

INTELIGÊNCIA ARTIFICIAL PARA AUXÍLIO DE ORDENS DE MANIPULAÇÃO DE MEDICAMENTOS

João Pedro Carlos da Silva¹, Matheus Leandro Ferreira²

Resumo: A análise de ordens de manipulação farmacêutica é uma etapa fundamental para garantir a segurança, a estabilidade e a eficácia dos medicamentos manipulados, uma vez que incompatibilidades entre insumos e erros de dosagem podem comprometer o tratamento do paciente. Este trabalho teve como objetivo avaliar a utilização de um agente baseado em *Large Language Models* como ferramenta de apoio à análise de ordens de manipulação, por meio do desenvolvimento de uma aplicação web capaz de identificar possíveis incompatibilidades e inconsistências de dosagem. A pesquisa caracteriza-se como aplicada e tecnológica, contemplando o desenvolvimento de uma solução composta por interface web, *backend* em Java com Spring Boot, banco de dados PostgreSQL e integração com o modelo Gemini 2.5 Flash. Para validação da proposta, seis farmacêuticos avaliaram as recomendações geradas pelo sistema a partir de 31 ordens de manipulação. Foram produzidas 166 recomendações, das quais 147 receberam avaliação, resultando em média geral de 4,76 em uma escala de 1 a 5, com 94,6% das avaliações concentradas entre as notas 4 e 5. Os resultados indicam boa aceitação da solução e demonstram o potencial dos *Large Language Models* como ferramenta de apoio à análise farmacotécnica.

Palavras-chave: inteligência artificial; *large language models*; farmácia magistral; manipulação de medicamentos; apoio à decisão.

ABSTRACT: The analysis of pharmaceutical compounding orders is a fundamental step to ensure the safety, stability, and efficacy of compounded medicines, since incompatibilities between ingredients and dosage errors may compromise patient treatment. This study aimed to evaluate the use of an agent based on *Large Language Models* as a support tool for the analysis of compounding orders, through the development of a web application capable of identifying possible incompatibilities and dosage inconsistencies.

¹ Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. joaopcarlosdasilva@unesc.net

² Orientador, Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. mlf@unesc.net

The research is characterized as applied and technological, comprising the development of a solution composed of a web interface, a backend implemented in Java with Spring Boot, a PostgreSQL database, and integration with the Gemini 2.5 Flash model. To validate the proposal, six pharmacists evaluated the recommendations generated by the system based on 31 compounding orders. A total of 166 recommendations were produced, of which 147 were evaluated, resulting in an overall average score of 4.76 on a scale from 1 to 5, with 94.6% of the evaluations concentrated between scores 4 and 5. The results indicate good acceptance of the solution and demonstrate the potential of Large Language Models as a support tool for pharmacotechnical analysis.

Keywords: artificial intelligence; large language models; compounding pharmacy; medication compounding; decision support.

1 INTRODUÇÃO

No Brasil, as farmácias de manipulação são responsáveis por uma parcela significativa do mercado de produtos farmacêuticos, oferecendo medicamentos personalizados que atendem às necessidades específicas dos pacientes, muitas vezes com custos mais acessíveis (Petroceli; Baiense, 2023).

Segundo a Agência Nacional de Vigilância Sanitária, é responsabilidade das farmácias de manipulação garantir a qualidade de todos os produtos fornecidos, abrangendo desde a aquisição, armazenamento, controle de qualidade, dispensação e acompanhamento das preparações. Essas medidas são essenciais para garantir a segurança e a eficácia dos medicamentos, de modo que os pacientes recebam tratamentos de qualidade e em conformidade com as normas sanitárias (ANVISA, 2007).

A manipulação de medicamentos caracteriza-se pela preparação individualizada de formulações farmacêuticas a partir das necessidades específicas de cada paciente. Diferentemente dos medicamentos industrializados, as formulações manipuladas permitem ajustes personalizados de concentração, associação de princípios ativos, formas farmacêuticas e posologia, ampliando as possibilidades terapêuticas e contribuindo para maior aderência ao tratamento (Dias; Frey; Marquez, 2021).

Nesse contexto, incompatibilidades farmacotécnicas podem ocorrer quando substâncias presentes na formulação interagem entre si antes mesmo da administração ao paciente, provocando alterações físico-

químicas indesejadas capazes de comprometer a estabilidade, a eficácia e a segurança do medicamento. Essas incompatibilidades podem afetar diretamente a qualidade da formulação manipulada, tornando a análise farmacêutica uma etapa essencial para garantir a segurança das preparações e minimizar riscos ao paciente (Secretaria de Estado de Saúde do Distrito Federal, 2021).

Além das incompatibilidades entre insumos, erros relacionados à sobredosagem e subdosagem também representam riscos relevantes à saúde, podendo ocasionar desde falhas terapêuticas até reações adversas graves, intoxicações e agravamento do quadro clínico do paciente. Dessa forma, a verificação adequada das dosagens prescritas torna-se fundamental no processo de conferência das ordens de manipulação (Kommu; Carter; Whitfield, 2024).

Entretanto, uma pesquisa realizada em uma farmácia-escola no estado do Rio de Janeiro revelou que, de 400 prescrições atendidas no período de um mês, 30 continham erros relacionados diretamente à interação entre os insumos utilizados, pondo em risco o tratamento, a saúde do paciente e a estabilidade da formulação (Alves et al., 2019).

A literatura evidencia de forma consistente a presença de falhas significativas no processo de prescrição medicamentosa. Um estudo realizado em 2022, em um Hospital Universitário em Natal-RN, identificou 1.490 problemas relacionados a medicamentos, sendo aproximadamente 33% associados a dosagens inadequadas (Araujo; Anjos, 2025). Corroborando esses achados, Amorim et al. (2021) verificaram que 76,6% dos erros de medicação analisados estavam ligados a falhas na prescrição, com destaque para inconsistências de dosagem.

Esses dados evidenciam a necessidade de desenvolver soluções que auxiliem os farmacêuticos na análise das prescrições, contribuindo para a identificação de possíveis pontos de atenção, em especial aqueles relacionados a interações entre insumos e inadequações de dosagem. Nesse contexto, a aplicação de técnicas de Inteligência Artificial (IA) surge como uma alternativa promissora, capaz de analisar grandes conjuntos de dados e identificar padrões de incompatibilidade que poderiam passar despercebidos, contribuindo para a segurança e a qualidade dos medicamentos manipulados.

