendimento ao paciente.

O trabalho de Rautenstraß et al. (2025) [9] propõe uma política de despacho e redistribuição de ambulâncias baseada em aprendizado de máquina e otimização combinatória, visando minimizar o tempo médio de resposta em sistemas de Serviços Médicos de Emergência (EMS). Utilizando dados de chamadas de emergência de São Francisco, os autores demonstraram que as políticas aprendidas superam os benchmarks online em diversos cenários de recursos e demanda, alcançando uma redução de até 30% no tempo médio de resposta. Além disso, a abordagem proposta oferece economias substanciais de tempo de execução, com até 87,9% de redução em comparação com métodos existentes que dependem de aumento de dados durante o treinamento.

Em relação às pesquisas relacionadas encontradas na literatura, o presente trabalho tem como principais contribuições: a validação de uma combinação de modelos que já possuem resultado considerável quando utilizados de forma isolada, aprimorando ainda mais o resultado com uso de votação majoritária; comprovação de uso de um método com baixo custo computacional, sem necessidade de utilizar um *hardware* dedicado para modelos de *deep learning*; e efetividade dos resultados em tempo real e sem impacto para o usuário do sistema.

III. E-SUS SAMU

O sistema e-SUS SAMU foi criado para apoiar a regulação médica realizada pelas Centrais de Regulação do SAMU e possibilita a gestão dos solicitantes e pacientes, registrando históricos de procedimentos médicos, controle de veículos enviados com horários detalhados, além de fornecer relatórios gerenciais e estatísticos. Segundo Machado et al. (2025) [10], o sistema foi desenvolvido com o framework ASP.NET, utilizando a linguagem VB.NET e armazenando dados no gerenciador de banco SQL Server.

Ele permite a integração dos profissionais da Central em uma única plataforma, onde os dados são coletados pelos Telefonistas Auxiliares de Regulação Médica (TARM), que após uma triagem, fazem registros no sistema e os tornam disponíveis em tempo real para o Médico Coordenador, Reguladores e Operadores de Frota. Na etapa da regulação, um médico recebe os dados via sistema e conversa com o demandante após a ligação ser transferida pelo TARM, para entender maiores detalhes da ocorrência e coletar outros dados de avaliação. É nessa etapa que a ambulância é autorizada, ao detectar a necessidade e principalmente a gravidade, fundamental para definição do tipo mais adequado de veículo a ser encaminhado ao atendimento.

O e-SUS SAMU do município de Manaus do estado do Amazonas armazena os dados coletados nos atendimentos realizados pelas bases descentralizadas do SAMU (10 terrestres, 01 fluvial e 01 central de regulação regional) e conta com apoio de 34 UBS, 07 USA e 16 motolâncias, conforme detalhado em Machado et al. (2025) [10].

IV. ARQUITETURA

A arquitetura proposta para o sistema de recomendação de ambulâncias desenvolvido pela Diretoria de Tecnologia da Informação da Secretaria Municipal de Saúde de Manaus - SEMSA, baseia-se na integração de técnicas de PLN e aprendizado de máquina para analisar os registros médicos do SAMU. O fluxo de processamento inicia-se com a coleta dos dados registrados no sistema e-SUS SAMU, que são então submetidos a técnicas de pré-processamento para remoção de ruídos e padronização das informações.

Na fase atual de implantação do sistema, especialistas emergencistas identificaram três grupos prioritários para atendimento em emergências médicas: Parada Cardiorrespiratória (PCR), Acidente Vascular Cerebral (AVC) e Incidente com Múltiplas Vítimas (IMV). Para cada um desses cenários, os médicos reguladores analisaram frases comuns associadas a essas ocorrências. Expressões como "sem respiração" ou "sem pulso" podem indicar um caso de PCR, enquanto termos como "sem movimento de um lado do corpo" ou "dificuldade para falar" podem sugerir um AVC. Já frases como "choque entre ônibus e carro" podem apontar para um IMV.

