



AUDITORIA ASSISTIDA POR INTELIGÊNCIA ARTIFICIAL COM AJUSTES PERSONALIZADOS E PROTEÇÃO DE DADOS

AI-ASSISTED AUDITING WITH CUSTOMIZED ADJUSTMENTS AND DATA PROTECTION

 **Arthur Frederico Lerner**
Doutorando em Contabilidade

Universidade Federal de Santa Catarina – UFSC 
Florianópolis, SC – Brasil.
arthurlerner@hotmail.com

 **Leonardo Flach**

Universidade Federal de Santa Catarina – UFSC 
Florianópolis, SC – Brasil.
leonardo.flach@gmail.com

Resumo: Este projeto apresenta uma solução de auditoria assistida por Inteligência Artificial (IA), utilizando o Modelo de Linguagem Grande (LLM) LLama 3, em ambiente *offline*, visando garantir a segurança de dados sensíveis e atender às exigências da Lei Geral de Proteção de Dados (LGPD). A ferramenta desenvolvida usa *prompts* personalizados para adaptar o modelo às demandas específicas dos auditores, proporcionando maior flexibilidade no processo. As ferramentas adotadas são de código aberto, garantindo acessibilidade e personalização para diferentes cenários de auditoria. O estudo explora aplicações práticas, como análise de dados em Excel e PDF, cálculo de indicadores financeiros e identificação de anomalias contábeis, áreas em que o modelo se mostrou eficaz para melhorar a precisão e a eficiência do processo. Além disso, o uso em ambiente *offline* oferece maior segurança no tratamento de dados financeiros e contábeis, protegendo as informações contra possíveis vazamentos. A viabilidade técnica, econômica, operacional e legal foi analisada cuidadosamente. Os resultados indicam que os riscos associados à implementação são baixos, com um retorno positivo em termos de eficiência e precisão nas auditorias. A ferramenta permite a adaptação contínua do modelo por meio de ajustes feitos diretamente pelos auditores, garantindo que a solução permaneça alinhada às necessidades específicas do contexto. Este projeto representa um avanço significativo no campo da auditoria, integrando IA de forma prática e segura, com potencial para transformar a execução de auditorias em empresas de diversos portes.

Palavras-chave: Auditoria. Inteligência artificial. Modelos de linguagem grandes. Segurança de dados; Ajuste fino.

Abstract: This project presents an Artificial Intelligence (AI)-assisted auditing solution, utilizing the Large Language Model (LLM) LLama 3, in an offline environment to ensure the security of sensitive data and comply with the General Data Protection Law (LGPD). The developed tool uses personalized prompts to adapt the model to the specific needs of auditors, providing greater flexibility in the process. The tools adopted are open-source, ensuring accessibility and customization for different auditing scenarios. The study explores practical applications, such as data analysis in Excel and PDF, financial indicator calculations, and the identification of accounting anomalies, areas in which the model has proven effective in improving the accuracy and efficiency of the process. Additionally, the offline use offers greater security in handling financial and accounting data, protecting the information from potential leaks. The technical, economic, operational, and legal feasibility was carefully analyzed. The results indicate that the risks associated with implementation are low, with a positive return in terms of efficiency and accuracy in audits. The tool allows for continuous model adaptation through adjustments made directly by auditors, ensuring the solution remains aligned with the specific needs of the context. This project represents a significant advance in the field of auditing, integrating AI in a practical and secure way, with the potential to transform audit execution for companies of various sizes.

Keywords: Auditing. Artificial intelligence. Large language models. Data security. Fine-tuning.

Cite como

American Psychological Association (APA)

Lerner, A. F., & Flach, L. (2024, jul./dez.). Auditoria assistida por inteligência artificial com ajustes personalizados e proteção de dados. *Revista Inovação, Projetos e Tecnologias - IPTEC*, São Paulo, 12(2), 1-18, e27075.
<https://doi.org/10.5585/iptec.v12i2.27075>

1 Introdução

A auditoria contábil, tradicionalmente marcada por processos manuais e demorados, tem sido profundamente impactada pela adoção de tecnologias de inteligência artificial (IA). Especificamente, os Modelos de Linguagem de Grande Escala (*Large Language Models* - LLMs), como o GPT-4, o LaMDA e o LLama, emergiram como ferramentas poderosas para a otimização de tarefas auditivas. Esses modelos, treinados para compreender e gerar linguagem natural, têm o potencial de transformar os processos de auditoria, aumentando a precisão e a eficiência em tarefas como a análise de dados financeiros e a detecção de anomalias (Bommasani *et al.*, 2021). No entanto, como discutido por Mökander *et al.* (2023), apesar dos benefícios que os LLMs trazem à auditoria, a sua utilização apresenta desafios éticos e sociais significativos.

