

CLASSIFICAÇÃO DE RISCO DE PACIENTES EM SISTEMAS DE SAÚDE ATRAVÉS DO USO DE MODELOS DE LINGUAGEM AMPLA (LLMs)

LUIZ HENRIQUE RIGO FACCIO^{1,2*}, SAMUEL FEITOSA^{2,3}

1. INTRODUÇÃO

A recente introdução de novas tecnologias de inteligência artificial significou um enorme impacto em inúmeras áreas da sociedade. Os Modelos de Linguagem de Grande Escala, ou Large Language Models (LLM), em especial, tem adquirido uma notoriedade cada vez maior, dada sua capacidade de processar e compreender textos em linguagem natural. Um dos segmentos atemporais e que demanda evolução constante é o da saúde. Em unidades de atendimento emergencial, em que o fluxo de pacientes pode ser enorme e proporcionar um atendimento rápido e de qualidade é elemental, o processo de triagem de pacientes é uma etapa vital na manutenção de um serviço de excelência.

Sob um cenário que demanda múltiplos atendimentos de saúde, é crucial que haja uma forma de organizar as requisições, priorizando pacientes com base em critérios que otimizem o consumo de recursos, diminuam o tempo de espera e, principalmente, garantam o atendimento necessário aos pacientes [1, 2, 3]. A triagem de pacientes possui exatamente este papel e é um ponto central nas unidades de atendimento de emergência.

Neste contexto, é possível que se possa extrair grande valor das ferramentas de LLM. Por conseguirem analisar, compreender e responder através de linguagem natural, estas ferramentas podem analisar sintomas presentes, listar potenciais doenças que um paciente possa ter contraído e fazer perguntas adicionais relevantes [4]. Portanto, quando alimentados com informações suficientes e corretas, os LLMs podem agir como assistentes dos profissionais da saúde e prover uma segunda opinião ou maior materialidade para as decisões de triagem.

Desta forma, esse estudo busca mapear as maneiras que LLMs podem ser empregados no crucial e delicado processo de triagem de pacientes, observando as suas aplicações, os métodos de avaliação de seu desempenho e também elencando quais as tecnologias mais utilizadas dentro desse contexto. Além disso, a literatura relacionada ao uso das ferramentas de LLM aplicadas no processo de triagem de pacientes é bastante escassa. Apesar de existir um número crescente de estudos nesse âmbito, a maioria é internacional e podem não ser facilmente aplicáveis no Brasil e seu sistema de saúde.

2. OBJETIVOS

Partindo da questão central que questiona a viabilidade e confiabilidade de empregar ferramentas baseadas em LLMs no processo de triagem de pacientes, são definidos os objetivos que devem guiar todo o percurso do estudo. O **objetivo geral** pauta-se na materialização de um

¹ Bacharelado, instituição UFFS, *campus Chapecó*, contato: luiz.faccio@estudante.uffs.edu.br

² Grupo de Pesquisa: IDT – Inovação e Desenvolvimento Tecnológico

³ Doutor em Computação, Universidade Federal da Fronteira Sul, **Orientador**.

módulo de aplicação que, baseado em um modelo de linguagem, realize a triagem de pacientes utilizando de dados vitais do paciente e de uma breve anamnese. Além do objetivo principal, definem-se os objetivos específicos como: pesquisar abordagens existentes, investigar o uso de LLMs, investigar a engenharia de *prompts*, criar um banco de casos de teste e coletar e analisar métricas de performance.

3. FUNDAMENTAÇÃO TEÓRICA

Nos centros de atendimento de saúde de emergência, a triagem de pacientes exerce um papel central na organização do fluxo e garantia do atendimento eficaz dos pacientes através da alocação correta de recursos e priorização de serviço [5, 8]. Tipicamente, o processo de triagem consiste na análise holística de uma série de informações (principalmente os dados vitais) relacionadas ao paciente que busca o atendimento de emergência [5]. Este processo é realizado por um enfermeiro capacitado que, com base em um protocolo de triagem, atribuirá ao paciente a sua prioridade de atendimento.

Existem diversos métodos de triagem de pacientes no cenário mundial [5, 8]. Cada protocolo possui suas especificidades, mas compartilham do mesmo objetivo: prover atendimento efetivo e corretamente priorizado aos pacientes e otimizar o uso de recursos e tempo de espera. Guiado pelo protocolo em uso, o profissional considerará os sinais vitais de um paciente, como pulso cardíaco, taxa respiratória e a presença de sangramento para definir o nível de triagem adequado [6]. Notavelmente, este processo carrega enorme responsabilidade sob a saúde dos pacientes atendidos e a triagem feita de forma incorreta pode acarretar a piora do estado de saúde de quem está sendo atendido. A **subtriagem** (quando um paciente recebe um nível de prioridade menor do que o adequado) e a **supertriagem** (quando um paciente recebe um nível de prioridade maior do que o adequado) são resultados de triagens inadequadas e que devem ser evitados [5].