A inteligência artificial pode ser compreendida como o campo da ciência da computação voltado ao desenvolvimento de sistemas capazes de simular processos de raciocínio humano, como aprendizado, tomada de

decisão e reconhecimento de padrões (Russell; Norvig, 2020). Entre as tecnologias recentes de maior destaque estão os *Large Language Models* (LLMs), modelos treinados em extensas bases textuais e capazes de interpretar linguagem natural, compreender contexto e gerar respostas coerentes a partir de informações estruturadas (Radford et al., 2018). No contexto farmacêutico, essas soluções apresentam potencial para auxiliar na identificação de incompatibilidades entre insumos, inconsistências posológicas e possíveis riscos associados às formulações manipuladas.

Além disso, a utilização de sistemas baseados em IA na área da saúde vem crescendo significativamente nos últimos anos, especialmente em aplicações relacionadas ao apoio clínico, interpretação de prescrições e detecção de inconsistências em dados médicos e farmacêuticos. Para a Organização Mundial da Saúde, soluções baseadas em IA possuem potencial para transformar os serviços de saúde, auxiliando profissionais em atividades analíticas e contribuindo para enfrentar desafios relacionados à limitação de recursos e à escassez de mão de obra especializada (OMS, 2024).

Com o objetivo de compreender o estado da arte relacionado ao tema, foram analisadas pesquisas que investigam a aplicação de técnicas de Inteligência Artificial no apoio à tomada de decisão em contextos clínicos e farmacêuticos. A literatura recente evidencia avanços significativos no uso de algoritmos capazes de interpretar informações médicas, identificar inconsistências em prescrições e auxiliar profissionais da saúde em atividades analíticas que demandam elevado nível de atenção e conhecimento especializado.

Nesse contexto, Lizée et al. (2024) desenvolveram um agente conversacional baseado em LLMs para aconselhamento médico, avaliando sua utilização em ambiente real de atendimento. O estudo teve como objetivo verificar a segurança, a qualidade das respostas e a aceitação da ferramenta pelos pacientes. Metodologicamente, foram comparadas interações conduzidas pelo agente com atendimentos convencionais supervisionados por profissionais da saúde. Os resultados demonstraram elevado nível de satisfação dos usuários, com média de 4,58 em uma escala de 1 a 5, além de 95% das respostas classificadas pelos médicos supervisores como boas ou excelentes. Os autores concluíram que sistemas baseados em LLMs possuem potencial para auxiliar atividades relacionadas ao suporte clínico, desde que utilizados sob supervisão profissional adequada.

De forma complementar, Nagata et al. (2021) propuseram um

modelo de *Machine Learning* voltado à identificação automática de casos de subdosagem e sobredosagem em prescrições medicamentosas. Diferentemente de abordagens fundamentadas em regras previamente definidas, o modelo foi treinado para reconhecer padrões de inadequação diretamente nos dados analisados. Como resultado, a solução foi capaz de identificar 87,1% das prescrições inadequadas previamente detectadas por farmacêuticos, alcançando precisão superior a 98% em cenários controlados. Os achados demonstram o potencial das técnicas de Inteligência Artificial para auxiliar processos de validação farmacoterapêutica e prevenção de eventos adversos relacionados ao uso inadequado de medicamentos.

Também no contexto farmacêutico, Leitão et al. (2023) avaliaram a implantação da ferramenta NoHarm.ai em um hospital público de ensino de grande porte em Belo Horizonte/MG, com foco na análise farmacêutica de prescrições médicas e na identificação de erros relacionados a medicamentos. O estudo comparou os períodos de março a setembro de 2021, antes da utilização da ferramenta, e o mesmo intervalo de 2022, após sua implantação. Os resultados indicaram aumento da taxa de prescrições avaliadas de 0,6% para 49%, redução da taxa de erro de prescrição de 13% para 0,3% e aumento da média de intervenções farmacêuticas mensais de 85 para 239, evidenciando o potencial de ferramentas baseadas em Inteligência Artificial como apoio à análise farmacêutica em ambiente hospitalar.

Embora os resultados apresentados pela literatura sejam promissores, observa-se que a maior parte das pesquisas concentra-se em ambientes hospitalares, sistemas de apoio clínico e análises de prescrições médicas convencionais. Ainda são escassos os estudos voltados especificamente ao contexto da farmácia magistral, sobretudo aqueles que utilizam *Large Language Models* para analisar ordens de manipulação farmacêutica, identificar incompatibilidades entre insumos, avaliar aspectos farmacotécnicos e auxiliar na conferência de dosagens. Essa lacuna evidencia a necessidade de investigações que explorem o potencial dessas tecnologias em cenários diretamente relacionados à manipulação personalizada de medicamentos.

Diante desse contexto, este trabalho tem como objetivo avaliar a utilização de um agente baseado em LLMs como ferramenta de apoio à análise de ordens de manipulação farmacêutica, por meio do desenvolvimento de uma aplicação web capaz de identificar possíveis incompatibilidades entre insumos e inconsistências relacionadas às dosagens prescritas. Busca-se, dessa forma, contribuir para o fortalecimento da segurança far-

macotécnica, oferecendo aos profissionais um mecanismo complementar de apoio à conferência das formulações manipuladas.

Além desta introdução, o artigo está organizado em três seções principais. A Seção 2 apresenta os materiais e métodos adotados na pesquisa, descrevendo a arquitetura da solução desenvolvida, as tecnologias empregadas e os procedimentos utilizados para coleta e avaliação dos dados. A Seção 3 apresenta os resultados obtidos e sua discussão à luz da literatura científica. Por fim, a Seção 4 apresenta as conclusões do estudo, suas limitações e perspectivas para trabalhos futuros.

2 MATERIAIS E MÉTODOS


A presente pesquisa caracteriza-se como aplicada e de base tecnológica, com foco no desenvolvimento e avaliação de uma aplicação web destinada a apoiar a análise e a conferência de ordens de manipulação de medicamentos. A solução proposta foi concebida para investigar o uso de um agente baseado em LLMs como mecanismo de apoio à identificação de alertas técnicos relacionados à formulação manipulada.