Sarker (2024) destaca que, embora os LLMs tenham grande potencial para aplicações em diversos setores, incluindo finanças e auditoria, é necessário considerar as implicações de confiança e responsabilidade ao implementar esses modelos. Além disso, a rápida evolução tecnológica dos LLMs exige uma revisão constante para garantir que a utilização dessas tecnologias se alinhe com as melhores práticas de IA responsável. Portanto, a auditoria precisa incorporar não apenas os avanços técnicos, mas também as preocupações com privacidade, transparência e mitigação de riscos.

Diante desse cenário, o presente projeto propõe o desenvolvimento de uma solução de auditoria assistida por IA, que utiliza modelos de linguagem ajustados (*fine-tuning*) para tarefas específicas da auditoria. O objetivo é oferecer uma ferramenta que, além de garantir a eficiência e precisão dos processos, assegure que os dados sensíveis permaneçam protegidos em ambientes controlados, como sistemas *offline*. A personalização dos *prompts* e o uso de técnicas de aprendizado conversacional são explorados para criar um ambiente de auditoria mais seguro e eficaz (Ouyang *et al.*, 2022; Wei *et al.*, 2022).

Este projeto busca, portanto, integrar os avanços da IA aos princípios fundamentais da auditoria, oferecendo uma solução que atenda tanto às demandas técnicas quanto aos requisitos legais e éticos.

2 Fundamentação teórica

2.1 Modelos de Linguagem de Grande Escala (LLMs) e o Impacto na auditoria

A auditoria contábil tradicionalmente se baseia em métodos manuais e revisões detalhadas de documentos, o que torna o processo demorado e suscetível a erros humanos. No entanto, a utilização de LLMs tem ganhado grande destaque, uma vez que esses modelos apresentam desempenho excepcional em diversas tarefas (Bommasani *et al.*, 2021). Eles estão revolucionando a maneira como as auditorias são conduzidas, permitindo análises mais rápidas e precisas de grandes volumes de dados.

Pesquisas recentes indicam um aumento significativo no uso de modelos de aprendizado profundo em auditoria, especialmente em demonstrações contábeis (Dong *et al.*, 2024; Freitas *et al.*, 2024; Hillebrand *et al.*, 2022a; Hillebrand *et al.*, 2022b; Schreyer *et al.*, 2020; Schultz & Tropmann-Frick, 2020; Vasarhelyi *et al.*, 2023). Esses modelos têm se mostrado eficazes em tarefas como testes de lançamento contábil, análise de notas explicativas e amostragem de auditoria. Além disso, eles despertam crescente interesse por seu desempenho excepcional em áreas como compreensão de linguagem natural, visão computacional, geração de código, resolução de equações e até mesmo a elaboração de provas matemáticas.

Os LLMs são caracterizados pela capacidade de aprendizado a partir de vastas quantidades de dados textuais, utilizando esses dados para gerar respostas e *insights* com base em padrões linguísticos (Schreyer *et al.*, 2020). Na auditoria, isso significa que os LLMs podem automatizar a análise de demonstrações financeiras, identificar anomalias e gerar relatórios de maneira eficiente. Esses modelos permitem a transformação de tarefas repetitivas e demoradas em processos automatizados e otimizados, liberando os auditores para se concentrarem em decisões mais estratégicas e complexas.

Com o uso adequado, os LLMs oferecem soluções práticas para os desafios enfrentados por auditores ao lidar com grandes volumes de dados, aumentando a precisão e reduzindo o tempo necessário para concluir auditorias (Vasarhelyi *et al.*, 2023). Além disso, sua flexibilidade para aprendizado contínuo possibilita a adaptação a diferentes contextos de auditoria, o que amplia ainda mais seu potencial de aplicação em diversos setores e regulamentações (Dong *et al.*, 2024).