Os *Large Language Models*, atores centrais deste estudo, são ferramentas emergentes na atualidade, muito devido ao lançamento de grandes LLMs com interfaces de chat. Estes softwares são construídos sob redes neurais e realizam uma série de análises e cálculos estatísticos para poder prever com precisão a melhor palavra seguinte em uma frase [10], capturando padrões linguísticos. A arquitetura *Transformer* permite que estas estruturas analisem uma frase completa de forma paralela, propiciando uma compreensão semântica mais profunda de cada palavra a partir do seu contexto.

A construção dos LLMs baseia-se na exposição de redes neurais a grandes conjuntos de textos em linguagem natural, ajustando seus parâmetros para melhorar a geração e análise posterior. Apesar do potencial, surgem preocupações quanto à explicabilidade e confiabilidade, já que esses modelos podem produzir textos sintaticamente corretos, mas factualmente incorretos, gerando as chamadas “alucinações” [7]. Em situações em que a factualidade das informações é imprescindível — como em ambientes de atendimentos de saúde — as alucinações são extremamente perigosas e precisam ser tratadas com atenção. Outro aspecto fundamental relacionado ao uso de *Large Language Models* é o texto inserido como entrada, normalmente uma pergunta ou tarefa que o usuário quer atribuir ao modelo. Este material provido pelo usuário é o ponto de partida para o modelo gerar mais texto, esse texto inicial é

chamado de “prompt”. As respostas dos LLMs podem ser fortemente influenciadas pela composição do prompt utilizado [7, 9], portanto, é importante estruturá-los meticulosamente para extrair todo o potencial destas tecnologias [10]

4. METODOLOGIA

Visando contemplar os objetivos definidos no capítulo 1, ficam definidas a seguir as fases para desenvolvimento da pesquisa: **Fase 1, exploração da bibliográfica.** O objetivo central é verificar a existência de trabalhos com temas similares e analisar as abordagens já propostas e resultados já obtidos. **Fase 2, preparo do Modelo de Linguagem.** Nesta etapa serão escolhidos os modelos de linguagem que farão parte do experimento. Além disso, deve ser implementado e validado o fluxo de trabalho para que estes modelos possam realizar a triagem de pacientes. **Fase 3, criação e teste de prompts.** O objetivo principal desta fase é investigar, criar e testar diferentes engenharias de prompt para alimentar os LLMs, variando escrita, ênfase e objetivo. **Fase 4, elaboração do repositório dos casos de teste.** Esta etapa se foca na criação de um banco de casos de teste que possam ser utilizados para a avaliação dos modelos. Isto é, construir um repositório de histórias de paciente válidas. **Fase 5, execução de testes.** Nesta etapa os modelos serão expostos aos casos de testes através dos prompts definidos. Uma série de iterações com os modelos deve ser realizada, fazendo ajustes nos prompts e casos de teste se necessário, e documentando as respostas para avaliação posterior. **Fase 6, avaliação e discussão.** Fase final do projeto em que todas as repostas documentadas serão apreciadas e servirão de material para a avaliação final da eficiência dos modelos. Também devem ser feitas as análises comparativas com os estudos observados na fase de revisão bibliográfica e também com um sistema que realiza a mesma função (triagem de pacientes), mas através de um fluxo baseado em regras.

5. RESULTADOS PARCIAIS

A pesquisa se encontra na fase de criação do repositório de casos de teste. Já é possível utilizar o sistema que realiza a triagem de pacientes baseado em regras (CROSS), que é preexistente ao início do estudo. Além disso, já foi implementado um fluxo que executa a triagem de pacientes através de LLMs, como módulo extra da aplicação baseada em regras. Este módulo foi testado em um pequeno grupo de casos de teste fictícios e não validados.

O sistema CROSS é fruto de uma pesquisa anterior dentro da área da saúde. O objetivo principal então, era validar a usabilidade da aplicação diante da criação e cadastro de regras e fluxogramas para atendimentos de triagem específicos. Em especial, um fluxograma de triagem para pacientes com COVID-19.

Após a exploração bibliográfica, iniciou-se a implementação do novo módulo da aplicação CROSS, que realiza a mesma tarefa – triagem de pacientes – mas utilizando de LLMs e não de regras pré-cadastradas. Atualmente, este módulo está concluído. É possível inserir as informações de um paciente, escolher um dos LLMs disponíveis e obter um resultado de triagem (classificação e justificativa). Um aspecto em constante discussão é a coleção de ferramentas LLM disponíveis. Por ora, as únicas ferramentas que podem ser utilizadas são as com APIs (*Application Programming Interface*) gratuitas ou que possam ser executadas localmente. Esse conjunto de LLMs, portanto, não contempla algumas das ferramentas mais

notórias do campo (ChatGPT, DeepSeek, etc.) pois elas não possuem APIs de fácil acesso. Testes que utilizem estas ferramentas precisam ser realizados manualmente através das interfaces visuais disponíveis online.