O sistema desenvolvido é composto por três camadas principais: a interface gráfica de interação com o usuário, o *backend* responsável pela persistência e pelo processamento dos dados, e o agente baseado em LLM, acionado para gerar recomendações técnicas a partir das informações registradas no cadastro da ordem. De forma complementar, a aplicação também incorpora um mecanismo de coleta de avaliações, utilizado para registrar a percepção do usuário sobre os resultados apresentados.

Em termos operacionais, o fluxo da aplicação inicia-se com o preenchimento dos dados de uma ordem de manipulação em uma interface semelhante a um formulário de cadastro. Após o envio dessas informações, o *backend* realiza a persistência dos dados recebidos, encaminha a ordem ao agente de análise e, em seguida, devolve ao usuário as recomendações produzidas. Após a visualização dos resultados, a interface disponibiliza recursos para que o usuário avalie cada recomendação gerada, permitindo a formação de uma base de avaliações para análises posteriores.

O fluxo da informação, desde o preenchimento da ordem até o registro da avaliação final, pode ser visualizado na Figura 1.

Figura 1 - Fluxo da informação



Fonte: Elaborado pelo autor.

Esse fluxo sintetiza a lógica geral da aplicação e serve como base para a descrição das decisões metodológicas e técnicas apresentadas nas subseções seguintes.

2.1 ADEQUAÇÃO DA ESTRATÉGIA DE APLICAÇÃO

Na concepção inicial deste trabalho, previa-se o desenvolvimento de uma aplicação local, executada diretamente em um *notebook*, para que o processo de cadastro das ordens de manipulação e o registro das avaliações fossem realizados presencialmente, em interação direta com profissionais farmacêuticos. Essa abordagem buscava favorecer a observação imediata do uso do sistema, bem como permitir o acompanhamento do preenchimento das informações e da interpretação das recomendações geradas.

Entretanto, ao longo do desenvolvimento, essa estratégia mostrou-se inviável, principalmente em razão da dificuldade de conciliar horários para encontros presenciais com os profissionais envolvidos. Diante desse cenário, tornou-se necessário adaptar a proposta metodológica para um formato que possibilitasse acesso remoto, maior flexibilidade de uso e melhor continuidade na coleta das interações.

Como consequência, optou-se pela construção de uma aplicação web hospedada em infraestrutura gratuita. No projeto implementado, a interface cliente, o *backend* e o banco de dados foram disponibilizados no serviço Render. Essa mudança ampliou a viabilidade prática do estudo, uma vez que os participantes puderam utilizar o sistema sem depender de

encontros presenciais previamente agendados.

Essa transição também exigiu ajustes na arquitetura da solução. Tornou-se necessária a criação de uma estrutura de usuários e de um mecanismo de autenticação, permitindo identificar quem realizou cada acesso, vincular ordens e avaliações a um usuário específico e restringir o uso das funcionalidades a perfis autenticados. Desse modo, a adaptação para uma aplicação web não representou apenas uma mudança de implantação, mas também uma evolução metodológica e técnica necessária para viabilizar a execução do estudo.

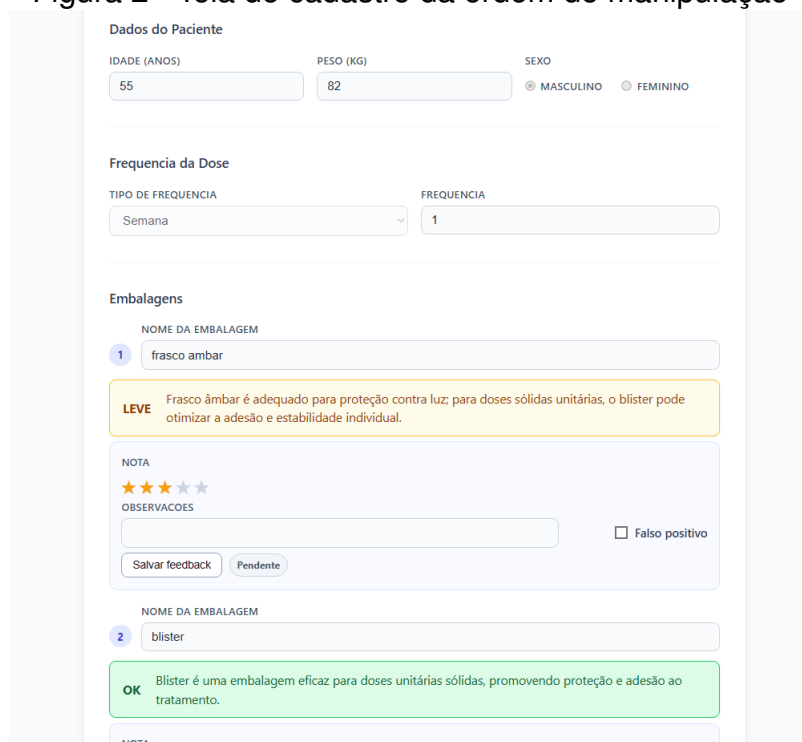
2.2 INTERFACE GRÁFICA

A interface gráfica foi desenvolvida utilizando Angular 20, *framework* adotado para a construção da aplicação cliente em arquitetura de página única. Essa camada é responsável pela autenticação do usuário, pela coleta dos dados necessários à análise, pela exibição das recomendações retornadas pela API e pelo envio das avaliações associadas aos resultados apresentados. Além disso, a aplicação disponibiliza uma tela de relatório, com acesso restrito a um usuário administrador, utilizada para consolidar as avaliações recebidas durante a coleta. Essa tela permite visualizar os resultados gerais e por categoria, servindo como apoio à análise final dos dados coletados, conforme apresentado no Apêndice A.

O formulário principal foi estruturado para receber informações demográficas e farmacotécnicas relevantes à análise, incluindo idade, sexo, peso, frequência de uso, princípios ativos, excipientes e embalagens. A modelagem da entrada foi organizada de forma padronizada para permitir o envio dessas informações ao *backend* por meio de requisições HTTP em formato JSON.