2.2 Personalização de LLMs para auditoria

Uma das principais vantagens dos LLMs é sua adaptabilidade, permitindo que sejam personalizados para tarefas específicas por meio do ajuste fino (*fine-tuning*). Esse processo de

personalização possibilita que os modelos atendam a requisitos específicos de setores como a auditoria, onde a precisão e a integridade dos dados são fundamentais (Dong *et al.*, 2024). Com o ajuste fino, os auditores podem configurar os LLMs para analisar determinados tipos de dados e fornecer *insights* altamente relevantes (Chen *et al.*, 2021).

Um *prompt* é uma instrução ou pergunta fornecida ao LLM, que guia o modelo a gerar uma resposta específica ou realizar uma tarefa. No contexto de auditoria, os *prompts* podem ser elaborados para direcionar o modelo a analisar lançamentos contábeis, identificar anomalias financeiras ou verificar a conformidade com regulamentos (Vasarhelyi *et al.*, 2023). Ao adaptar os *prompts* para tarefas específicas, os auditores podem utilizar os LLMs de forma mais eficiente, maximizando a precisão e a relevância das respostas fornecidas pela IA.

Estudos sugerem que a personalização dos *prompts*, que orientam a geração de respostas pelos LLMs, aumenta significativamente a qualidade dos resultados (Longpre *et al.*, 2023). Em auditorias, isso pode incluir desde a análise de lançamentos contábeis até a detecção de fraudes, utilizando *prompts* cuidadosamente elaborados para orientar o modelo a seguir os princípios fundamentais da auditoria - como objetividade, precisão e integridade dos dados.

2.3 Proteção de dados e segurança no uso de IA em auditoria

A auditoria envolve o manuseio de dados altamente sensíveis, o que torna a segurança da informação uma prioridade. A Lei Geral de Proteção de Dados (LGPD) no Brasil estabelece diretrizes claras para o tratamento de dados pessoais, exigindo que as informações sejam processadas de maneira que garanta sua segurança e confidencialidade (Sebastian, 2023). O uso de LLMs em auditoria traz consigo o risco de exposição de dados quando esses modelos são operados em nuvens públicas ou plataformas de terceiros. Para mitigar esses riscos, propõe-se a utilização de IA localmente, em sistemas *offline*, onde os dados possam ser processados internamente, sem a necessidade de transferência para ambientes externos.

Essa abordagem não só atende às exigências da LGPD, como também permite o uso de técnicas avançadas de IA, como o aprendizado por instrução e a geração de pensamento em cadeia (*chain-of-thought* - CoT) para manter a eficiência sem comprometer a segurança dos dados (Wei *et al.*, 2022).

Wei *et al.* (2022) explicam que a geração de pensamento em cadeia (CoT) é uma técnica que permite aos LLMs seguirem uma sequência lógica de raciocínio para resolver problemas mais complexos, em vez de gerar respostas imediatas baseadas em um único passo. Na prática, o CoT simula o processo de raciocínio humano, onde o modelo desmembra uma questão em

subetapas, chegando a uma solução final de forma mais estruturada e confiável. Em auditoria, essa técnica pode ser usada para detectar fraudes e anomalias financeiras ao analisar múltiplas camadas de dados com maior profundidade e precisão (Dong *et al.*, 2024).

Com essas técnicas, as empresas podem aproveitar os benefícios da IA para otimizar seus processos de auditoria, ao mesmo tempo em que garantem que as informações confidenciais estejam devidamente protegidas.

2.4 Implicações éticas e desafios legais no uso de IA na auditoria

Embora os LLMs ofereçam uma gama de benefícios, seu uso também apresenta desafios éticos e legais que precisam ser considerados. A capacidade desses modelos de tomar decisões com base em grandes volumes de dados levanta questões sobre a transparência e a responsabilidade no processo de auditoria. Os auditores devem manter uma supervisão cuidadosa dos resultados gerados pela IA, assegurando que não haja vieses e que as decisões tomadas estejam de acordo com os padrões éticos da profissão (Kok, 2023).

Além disso, é fundamental garantir a conformidade com regulamentações como a LGPD e o GDPR (Regulamento Geral de Proteção de Dados da União Europeia), que impõem diretrizes rígidas para o manuseio de dados pessoais. As soluções de IA devem ser desenvolvidas de forma a garantir a conformidade com essas leis, além de proteger a integridade dos dados processados durante o processo de auditoria (Sebastian, 2023).