Com base nessas informações, a recomendação para os dois primeiros casos é o envio de ambulâncias do tipo USA, que possuem os recursos mais adequados para esse tipo de atendimento. No caso de um IMV, é necessário mobilizar múltiplas equipes e ambulâncias para prestar o socorro de maneira eficaz, o que requer uma mobilização maior e sincronização dos diversos setores e bases descentralizadas do SAMU.

A integração de um agente inteligente ao sistema e-SUS-SAMU permite fornecer informações em tempo real aos profissionais de saúde, gerando recomendações com base em modelos treinados e auxiliando na tomada de decisões durante o atendimento pré-hospitalar. Essa solução oferece suporte adicional aos médicos reguladores, que são responsáveis por autorizar o envio e definir o tipo de ambulância mais adequado para cada ocorrência. Isso contribui para a redução do tempo de resposta, otimização da alocação de recursos e aprimoramento da eficiência no atendimento de emergências.

A Figura 1 apresenta a arquitetura da solução tendo como base o sistema web E-SUS SAMU, que integra o acesso ao banco de dados, o monitoramento de eventos da interface por meio de JavaScript e a comunicação com a API onde o modelo treinado foi hospedado utilizando o micro framework Flask. Essa estrutura permite a captura do texto digitado pelo médico regulador no momento da avaliação e o envio do texto capturado para execução dos procedimentos de processamento, inferência dos modelos e definição da classe correspondente, e a partir da resposta da API, é exibida a informação na própria página para auxiliar o médico na tomada de decisão sobre qual tipo de veículo escolher. Somente os casos de AVC, PCR a IMV estão habilitados no momento. Nos caso de AVC e PCR, caso o médico regulador

acate a recomendação do modelo, precisa enviar uma ambulância do tipo USA.

A arquitetura proposta é modular e escalável, permitindo a incorporação de novos dados, assim como outros grupos que já estão sendo identificados para atualização dos treinamentos dos modelos de aprendizado de máquina e serão adicionados aos 3 primeiros que estão em operação (PCR, AVC e IMV) conforme novas informações se tornam disponíveis, ou novas questões relevantes sejam identificadas para serem monitoradas. Essa flexibilidade é essencial para garantir que o sistema permaneça atualizado e capaz de fornecer recomendações precisas em um ambiente dinâmico como o atendimento de emergências.

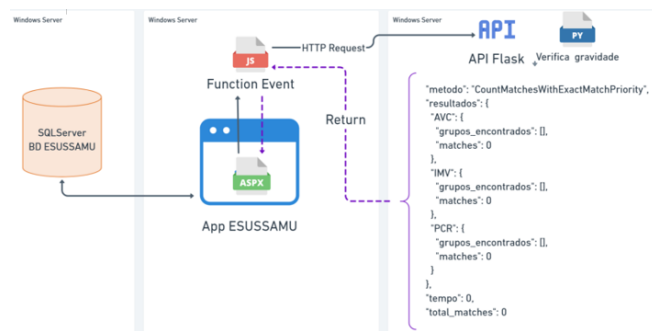


Fig. 1. Arquitetura da solução.

Inicialmente, um agente inteligente monitora em tempo real a inclusão da avaliação médica para um atendimento na tela do sistema e-SUS-SAMU. Quando o evento de inclusão é detectado, ao clicar no botão “INCLUIR AVALIAÇÕES”, conforme ilustrado na Figura 2, o texto capturado é enviado à API para processamento. Nesse estágio, ocorre a execução do processo híbrido, que combina técnicas de PLN, inferência do modelo de *ensemble*, que toma a decisão por votação majoritária. Após a identificação da classe final pelo modelo, a interface gráfica do sistema é atualizada automaticamente, e no caso da indicação seja alguma das classes a serem monitoradas, é mostrado na cor vermelha o texto “Provável AVC”, “Provável PCR” ou “Provável IMV”. A partir disso, o médico regulador avalia essa a sugestão gerada, contendo a classe identificada, e possui autonomia para realizar a tomada de decisão mais ágil e embasada.