A Figura 2 apresenta a tela de cadastro de ordens de manipulação, elaborada para simular o funcionamento de um sistema de gerenciamento de formulações magistrais. Nessa interface, o usuário informa os dados do paciente, a frequência de uso e os insumos da formulação. Essa etapa representa o ponto inicial do processo de apoio à decisão, pois as informações preenchidas servem como base para a geração das recomendações técnicas apresentadas posteriormente pelo sistema.

Figura 2 - Tela de cadastro da ordem de manipulação



O formulário é dividido em seções para coleta de dados do paciente, frequência da dose e avaliação de embalagens. A seção 'Dados do Paciente' contém campos para idade (55 anos) e peso (82 kg), além de botões para selecionar o sexo (MASCULINO ou FEMININO). A seção 'Frequencia da Dose' possui um menu suspenso para o tipo de frequência (definido como 'Semana') e um campo numérico para a frequência (definido como '1'). A seção 'Embalagens' permite adicionar múltiplas opções. A primeira opção, 'frasco ambar', é marcada com um ícone '1' e recebe uma avaliação 'LEVE' (3 estrelas) com uma observação explicando sua adequação para proteção contra luz. A segunda opção, 'blister', é marcada com um ícone '2' e recebe uma avaliação 'OK' (5 estrelas) com uma observação destacando sua eficácia. Ambas as opções incluem campos para notas, observações e uma caixa de seleção para 'Falso positivo'. Botões de 'Salvar feedback' e 'Pendente' estão disponíveis para cada avaliação.

Fonte: Elaborado pelo autor.

Além da submissão da ordem, a interface também implementa a apresentação individualizada das recomendações por categoria, contemplando recomendações gerais, relacionadas a princípios ativos, excipientes e embalagens. Essa organização busca apoiar a tomada de decisão do farmacêutico ao destacar possíveis pontos de atenção da formulação, sem substituir sua análise técnica. Para cada item retornado, o usuário pode atribuir uma nota, registrar observações textuais e indicar a ocorrência de falso positivo, permitindo que a interação não se limite apenas à visualização dos resultados.

2.3 BACKEND

O *backend* foi desenvolvido em Java 17, com o uso do *framework* Spring Boot 3.5, adotando arquitetura baseada em serviços, controladores REST e persistência relacional via Spring Data JPA. Essa camada centraliza a recepção das requisições enviadas pela interface, o armazenamento das ordens de manipulação e o orquestramento da comunicação com o agente baseado em LLM.

O fluxo principal de processamento ocorre a partir do recebimento de uma requisição no *endpoint* responsável pelo cadastro da ordem de manipulação. Uma vez recebidos, os dados são convertidos em enti-

dades persistentes, associadas ao usuário autenticado e armazenadas em banco de dados relacional. Em seguida, a mesma estrutura de entrada é encaminhada ao componente responsável pela geração de recomendações. Após o retorno da análise, o sistema transforma a resposta em entidades de recomendação, as persiste e devolve ao cliente uma estrutura já enriquecida com os identificadores necessários para a etapa posterior de avaliação.

Do ponto de vista de segurança, a aplicação utiliza autenticação baseada em *JSON Web Token* (JWT), com controle de sessão do tipo *stateless*. As rotas de autenticação e verificação de disponibilidade permanecem públicas, enquanto os demais recursos exigem usuário autenticado. As senhas são tratadas com codificação segura e as chamadas entre a interface cliente e o *backend* são controladas por configuração de *Cross-Origin Resource Sharing* (CORS).

Na camada de persistência, a aplicação mantém estruturas específicas para ordens de manipulação, recomendações e avaliações, preservando o relacionamento entre os dados cadastrados pelo usuário e as respostas produzidas pelo agente. Essa organização permite rastrear tanto a entrada submetida quanto a saída gerada, favorecendo análises posteriores sobre a utilidade das recomendações emitidas.

2.4 AGENTE LLM

O agente de análise foi implementado no *backend* por meio da biblioteca LangChain4j, integrada ao modelo Gemini 2.5 Flash, da Google. Esse modelo foi utilizado em todas as chamadas responsáveis pela geração das recomendações avaliadas neste trabalho. Sua função consiste em receber os dados estruturados da ordem de manipulação e produzir recomendações técnicas em formato JSON, contemplando uma recomendação geral e recomendações específicas para princípios ativos, excipientes e embalagens.

Para isso, o sistema constrói dinamicamente um *prompt* com base nas informações fornecidas pelo usuário, incluindo dados demográficos, frequência de uso e composição da formulação. Esse *prompt* estabelece regras explícitas de resposta, como a exigência de saída exclusivamente em JSON válido, a manutenção da mesma ordem entre itens de entrada e itens de recomendação, e a limitação do texto ao escopo técnico da formulação analisada. Após a chamada ao modelo, a resposta é saneada e desserializada para uma estrutura tipada utilizada internamente pela

aplicação.

2.5 COLETA DE AVALIAÇÕES

A coleta das avaliações foi concebida como etapa complementar ao processo de análise, com o objetivo de registrar a percepção do usuário sobre a adequação das recomendações emitidas. Após a apresentação dos resultados, a interface permite o envio de avaliações individuais para cada recomendação apresentada, abrangendo a recomendação geral e aquelas associadas a princípios ativos, excipientes e embalagens.

Cada avaliação é composta por três elementos principais: uma nota atribuída pelo usuário, um campo de observações textuais e um marcador para identificação de falso positivo. Essas informações são encaminhadas ao *backend* por meio de rotas específicas para cada tipo de recomendação e, posteriormente, persistidas em estruturas próprias relacionadas ao item avaliado e ao usuário autenticado.

A separação das avaliações por categoria permite análises mais granulares sobre o comportamento do agente, possibilitando identificar, por exemplo, quais tipos de recomendação tendem a ser mais úteis, menos precisos ou mais suscetíveis a interpretações inadequadas. Dessa forma, os dados coletados podem subsidiar futuras etapas de refinamento do *prompt*, revisão das regras de análise e reavaliação do desempenho do sistema em contextos reais de uso.