3 Metodologia

Esta pesquisa adota uma abordagem mista, combinando o desenvolvimento de uma solução tecnológica de auditoria assistida por IA com a aplicação de testes práticos em um ambiente simulado. O processo metodológico foi organizado em três fases principais: desenvolvimento da ferramenta, personalização por meio de *prompts* e ajustes finos, e testes empíricos.

3.1 desenvolvimento da ferramenta de auditoria assistida por IA

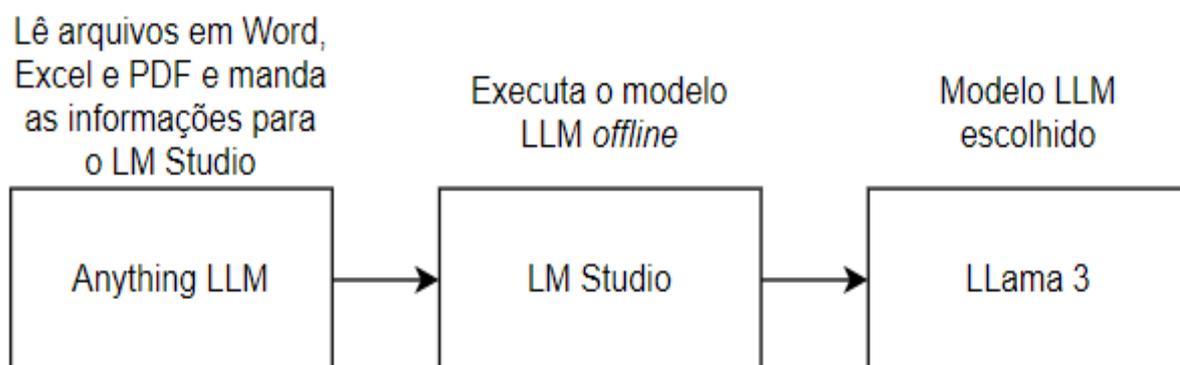
O desenvolvimento desta ferramenta de auditoria assistida por IA utilizou exclusivamente ferramentas *open source*, garantindo flexibilidade e acessibilidade ao projeto. Três principais ferramentas *open source* foram integradas para a construção desta solução: i) Llama 3: O modelo de LLM utilizado neste projeto. Ele serve como a base de processamento de linguagem natural para as tarefas de auditoria, com a possibilidade de trocar para outros

LLMs, dependendo da necessidade. ii) LM Studio: Um *software* responsável por executar o modelo LLM localmente, sem necessidade de conexão com a internet, garantindo maior segurança e conformidade com a Lei Geral de Proteção de Dados (LGPD), uma vez que os dados sensíveis não são transmitidos para servidores externos. iii) Anything LLM: *Software* usado para leitura de arquivos em formatos como Excel, Word e PDF, utilizando o modelo LLM para processar e interpretar esses documentos dentro do contexto de auditoria.

Todas essas ferramentas foram escolhidas não apenas por serem gratuitas e de código aberto, mas também por sua facilidade de uso, eliminando a necessidade de conhecimento avançado em programação para utilizá-las. Essas ferramentas *open source* permitem a flexibilidade na adaptação do modelo e nas operações realizadas, contudo, elas ficam limitadas à versão que estiver instalada no momento da implementação. Ou seja, a funcionalidade e os recursos disponíveis dependem diretamente da versão específica instalada de cada uma dessas ferramentas no sistema. A Figura 2 ilustra a estrutura de integração dessas ferramentas no desenvolvimento da solução.

Figura 1

As Ferramentas do Modelo Proposto



Fonte: Elaborado pelos autores (2024).

3.2 Personalização por meio de prompts e aplicação do ajuste fino

Os *prompts*, que são instruções textuais fornecidas ao modelo de IA, foram desenvolvidos com base nos princípios fundamentais da auditoria, como objetividade, precisão e integridade, com o objetivo de resolver problemas práticos específicos da auditoria. Esses *prompts* orientaram o sistema em tarefas como a análise de lançamentos contábeis, a identificação de anomalias financeiras e a verificação de conformidade regulatória. Durante o