Fig. 2. Identificação da classe “AVC” após inclusão das avaliações do médico e processamento do modelo de *ensemble* utilizado.

V. METODOLOGIA

O sistema de recomendação de ambulâncias baseado em aprendizado de máquina foi desenvolvido usando uma abordagem estruturada que envolve várias etapas essenciais. Inicialmente, realizamos a coleta de dados históricos de atendimentos do SAMU, abrangendo informações como tipo de ocorrência, avaliação feita pelo médico regulador, tempo de resposta e recursos utilizados. Esses dados foram extraídos do sistema e-SUS-SAMU, garantindo a conformidade com as normas de privacidade e ética em pesquisa.

Após a coleta, procedemos ao pré-processamento dos dados para assegurar sua qualidade e adequação aos modelos de aprendizado de máquina utilizados. Essa etapa incluiu tarefas de limpeza dos dados, tratamento de valores ausentes, padronização de termos médicos e codificação de variáveis categóricas.

Os dados anonimizados de ocorrências e suas respectivas avaliações médicas foram coletados do sistema e-SUS-SAMU do Município de Manaus, referente ao período de junho de 2022 a fevereiro de 2025, totalizando 148.351 atendimentos com avaliações registradas. Como o campo de avaliação médica é composto por texto livre e a base de dados não continha rótulos, foi necessário identificar a qual dos três grupos de interesse (PCR, AVC ou IMV) cada avaliação estava correlacionada. Para tal, foram criados 3 dicionários (*grupo_pcr*, *grupo_avc* e *grupo_imv*) contendo termos associados com o respectivo grupo e utilizada a técnica de *fuzzy matching* com similaridade de 80% para atribuir o rótulo de cada avaliação existente, a partir de uma lista simplificada de palavras correlacionadas com cada um dos 3 dicionários. Essa lista resultante foi revisada pela equipe médica a partir de várias amostragens, para validar as classes identificadas e detectar situações que continham por exemplo, a frase “histórico de AVC”, que é registrada, mas não necessariamente indica um caso de AVC a ser atendido. Ao final deste processo, para as linhas referentes às ocorrências com valor de similaridade menor que o limiar definido, ou seja, que não foram classificadas como nenhum dos 3 grupos, foi atribuído o rótulo “outros”. Essa técnica também foi utilizada na pesquisa de Denecke et al. (2024) [11].

Após a geração dos rótulos para o conjunto de dados, foi feito o seu particionamento, considerando 70% para treino e 30% para teste, resultando em 103.845 e 44.506 instâncias em cada conjunto, respectivamente. A partir disso, foram aplicadas técnicas de *stemming* para extrair e gerar somente o radical dos termos, Yang et al. (2023) [12], a partir da redução de variações morfológicas que resulta somente na forma padrão de cada palavra, descartando prefixos, sufixos e infixos, e no caso, foi considerado somente o corpus da língua portuguesa. Adicionalmente, foi realizada a remoção de *stopwords*, para evitar a geração de tokens desnecessários com termos que não possuem relevância, como artigos e preposições.

O próximo passo foi o treinamento dos modelos. Foi aplicada a técnica *Term Frequency-Inverse Document Frequency* (TF-IDF) para transformar termos textuais em vetores numéricos de características que possam ser utilizados por modelos de aprendizado de máquina. Essa técnica permite que o modelo consiga entender quais palavras ou combinação

de palavras são mais representativas. Dessa forma, o termo “sem pulso” passa a ter mais relevância do que cada palavra (*token*) analisada separadamente. A escolha de uma técnica diferente da utilizada para rotular o dataset é necessária para evitar *data leakage* [12], pois modelos de aprendizado de máquina conseguem facilmente “decorar” padrões, o que causaria um impacto negativo na generalização.