2.6 MECANISMO DE PERSISTÊNCIA


O mecanismo de persistência da aplicação foi implementado com o uso do sistema gerenciador de banco de dados relacional PostgreSQL 17. A escolha dessa tecnologia ocorreu em função de sua robustez, aderência ao modelo relacional e ampla integração com o ecossistema Java. No contexto deste trabalho, o banco é responsável por armazenar de forma estruturada os dados de autenticação, as ordens de manipulação submetidas, as recomendações geradas pelo agente e as avaliações registradas pelos usuários.

O acesso aos dados é realizado no *backend* por meio do Spring Data JPA, que abstrai operações de leitura e escrita por intermédio de repositórios e entidades mapeadas. Essa abordagem favorece a organização da camada de persistência, reduz a necessidade de consultas SQL escritas manualmente e mantém o vínculo entre os objetos manipulados pela aplicação e as tabelas do banco de dados.

Sob a perspectiva da modelagem, a estrutura foi pensada de forma a preservar o relacionamento entre os diferentes elementos do fluxo de análise. Assim, cada ordem de manipulação pode ser associada ao usuário que a cadastrou, às recomendações produzidas a partir dela e, posteriormente, às respectivas avaliações.

O diagrama com o relacionamento entre as tabelas pode ser observado na Figura 3. Para facilitar a visualização, a tabela de usuários foi ocultada.

Figura 3 - Diagrama do banco de dados



Fonte: Elaborado pelo autor.

O código-fonte da aplicação desenvolvida neste trabalho encontra-se disponível publicamente em repositório no GitHub³. A disponibilização do código tem como objetivo favorecer a transparência metodológica, permitir a consulta à implementação realizada e possibilitar a reprodução ou continuidade da solução em estudos futuros.

3 RESULTADOS E DISCUSSÃO

A coleta das avaliações foi realizada com farmacêuticos atuantes na área magistral e professores do curso de Farmácia da universidade. Os participantes foram convidados por meio de contato telefônico com farmácias de manipulação da região, contato com docentes da área e indicações recebidas ao longo das conversas com os próprios profissionais. Ao todo, 6 participantes colaboraram com o estudo, preenchendo 31 ordens de mani-

³<<https://github.com/JPKyzzor/TCC-WORKSPACE-JP>>

pulação e avaliando as recomendações geradas pelo agente baseado em LLM.

As avaliações foram organizadas em quatro categorias: recomendações gerais da ordem de manipulação, princípios ativos, excipientes e embalagens. Para cada recomendação apresentada, o participante pôde atribuir uma nota de 1 a 5, sendo 1 a menor avaliação e 5 a maior avaliação. A aplicação também possuía um campo para indicação de falso positivo, entretanto, durante a coleta, observou-se que esse campo gerava ambiguidade, pois não ficava claro aos participantes em quais situações deveria ser marcado. Por esse motivo, os participantes foram orientados a não preencher obrigatoriamente esse campo e, posteriormente, decidiu-se não utilizá-lo na análise dos resultados.

Os dados foram extraídos por meio da rota de relatórios implementada no *backend* da aplicação. As médias apresentadas consideram apenas as recomendações que receberam avaliação numérica, desconsiderando os registros sem resposta.

3.1 RESULTADOS POR CATEGORIA

A análise por categoria permitiu observar o comportamento do agente em diferentes dimensões da ordem de manipulação. As recomendações gerais tiveram média de 4,67, com 27 avaliações respondidas entre 31 recomendações geradas. Embora tenha sido a menor média entre as categorias, 25 avaliações receberam nota 4 ou 5, correspondendo a 92,6% das respostas válidas. Esse resultado sugere elevada aceitação do agente pelos especialistas participantes, indicando a potencial aplicabilidade prática da solução como ferramenta de apoio à análise farmacotécnica.

As recomendações sobre princípios ativos apresentaram média de 4,77, com 52 avaliações respondidas entre 57 recomendações. Essa categoria concentrou 45 notas 5 e 5 notas 4, totalizando 96,2% de avaliações com nota 4 ou 5. O resultado é relevante para o objetivo do trabalho, pois os princípios ativos estão diretamente relacionados à eficácia terapêutica, à segurança do paciente e à análise de possíveis inadequações de dosagem ou uso.

Na categoria de excipientes, foram registradas 38 avaliações entre 44 recomendações geradas, com média de 4,76. A maior parte das respostas recebeu nota 5, mas essa categoria também apresentou algumas avaliações intermediárias e uma avaliação baixa. Isso pode indicar que a análise de excipientes depende de fatores contextuais, como forma

farmacêutica, finalidade da preparação, concentração dos componentes e experiência do profissional avaliador.

As recomendações sobre embalagens apresentaram a maior média entre as categorias, com 4,83. Foram 30 avaliações respondidas entre 34 recomendações geradas, sendo 27 notas 5 e 2 notas 4. Esse resultado pode estar relacionado ao caráter mais objetivo desse tipo de recomendação, que normalmente envolve aspectos como conservação, proteção contra luz ou umidade, compatibilidade da embalagem e adequação ao tipo de formulação.

A Tabela 1 consolida os principais indicadores obtidos por categoria.

Tabela 1 - Resumo das avaliações por categoria


Categoria	Total	Avaliadas	Sem resp.	Média	Notas 4 ou 5
Geral	31	27	4	4,67	25 (92,6%)
Princípio ativo	57	52	5	4,77	50 (96,2%)
Excipiente	44	38	6	4,76	35 (92,1%)
Embalagem	34	30	4	4,83	29 (96,7%)

Fonte: Elaborado pelo autor.

3.2 RESULTADO DAS AVALIAÇÕES

Considerando todas as categorias, foram geradas 166 recomendações, das quais 147 receberam avaliação e 19 permaneceram sem resposta. A média geral das avaliações foi de 4,76 em uma escala de 1 a 5. Entre as avaliações respondidas, 128 receberam nota 5 e 11 receberam nota 4, totalizando 139 avaliações com nota 4 ou 5, o que representa 94,6% das respostas válidas conforme apresentado na Figura 4.

Figura 4 - Resultados compilados



Fonte: Elaborado pelo autor.