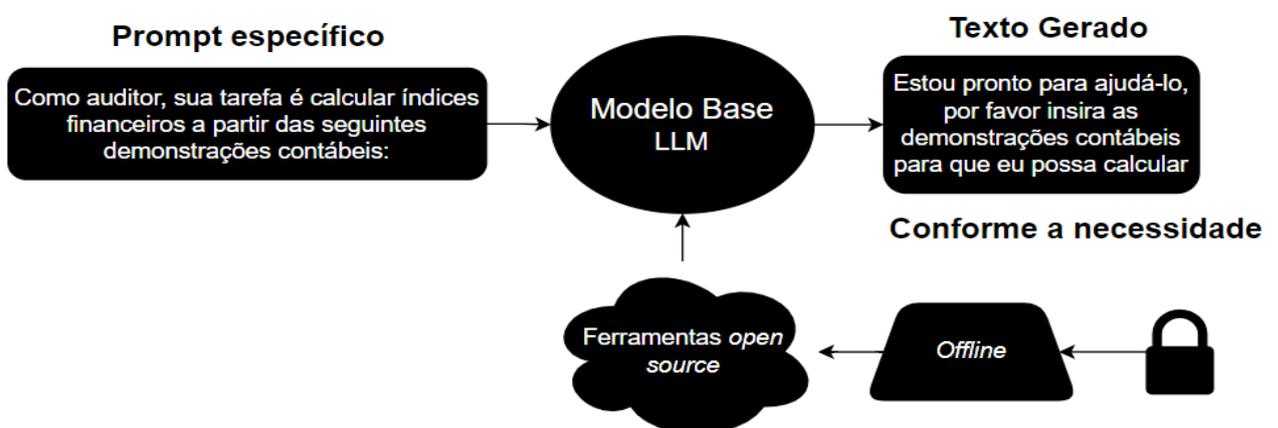
desenvolvimento, os *prompts* foram refinados iterativamente, com base no desempenho do modelo, garantindo que a ferramenta fosse adequada às necessidades práticas da auditoria.

Além da criação dos *prompts*, foi realizado o ajuste fino (*fine-tuning*) para personalizar o modelo de LLM e adaptá-lo a tarefas específicas. Esse ajuste fino foi aplicado para ensinar o modelo a realizar tarefas críticas de auditoria, como: i) Identificação de potenciais anomalias em dados contábeis específicos, ensinando ao modelo a identificar anomalias tanto locais quanto globais. ii) Cálculo de indicadores financeiros, instruindo o modelo a interpretar dados contábeis e gerar cálculos precisos para margens de lucro bruto, operacional e líquido. iii) Criação de planos de trabalho detalhados, alinhados aos objetivos de auditoria e ajustados a diferentes contextos regulatórios e empresariais.

A Figura 2 abaixo ilustra a estrutura geral do fluxo de personalização e ajuste do modelo, destacando o processo desde a criação dos *prompts* até a aplicação do ajuste fino.

Figura 2.

Fluxo de Personalização e Ajuste Fino do Modelo de LLM



Fonte: Elaborado pelos autores (2024).

O ajuste fino permitiu que o modelo fosse personalizado para lidar com bases de dados específicas no contexto de auditoria, garantindo que ele gerasse respostas mais precisas e relevantes. Ao ajustar o modelo para essas necessidades específicas, foi possível criar uma ferramenta altamente eficaz e adaptável, que aprimora a eficiência do processo de auditoria e oferece suporte estratégico aos auditores.

3.3 Testes práticos em ambiente simulado

A fase final do estudo envolveu a aplicação da ferramenta em um ambiente simulado de auditoria. Conjuntos de dados reais e fictícios foram usados para testar o desempenho do modelo em diferentes cenários, como auditorias de conformidade, análise de grandes volumes de dados e detecção de irregularidades financeiras. Os principais critérios de avaliação incluíram: i) Precisão: A capacidade do modelo de identificar corretamente anomalias contábeis e fornecer recomendações consistentes. ii) Eficiência: A comparação entre o tempo gasto pelo modelo de IA e o tempo gasto por auditores humanos para executar as mesmas tarefas. iii) Segurança dos Dados: A avaliação da eficácia do processamento *offline* no que se refere à proteção dos dados financeiros utilizados.