O limitado conjunto de casos de teste utilizado até agora foi sinteticamente desenvolvido através do *ChatGPT*. Foi solicitado ao software que gerasse histórias de pacientes com todos os atributos utilizados em triagens e também já com uma classificação de prioridade de acordo com o *Manchester Triage System* (MTS). Assim, os casos são completos e utilizáveis mas não possuem materialidade, visto que foram produzidos por um LLM e não possuem validação profissional. Portanto, servem apenas para validar as ferramentas e fluxos implementados.

6. CONSIDERAÇÕES FINAIS

Este trabalho explora a possibilidade de aplicação de Modelos de Linguagem de Grande Escala (LLMs) no processo de triagem de pacientes, vendo nesta tecnologia um potencial aliado à prática clínica que pode aumentar a eficiência e a acurácia da triagem. Além disso, a comparação entre o modelo baseado em processamento de linguagem natural e ferramentas tradicionais baseadas em regras pode jogar luz a características específicas de cada técnica, evidenciando fragilidades e potencialidades. Por fim, este estudo reforça a importância da integração entre saúde e tecnologia, apontando para um futuro onde soluções baseadas em inteligência artificial podem complementar o trabalho humano, resultando em sistemas de saúde mais eficientes, acessíveis e centrados no paciente.

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 MASANNECK, L. et al. **Triage Performance Across Large Language Models, ChatGPT, and Untrained Doctors in Emergency Medicine: Comparative Study.** *Journal of Medical Internet Research*, v. 26, p. e53297, 2024. Publisher: JMIR Publications Toronto, Canada. Disponível em: <<https://www.jmir.org/2024/1/e53297/>>
- 2 YAZAKI, M. et al. **Emergency Patient Triage Improvement through a Retrieval Augmented Generation Enhanced Large-Scale Language Model.** *Prehospital Emergency Care*, p. 1–7, jul. 2024. ISSN 1090-3127, 1545-0066. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/10903127.2024.2374400>>.
- 3 LEE, S. et al. **Deep learning-based natural language processing for detecting medical symptoms and histories in emergency patient triage.** *The American Journal of Emergency Medicine*, v. 77, p. 29–38, 2024. Publisher: Elsevier. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0735675723006770>>
- 4 LANSIAUX, E.; BARON, M.-A.; VROMANT, A. **Navigating the landscape of medical triage: Unveiling the potential and challenges of large language models and beyond.** *The American Journal of Emergency Medicine*, v. 78, p. 224, abr. 2024. ISSN 07356757. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0735675724000718>>.
- 5 FEKONJA, Z. et al. **Factors contributing to patient safety during triage process in the emergency department: A systematic review.** *Journal of Clinical Nursing*, v. 32, n.17-18, p. 5461–5477, 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jocn.16622>>

6 SARBAY, ; BERIKOL, G. B.; ÖZTURAN, U. **Performance of emergency triage prediction of an open access natural language processing based chatbot application (ChatGPT): A preliminary, scenario-based cross-sectional study.** Turkish Journal of Emergency Medicine, v. 23, n. 3, p. 156–161, 2023. ISSN 2452-2473.

7 FRANC, J. M. et al. **Repeatability, reproducibility, and diagnostic accuracy of a commercial large language model (ChatGPT) to perform emergency department triage using the Canadian triage and acuity scale.** Canadian Journal of Emergency Medicine, v. 26, n. 1, p. 40–46, jan. 2024. ISSN 1481-8035, 1481-8043. Disponível em: <<https://link.springer.com/10.1007/s43678-023-00616-w>>.

8 WIREKLINT, S. C. et al. **A descriptive study of registered nurses' application of the triage scale retts©; a swedish reliability study.** International Emergency Nursing, v. 38, p. 21–28, 2018. ISSN 1755-599X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1755599X17301714>>.

9 FRASER, H. et al. **Comparison of Diagnostic and Triage Accuracy of Ada Health and WebMD Symptom Checkers, ChatGPT, and Physicians for Patients in an Emergency Department: Clinical Data Analysis Study.** JMIR mHealth and uHealth, v. 11, p. e49995, out. 2023. ISSN 2291-5222. Disponível em: <<https://mhealth.jmir.org/2023/1/e49995>>

10 PATEL, D. et al. **Traditional Machine Learning, Deep Learning, and BERT (Large Language Model) Approaches for Predicting Hospitalizations From Nurse Triage Notes: Comparative Evaluation of Resource Management.** JMIR AI, v. 3, n. 1, p. e52190, 2024. Publisher: JMIR Publications Inc., Toronto, Canada. Disponível em: <<https://ai.jmir.org/2024/1/e52190/>>.

Palavras-chave: Modelos de Linguagem de Grande Escala, Triagem de pacientes, Inteligência Artificial, Suporte à decisão clínica, IA na Saúde.

Nº de Registro no sistema Prisma: PES-2024-0130

Financiamento