A predominância de notas 5 indica que as recomendações foram bem recebidas pelos participantes na maior parte dos casos. Além disso, a proximidade entre as médias das categorias, todas acima de 4,6, sugere consistência do agente na geração de recomendações para diferentes elementos da ordem de manipulação. A melhor média foi observada em embalagens, enquanto a menor média ocorreu nas recomendações gerais, diferença que pode estar associada ao grau de objetividade de cada tipo de análise.

3.3 DISCUSSÃO DOS ACHADOS

Os resultados obtidos indicam boa aceitação inicial da aplicação pelos participantes. A elevada concentração de notas 4 e 5 sugere que, na percepção dos farmacêuticos, as recomendações geradas pelo agente foram consideradas úteis e adequadas na maioria das avaliações. Esse comportamento foi observado tanto em recomendações diretamente relacionadas aos componentes da formulação, como princípios ativos e excipientes, quanto em recomendações complementares, como as relacionadas às embalagens.

Durante o acompanhamento do uso da aplicação, também foram registradas observações qualitativas feitas pelos participantes. Um dos pontos levantados foi que o tipo de prescritor pode influenciar a avaliação de limites de dose e adequação da prescrição, por exemplo quando a prescrição é feita por médico ou nutricionista. A aplicação atual não possui campo específico para essa informação e, portanto, o agente não realiza esse tipo de julgamento.

Outra sugestão foi a inclusão de informações adicionais do paciente, como características que podem influenciar restrições ou indicações específicas de uso de determinados medicamentos. Também foi apontada a ausência de um seletor de forma farmacêutica, fazendo com que parte dessa interpretação fique dependente da embalagem ou das informações textuais fornecidas. Além disso, um participante sugeriu que a IA poderia recomendar o melhor horário de administração do medicamento, funcionalidade que não fazia parte do escopo inicial, mas que pode ampliar a utilidade da ferramenta em versões futuras.

Essas observações não foram tratadas como métricas quantitativas, pois surgiram durante o acompanhamento do uso e não por meio de um instrumento estruturado de coleta. Ainda assim, elas são relevantes por evidenciarem necessidades percebidas por profissionais da área e aponta-

rem melhorias práticas para a evolução da aplicação.

Apesar dos resultados positivos, a aplicação deve ser compreendida como ferramenta de apoio ao farmacêutico, e não como substituta da análise profissional. As recomendações geradas pelo agente podem auxiliar na identificação de pontos de atenção, mas a decisão final sobre a adequação da formulação deve permanecer sob responsabilidade de profissionais habilitados, considerando critérios técnicos, clínicos, regulatórios e o contexto específico de cada paciente.

3.4 LIMITAÇÕES

A principal limitação do estudo está relacionada ao tamanho e à composição da amostra. A coleta contou com 6 participantes, que preencheram ao todo 31 ordens de manipulação. Embora esse perfil esteja alinhado ao domínio investigado, a quantidade de participantes e de ordens avaliadas ainda é restrita, o que limita a generalização dos resultados para diferentes farmácias, regiões, perfis de pacientes e tipos de formulação.

Outra limitação refere-se à seleção dos participantes. O contato foi feito diretamente com farmácias de manipulação da região e ampliado por indicações, caracterizando uma amostragem por conveniência. Essa estratégia viabilizou a coleta com profissionais da área, mas pode concentrar participantes com maior disponibilidade, proximidade com o pesquisador ou interesse em tecnologia.

Também houve 19 recomendações sem avaliação numérica. Embora as médias tenham sido calculadas apenas com respostas válidas, a ausência de avaliação pode indicar casos em que o participante não se sentiu seguro para julgar a recomendação, não a considerou aplicável ou apenas deixou o campo sem preenchimento durante o uso da aplicação.

Além disso, as notas atribuídas representam a percepção dos participantes sobre as recomendações, e não uma validação técnica formal da precisão do agente. Para validar a correção das respostas, seriam necessários estudos adicionais com critérios objetivos, revisão por especialistas, comparação com referências farmacotécnicas estruturadas e análise individual das recomendações geradas.

A decisão de não utilizar o campo de falso positivo também representa uma limitação metodológica. Como o campo gerou ambiguidade durante os testes, não foi possível analisar quantitativamente a proporção de recomendações incorretas, excessivas ou não aplicáveis. Em trabalhos futuros, esse mecanismo pode ser reformulado com categorias mais cla-

ras, como recomendação correta, parcialmente correta, incorreta ou não aplicável.

Por utilizar um LLM, a qualidade das recomendações depende diretamente das informações fornecidas na ordem de manipulação e da capacidade do modelo de interpretar corretamente o contexto apresentado. Assim, respostas incompletas, genéricas ou inadequadas ainda podem ocorrer, reforçando a necessidade de supervisão profissional durante o uso da aplicação. Além disso, este trabalho avaliou apenas uma configuração de modelo, baseada no Gemini 2.5 Flash, de modo que estudos futuros podem comparar diferentes LLMs, parâmetros de geração e estratégias de *prompt*, a fim de verificar possíveis variações na qualidade, consistência e utilidade das recomendações produzidas.

3.5 COMPARAÇÃO COM TRABALHOS CORRELATOS

Os resultados obtidos podem ser relacionados aos estudos correlatos apresentados anteriormente, especialmente aqueles que investigam o uso de Inteligência Artificial em atividades de apoio à decisão na área da saúde. Embora os objetivos e métodos de avaliação sejam distintos, a comparação ajuda a posicionar a proposta desenvolvida em relação às abordagens existentes.

O estudo de Lizée et al. (2024) avaliou um agente conversacional baseado em LLM aplicado ao aconselhamento médico, obtendo uma média de satisfação de 4,58 em uma escala de 1 a 5. Neste trabalho, a média geral das recomendações avaliadas foi de 4,76, também em escala de 1 a 5. Apesar de não ser possível comparar diretamente os resultados devido às diferenças de contexto, público e objetivo, ambos indicam boa aceitação de soluções baseadas em LLM como ferramentas de apoio em atividades relacionadas à saúde.