Para definir os modelos (classificadores) que seriam utilizados, foi usada a biblioteca LazyPredict [13] para treinar diversos modelos e retornar um ranking baseado na acurácia. Essa biblioteca simplifica o processo inicial de avaliação de algoritmos, permitindo que o usuário, com poucas linhas de código, treine e compare diversos modelos preditivos sem a necessidade de configurar manualmente cada um deles. LazyPredict gera automaticamente uma tabela com métricas de desempenho, como acurácia e tempo de execução, facilitando a escolha do modelo mais promissor para o problema em questão. Inicialmente escolhemos os top-3 modelos tomando como base a média ponderada de F1-Score, que foram o XGBoost [14] e [15], Support Vector Machine [16] e Gradient Boosting [17]. Os maiores valores nessa métrica garantem um bom equilíbrio entre precisão e recall, evitando excessos de falsos positivos e de falsos negativos nas classificações. Todas estas etapas estão ilustradas na Figura 3.



Fig. 3. Etapas realizadas até a geração dos classificadores de votação majoritária.

Essa estratégia definida para tomada de decisão pode ser alterada ao longo do tempo de forma simples, com a utilização de modelos com maior valor médio de *recall*. Na fase atual de avaliação da solução, foi considerado como muito mais crítico o envio de USBs, que não possuem suporte a determinadas questões mais graves, nem equipamentos de suporte vital como UTI, para uma ocorrência que seja grave, e tal decisão poderia ser fatal. Por outro lado, enviar uma ambulância com recursos avançados para um caso de menor gravidade pode comprometer o atendimento de outras ocorrências mais graves que ocorram no mesmo horário, devido à quantidade limitada de ambulâncias especializadas disponíveis.

Por fim, integramos a solução híbrida com votação majoritária a partir de um *ensemble* dos 3 modelos, técnica bastante eficiente em diversos trabalhos, como em [18] e dessa forma, o sistema de suporte à decisão, acessível aos profissionais do SAMU por meio de uma interface amigável, pode dar maior segurança nas decisões. A aplicação do agente inteligente ocorre em tempo real, com a aplicação das técnicas de PLN auxiliando durante a triagem e avaliação do médico regulador, fornecendo recomendações em tempo real sobre o tipo de ambulância mais adequado para cada situação identificada nas ocorrências. Essa ferramenta visa complementar o julgamento clínico dos profissionais, oferecendo suporte adicional baseado em dados históricos e padrões identificados pelos modelos de aprendizado de máquina.

A combinação de classificadores por meio de técnicas de ensemble contribuiu para a redução da variância e do viés, fatores que ocorrem comumente em modelos utilizados de forma individualizada. Mesmo quando um dos modelos gerava uma predição incorreta para determinada entrada, os demais frequentemente compensavam o erro e produziam a classificação correta. Como os erros dos modelos diferentes apresentaram baixa correlação, a performance geral do classificador foi substancialmente aprimorada.

VI. RESULTADOS

A implementação do sistema de recomendação de ambulâncias baseado em PLN e aprendizado de m resultou em melhorias significativas na alocação de recursos no atendimento pré-hospitalar. A aplicação da votação majoritária, com a combinação dos três modelos de aprendizado de máquina resultou em maior segurança na aplicação do que quando cada modelo foi utilizado isoladamente na recomendação do tipo de ambulância adequado para cada ocorrência. Os resultados dos relatórios de classificação e matrizes de confusões para cada modelo são ilustrados na Figura 4. O resultado da acurácia média do *ensemble* dos modelos foi de 99.42%.




Fig. 4. Relatórios de classificação e matrizes de confusão dos modelos de machine learning utilizados e do *ensemble* resultante.

A partir dos resultados obtidos pelos 3 modelos utilizados, foi possível confirmar que a estratégia de votação majoritária a partir do *ensemble* dos modelos fornece uma confiança

superior às recomendações resultantes de cada modelo individualizado para os grupos prioritários classificados, e que também gera novas perspectivas para expansão da aplicação para outros grupos com outras finalidades a serem definidos futuramente.