Os resultados dos testes compararam o desempenho do modelo com o dos auditores. O modelo demonstrou ser altamente adaptável e flexível, permitindo ajustes para atender a necessidades específicas dos auditores, seja em tarefas de auditoria contábil, detecção de fraudes ou conformidade regulatória. Essa capacidade de personalização garante que o modelo possa ser configurado para diferentes cenários e demandas, tornando-o uma ferramenta eficaz em diversas áreas da auditoria.

4 Análise e discussão dos resultados

Os resultados obtidos durante a implementação e aplicação do modelo de auditoria assistida por IA foram analisados comparando seu desempenho com o dos auditores humanos. A análise considerou a precisão das respostas geradas pelo modelo, sua eficiência em termos de tempo de execução, sua capacidade de adaptação às diferentes necessidades dos auditores e a segurança no tratamento de dados sensíveis.

Uma das principais aplicações do modelo foi a identificação de potenciais anomalias em dados contábeis específicos. Durante os testes, o modelo se mostrou eficaz ao detectar tanto anomalias locais quanto globais, aprimorando o processo de detecção de fraudes e inconsistências financeiras. Esse processo é ilustrado na Figura 3.

Figura 3.

Identificador de Potenciais Anomalias nos Dados Contábeis (Parte A)

<p>(Entrada-Auditor): Você é um excelente auditor de transações financeiras tabulares também conhecidas como "lançamentos contábeis". Dado um conjunto de dados de lançamentos contábeis tabulares e informações sobre como auditar os dados, você os divide em uma sequência de ações de auditoria. Por favor, estabeleça isso como Regra 1 e siga esta regra para todas as instruções seguintes, a menos que seja solicitado que você ignore a regra.</p> <p>Por favor, não comece a auditar até que eu diga "Auditar" e não responda mais nada. Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input".</p> <p>(Saída-LLM): Processado - Aguardando próximo input. 1</p>	<p>2. Anomalias Locais: Essas anomalias envolvem uma combinação incomum de valores para um fornecedor específico e tipo de documento quando comparados a outros lançamentos com o mesmo fornecedor e tipo de documento. Por exemplo, um título de departamento raro encontrado apenas dentro de uma combinação específica de fornecedor e tipo de documento, ou um valor de transação incomum para essa combinação, seria considerado uma anomalia local. As anomalias locais são detectadas dentro de um subconjunto do conjunto de dados, considerando o contexto de lançamentos semelhantes.</p> <p>Mantenha essas definições em mente ao analisar conjuntos de dados em busca de anomalias. Como auditor, seu objetivo é detectar ambos os tipos de anomalias de lançamentos contábeis. Por favor, estabeleça isso como Regra 2 e siga esta regra para todas as instruções seguintes, a menos que seja solicitado que você ignore a regra.</p> <p>Por favor, não comece a auditar até que eu diga "Auditar" e não responda mais nada. Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input".</p> <p>(Saída-LLM): Processado - Aguardando próximo input. 3</p>
<p>(Entrada-Auditor): Como auditor, sua tarefa é examinar dados de lançamentos contábeis registrados no sistema de Planejamento de Recursos Empresariais (ERP) de um cliente de auditoria. Especificamente, você é responsável por detectar dois tipos de lançamentos contábeis anômalos em grandes conjuntos de dados:</p> <p>Anomalias são classificadas em duas categorias:</p> <p>1. Anomalias Globais: Essas anomalias envolvem uma combinação incomum de valores para qualquer atributo único quando comparados ao conjunto de dados inteiro. Por exemplo, um valor de transação significativamente maior ou menor para um título de departamento específico ou um título de departamento raro no conjunto de dados seria considerado uma anomalia global. As anomalias globais geralmente estão relacionadas a um atributo que se destaca em todo o conjunto de dados, independentemente dos valores de outros atributos. 2</p>	

Fonte: Elaborado pelos autores (2024).

Figura 3.

Identificador de Potenciais Anomalias Nos Dados Contábeis (Parte B)



Fonte: Elaborado pelos autores (2024).

Embora não tenha sido possível mensurar o ganho de horas exato, foi constatado que o modelo completou as análises de forma significativamente mais rápida do que seria possível para um auditor humano ao lidar com grandes volumes de dados. Esse ganho de eficiência é

especialmente relevante em auditorias com grandes quantidades de dados, nas quais a velocidade de processamento é crítica para a conclusão do trabalho em tempo hábil.