De forma complementar, Nagata et al. (2021) propuseram um modelo de Inteligência Artificial baseado em *Machine Learning* para identificar casos de subdosagem e sobredosagem, alcançando desempenho elevado na detecção de prescrições inadequadas. Diferentemente desse estudo, que se concentrou na avaliação técnica do modelo, o presente trabalho avaliou a percepção dos usuários sobre recomendações geradas por um agente LLM em uma aplicação web voltada ao contexto da farmácia magistral.

O estudo de Leitão et al. (2023) por sua vez, aproxima-se desta pesquisa por investigar uma ferramenta de Inteligência Artificial aplicada ao

apoio da análise farmacêutica. No entanto, enquanto a NoHarm.ai foi avaliada em ambiente hospitalar, com foco na análise de prescrições médicas e priorização de prescrições com maior risco de problemas relacionados a medicamentos, o presente trabalho concentra-se no contexto da farmácia magistral, com foco em ordens de manipulação e recomendações relacionadas a princípios ativos, excipientes e embalagens. Assim, embora ambos os estudos explorem a Inteligência Artificial como apoio à decisão farmacêutica, diferem quanto ao ambiente de aplicação, ao tipo de prescrição analisada e à estratégia de avaliação utilizada.

Dessa forma, a principal contribuição deste trabalho está na aplicação de LLMs à análise de ordens de manipulação de medicamentos, organizando as recomendações em categorias como princípios ativos, excipientes e embalagens. Os resultados iniciais indicam viabilidade e boa aceitação da proposta, enquanto as limitações observadas apontam caminhos para continuidade da pesquisa, como ampliação da amostra, refinamento do formulário, melhoria dos critérios de avaliação, integração com bases farmacotécnicas e comparação com outras abordagens de Inteligência Artificial.

4 CONCLUSÃO

A manipulação de medicamentos exige processos rigorosos de análise e conferência, uma vez que incompatibilidades entre insumos, inadequações de dosagem e falhas farmacotécnicas podem comprometer a segurança do paciente e a eficácia terapêutica das formulações. Nesse contexto, este trabalho teve como objetivo avaliar a utilização de um agente baseado em *Large Language Models* como ferramenta de apoio à análise de ordens de manipulação farmacêutica, por meio do desenvolvimento de uma aplicação web capaz de identificar potenciais inconsistências em formulações manipuladas.

Para atingir esse objetivo, foi desenvolvida uma solução composta por interface web, *backend* baseado em Java e Spring Boot, banco de dados PostgreSQL e integração com o modelo Gemini 2.5 Flash. A aplicação permitiu o cadastro de ordens de manipulação, a geração automatizada de recomendações técnicas e a coleta estruturada das avaliações dos usuários, possibilitando a avaliação prática da proposta em ambiente real de utilização.

Os resultados obtidos demonstraram boa aceitação da ferramenta pelos participantes da pesquisa. Foram analisadas 31 ordens de manipu-

lação por seis participantes, entre farmacêuticos magistrais e professores do curso de farmácia, resultando na geração de 166 recomendações, das quais 147 receberam avaliação. A média geral obtida foi de 4,76 em uma escala de 1 a 5, sendo que 94,6% das avaliações válidas receberam notas 4 ou 5. Esses resultados indicam que as recomendações produzidas pelo agente foram consideradas úteis e adequadas pela maioria dos participantes, evidenciando o potencial da Inteligência Artificial como mecanismo de apoio à tomada de decisão farmacêutica.

Como principal contribuição científica, o estudo apresenta uma aplicação prática de LLMs voltada especificamente ao contexto da farmácia magistral, área ainda pouco explorada na literatura quando comparada a outras aplicações da Inteligência Artificial em saúde. Além disso, a pesquisa demonstra a viabilidade da utilização de agentes baseados em linguagem natural para auxiliar profissionais na análise de potenciais pontos de atenção relacionados a princípios ativos, excipientes e embalagens.

Apesar dos resultados promissores, algumas limitações devem ser consideradas. A amostra utilizada foi reduzida e composta por um número limitado de participantes, impossibilitando a generalização dos resultados para diferentes contextos de utilização. Além disso, a avaliação baseou-se na percepção dos usuários sobre as recomendações geradas, não contemplando uma validação farmacotécnica formal de cada resposta produzida pelo modelo.

Para trabalhos futuros, sugere-se ampliar a quantidade de participantes e ordens avaliadas, incorporar informações adicionais ao formulário de análise, integrar bases farmacotécnicas especializadas ao processo de inferência e realizar estudos comparativos entre diferentes modelos de Inteligência Artificial. Também podem ser explorados mecanismos de aprendizado a partir das avaliações coletadas, visando aprimorar continuamente a qualidade e a precisão das recomendações geradas.

Por fim, conclui-se que a solução desenvolvida apresentou resultados satisfatórios e demonstrou potencial para atuar como ferramenta de apoio ao farmacêutico na análise de ordens de manipulação, contribuindo para a identificação de possíveis inconsistências e para o fortalecimento da segurança no processo magistral.

DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Os autores declaram que ferramentas de Inteligência Artificial generativa foram utilizadas exclusivamente como apoio auxiliar à elabora-

ção deste trabalho, incluindo assistência na revisão linguística, estruturação textual e organização de ideias. Nenhuma ferramenta de IA foi utilizada para substituição da autoria intelectual, análise científica, interpretação dos resultados ou tomada de decisões acadêmicas. A responsabilidade integral pelo conteúdo, originalidade, veracidade das informações e conformidade com os princípios de integridade científica permanece integralmente atribuída aos autores.

REFERÊNCIAS

ALVES, F. C. et al. **Perfil dos erros de prescrições de medicamentos manipulados em uma farmácia-escola**. Vigilância Sanitária em Debate, v. 7, n. 1, p. 5–13. 2019, Disponível em: <<https://visaemdebate.incqs.fiocruz.br/index.php/visaemdebate/article/view/1194>>. Acesso em: 21 ago. 2025.

AMORIM, S. H. B. M. de et al. **Medication errors in compounding pharmacy**. J. Health Sci., v. 23, n. 4, p. 316–322. 2021, Disponível em: <<https://journalhealthscience.pgsscogna.com.br/JHealthSci/article/view/9237>>. Acesso em: 28 de agosto de 2025.