A integração de um agente inteligente ao sistema reforça esses avanços, demonstrando benefícios concretos, como maior agilidade na tomada de decisões e aumento da sensação de segurança entre os profissionais de saúde envolvidos. Os profissionais relataram maior confiança nas recomendações fornecidas pelo sistema, especialmente em situações de alta complexidade ou ambiguidade clínica. Além disso, observou-se uma alocação mais precisa das ambulâncias disponíveis.

VII. CONCLUSÕES

Este estudo evidenciou o potencial da Inteligência Artificial na otimização da alocação de recursos no atendimento pré-hospitalar. A aplicação de modelos de aprendizado de máquina para a recomendação do tipo de ambulância mostrou-se eficaz, resultando em ganhos consideráveis de eficiência, precisão e suporte à decisão clínica para envio do tipo de veículo mais adequado.

Ressalta-se que o sistema não visa substituir, e sim auxiliar o médico regulador, sob o qual permanece a responsabilidade da decisão final, mas o sistema foi configurado para priorizar a detecção de casos que façam parte de um dos 3 grupos críticos (AVC, PCR e IMV). Nesses casos, o tempo de resposta e o envio de uma unidade equipada adequadamente são fatores determinantes para a sobrevivência do paciente.

Os resultados apresentados evidenciam o potencial transformador da combinação de modelos preditivos por meio de estratégias de *ensemble*, especialmente a votação majoritária, no contexto do atendimento pré-hospitalar. A superioridade da abordagem coletiva em relação aos modelos individualizados não apenas aumenta a confiabilidade das recomendações para grupos prioritários, como também abre caminho para adaptações futuras em diferentes cenários clínicos.

A integração de um agente inteligente ao sistema reforça esses avanços, resultando em impactos práticos significativos, como a melhora na percepção de segurança por parte dos profissionais da saúde na tomada de decisão, refletindo em uma triagem mais precisa e uma gestão mais eficaz das ambulâncias. Assim, a aplicação da PLN em conjunto com *ensemble* de modelos de aprendizado de máquina se mostra uma ferramenta promissora para otimizar decisões críticas e melhorar a resposta em contextos de urgência.

A integração de ferramentas com o agente inteligente para suporte à triagem inicial complementa o trabalho dos profissionais de saúde, fornecendo recomendações baseadas em dados e auxiliando na tomada de decisões críticas. Essas inovações contribuem para a modernização dos serviços de emergência, alinhando-os às tendências tecnológicas atuais.

Para pesquisas futuras, além da identificação de novos grupos de interesse nos atendimentos emergenciais, além dos utilizados atualmente (PCR, AVC e IMV), sugere-se:

- a ampliação dos grupos clínicos atendidos além dos três em funcionamento;

- a inclusão de novas variáveis clínicas e operacionais que podem auxiliar e melhorar o processo de análise;
- a realização de estudos longitudinais para avaliar o impacto a longo prazo da implementação dessas tecnologias no atendimento pré-hospitalar.

Além disso, é fundamental explorar estratégias para garantir a aceitação e adesão dos profissionais às novas ferramentas, assegurando sua eficácia e sustentabilidade considerando os contextos reais de operação.