ANVISA. **RDC nº 67, de 8 de outubro de 2007 - Boas Práticas de Manipulação de Medicamentos**. 2007. <https://bvsms.saude.gov.br/bvs/saudelegis/anvisa/2007/rdc0067_08_10_2007.html>. Acesso em: 21 ago. 2025.

ARAUJO, S. R. Fernandes de; ANJOS, A. R. Pereira Johnson dos. **Análise crítica dos problemas relacionados a medicamentos advindos de erros de prescrição em ambiente hospitalar: Um estudo sobre a segurança do paciente**. JORNAL DE ASSISTÊNCIA FARMACÊUTICA E FARMACOECONOMIA, v. 10, n. 3. 2025, Disponível em: <<https://www.ojs.jaff.org.br/ojs/index.php/jaff/article/view/1039>>. Acesso em: 05 abr. 2026.

DIAS, K. L. F.; FREY, J. A.; MARQUEZ, C. d. O. **As vantagens dos medicamentos manipulados x medicamentos industrializados**. Revista Ibero-Americana de Humanidades, Ciências e Educação, v. 6, p. 10. 2021, Disponível em: <<https://periodicorease.pro.br/rease/article/view/333>>. Acesso em: 25 set. 2025.

KOMMU, S.; CARTER, C.; WHITFIELD, P. **Adverse Drug Reactions**. Internet. StatPearls Publishing. Disponível em: <<https://www.ncbi.nlm.nih.gov/books/NBK599521/>>. 2024. Acesso em: 20 nov. 2025.

LEITÃO, C. et al. **Inteligência artificial no serviço farmacêutico de análise de prescrições médicas em um hospital público**. Revista Brasileira de Farmácia Hospitalar e Serviços de Saúde, v. 14, p. 991. 2023. Acesso em: 21 ago. 2025.

LIZÉE, A. et al. **Conversational medical ai: Ready for practice**. arXiv preprint. 2024, Disponível em: <<https://arxiv.org/abs/2411.12808>>. Acesso em: 22 out. 2025.

NAGATA, K. et al. **Detection of extreme overdosage or underdosage prescription using one-class support vector machine**. PLOS ONE, v. 16. 2021, Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0260315>>. Acesso em: 20 nov. 2025.

OMS. **Artificial Intelligence for Health. Supporting countries to deploy responsible AI technologies to accelerate equitable health for all**. 2024. Disponível em: <<https://www.who.int/publications/m/item/artificial-intelligence-for-health>>. Acesso em: 04 set. 2025.

PETROCELI, R. N. d. S.; BAIENSE, A. S. R. **Papel do farmacêutico na garantia do controle de qualidade da farmácia magistral**. Revista Ibero-Americana de Humanidades, Ciências e Educação, v. 9, n. 4, p. 358–370. 2023, Disponível em: <<https://periodicorease.pro.br/rease/article/view/9179>>. Acesso em: 21 ago. 2025.

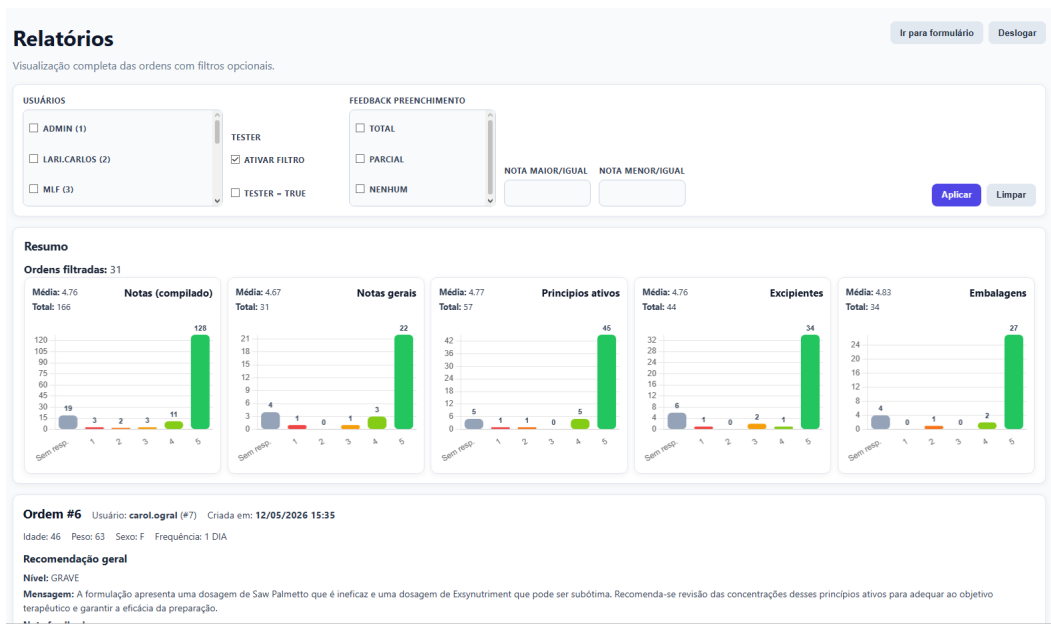
RADFORD, A. et al. **Improving Language Understanding by Generative Pre-Training**. San Francisco, CA: [s.n.], 2018. Disponível em: <https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf>. Acesso em: 30 out. 2025.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4. ed. Boston: Pearson. Disponível em: <<https://aima.cs.berkeley.edu/>>. 2020. Acesso em: 04 set. 2025.

Secretaria de Estado de Saúde do Distrito Federal. **Interações medicamentosas: classificação, interpretação e manejo clínico**. Distrito Federal, Brasil: [s.n.], 2021. Boletim da Farmácia Clínica, Ano IV, nº 09. Disponível em: <https://www.saude.df.gov.br/documents/37101/572829/Boletim-Farmacia-Clinica-SESDF-n.9-ago_2021-Interacoes-medicamentosas.pdf/3dfc3824-2246-8008-298b-c58b980cd85f?t=1649023256663>. Acesso em: 09 out. 2025.

APÊNDICE A – TELA DE RELATÓRIO DAS AVALIAÇÕES

Figura 5 - Tela de relatório das avaliações



Fonte: Elaborado pelo autor.