REFERÊNCIAS

- [1] LOPES, Sérgio Luiz Brasileiro; FERNANDES, Rosana Joaquim. Uma breve revisão do atendimento médico pré-hospitalar. *Medicina (Ribeirão Preto)*, v. 32, n. 4, p. 381-387, 1999.
- [2] KAIESKI, Naira; LORA, Priscila Schmidt; DA COSTA, Cristiano André. Predição de Sepsis a partir de Dados do Atendimento Pré-Hospitalar. In: *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*. SBC, 2021. p. 369-380.
- [3] Wang, H., Ng, Q. X., Arulanandam, S., Tan, C., Ong, M. E., & Feng, M. (2023). Building a machine learning-based ambulance dispatch triage model for emergency medical services. *Health Data Science*, 3, 0008.
- [4] LAMY, Marcelo; DE MALTA, Klauss Carvalho. Avanços e riscos da inteligência artificial na atenção à saúde. *Avances y riesgos de la inteligencia artificial en la atención sanitaria*.
- [5] SON, Byunghoon et al. Improved patient mortality predictions in emergency departments with deep learning data-synthesis and ensemble models. *Scientific reports*, v. 13, n. 1, p. 15031, 2023.
- [6] O'DWYER, Gisele et al. Atenção pré-hospitalar móvel às urgências: análise de implantação no estado do Rio de Janeiro, Brasil. *Ciência & Saúde Coletiva*, v. 21, p. 2189-2200, 2016.
- [7] COSTA, Arthur Pinheiro de Araújo et al. Aprendizado de Máquina e Simulação: caminhos para um atendimento de emergência eficiente no Brasil. *Ciência & Saúde Coletiva*, v. 30, p. e03522025, 2025.
- [8] SMITH, M. E., Zalesky, C. C., Lee, S., Gottlieb, M., Adhikari, S., Goebel, M., ... & Lam, S. H. (2025). Artificial Intelligence in Emergency Medicine: A Primer for the Nonexpert. *JACEP Open*, 6(2), 100051.
- [9] RAUTENSTRAUB, Maximiliane; SCHIFFER, Maximilian. Optimization-Augmented Machine Learning for Vehicle Operations in Emergency Medical Services. *arXiv preprint arXiv:2503.11848*, 2025.
- [10] MACHADO, M. C.; ALENCAR, M. A. S. ; DA SILVA, I. F.; SOUZA, S. E. Proposta de Agentes Inteligentes para Monitorar Ocorrências do SAMU. *XX Congresso Brasileiro de Informática em Saúde - CBIS, Belo Horizonte-MG*, v. 1, 2024
- [11] DENECKE, Kerstin; VAAHEESAN, Sayan; ARULNATHAN, Aaganya. A mental health chatbot for regulating emotions (SERMO)-concept and usability test. *IEEE Transactions on Emerging Topics in Computing*, v. 9, n. 3, p. 1170-1182, 2020.
- [12] YANG, Meiqi et al. Predicting extraction selectivity of acetic acid in pervaporation by machine learning models with data leakage management. *Environmental Science & Technology*, v. 57, n. 14, p. 5934-5946, 2023.
- [13] PANDALA, Shankar. lazypredict (versão 0.2.12). [s.l.]: [s.n.], 2020. Disponível em: <<https://github.com/shankarpandala/lazypredict>>. Acesso em 10 nov. 2024.
- [14] QI, Zhang. The text classification of theft crime based on TF-IDF and XGBoost model. In: *2020 IEEE International conference on artificial intelligence and computer applications (ICAICA)*. IEEE, 2020. p. 1241-1246.
- [15] BOHACEK, Matyas; BRAVANSKY, Michal. When XGBoost outperforms GPT-4 on text classification: A case study. In: *Proceedings of the 4th Workshop on Trustworthy Natural Language Processing (TrustNLP 2024)*. 2024. p. 51-60.
- [16] CAIYU, Su et al. A Classification Application Based on Support Vector Machine for Health IoT. In: *2022 Prognostics and Health Management Conference (PHM-2022 London)*. IEEE, 2022. p. 326-331.
- [17] KLUG, Maximiliano et al. A gradient boosting machine learning model for predicting early mortality in the emergency department triage: devising a nine-point triage score. *Journal of general internal medicine*, v. 35, p. 220-227, 2020.
- [18] NUNES, Matheus Henrique A.; ALMEIDA, João Dallyson S.; SILVA, Italo Francys S. da; BRAZ JÚNIOR, Geraldo. Detecção automática de doenças da visão em imagens de reflexo vermelho utilizando Deep Features e Ensemble. In: *SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS)*, 23. , 2023, São Paulo/SP. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2023 . p. 222-233. ISSN 2763-8952. DOI: <https://doi.org/10.5753/sbcas.2023.229638>.