Um risco importante a ser analisado é o viés algorítmico. LLMs são treinados em grandes volumes de dados, que podem conter vieses inerentes. Esses vieses podem se manifestar nos resultados da auditoria, levando a conclusões injustas ou discriminatórias. A solução para este risco envolve a curadoria cuidadosa dos dados de treinamento para remover vieses e o monitoramento contínuo do modelo em busca de saídas enviesadas. Nesse sentido, auditorias algorítmicas regulares e avaliações de equidade são essenciais para garantir que o modelo opere de forma justa e sem distorções (Metaxa *et al.*, 2021). Além disso, é fundamental assegurar a diversidade dos dados de treinamento para mitigar a amplificação de vieses preexistentes.

No mesmo contexto, é importante considerar o risco de resultados inconsistentes, já que os LLMs, apesar de eficientes, não são infalíveis e podem gerar conclusões imprecisas ou conflitantes. Para mitigar esse risco, é essencial que os auditores humanos validem os resultados gerados pelo modelo, atuando como um controle de qualidade. Testes contínuos também devem ser realizados para garantir que o modelo permaneça confiável ao longo do tempo. Além disso, protocolos claros devem ser estabelecidos para corrigir e lidar com erros, minimizando o risco de relatórios incorretos em auditorias, assegurando a precisão e integridade das conclusões finais.

Outra funcionalidade relevante foi o cálculo de indicadores financeiros, onde o modelo foi instruído a interpretar dados contábeis e gerar cálculos precisos, como margens de lucro bruto, operacional e líquido. Essa capacidade é detalhada na Figura 4.

Figura 4.

Cálculo de Indicadores

{{(Entrada-Auditor): Como auditor, sua tarefa é calcular índices financeiros a partir das demonstrações financeiras. Especificamente, seu objetivo é calcular três índices financeiros comuns da seguinte forma:

Margem de lucro bruto: Mede quanto lucro uma empresa obtém em suas vendas após contabilizar o custo das mercadorias vendidas. É calculado dividindo o lucro bruto pela receita total.

Margem de lucro bruto = Lucro bruto / Receita total

Margem de lucro operacional: Mede quanto lucro uma empresa gera de suas operações antes de contabilizar impostos e despesas de juros. É calculado dividindo o lucro operacional pela receita.

Margem de lucro operacional = Lucro operacional / Receita total

Margem de lucro líquido: Mede quanto lucro uma empresa gera após contabilizar todas as despesas, incluindo impostos e despesas de juros. É calculado dividindo o lucro líquido pela receita.

Margem de lucro líquido = Lucro líquido / Receita total

1

Por favor, mantenha essas definições em mente ao calcular os índices financeiros, estabeleça isso como Regra 2 e siga esta regra para todas as instruções seguintes, a menos que seja solicitado que você ignore a regra. Por favor, não inicie a auditoria até que eu diga "Auditar!". Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input."

(Saída-LLM): Processado - Aguardando próximo input.

(Entrada-Auditor): Os auditores geralmente recebem o demonstrativo financeiro em formato de tabela de banco de dados. Esta tabela é uma demonstração de resultados para calcular os índices financeiros. Cada coluna representa um item distinto. Como os itens podem ser diferentes nas demonstrações de resultados de diferentes empresas, não posso fornecer explicações para todos os possíveis nomes de colunas.

2

Por favor, mantenha o formato de saída em mente ao calcular os índices financeiros, estabeleça isso como Regra 4 e siga esta regra para todas as instruções seguintes, a menos que seja solicitado que você ignore a regra. Por favor, não inicie a auditoria até que eu diga "Auditar!". Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input."

(Saída-LLM): Processado - Aguardando próximo input.

(Entrada-Auditor): A seguir, estou fornecendo um exemplo de cálculo de índice.

Dados de entrada:

Data de referência, tipo de período, código de moeda, número de ações, lucro por ação, receita total, lucro bruto, lucro operacional, lucro líquido, Despesas gerais e administrativas.

31-12-2023; 12M; R\$; 566000000; 10,21; 580465000; 567600000; 101180000; 91675000; 854000.

5

Os dados de entrada não devem ser incluídos na saída. Abaixo está a saída esperada:

Cálculo concluído!

Margem de lucro bruto = Lucro bruto / Receita total

Margem de lucro bruto = 567.600.000 / 580.465.000 = 0,9786

Margem de lucro operacional = Lucro operacional / Receita total

Margem de lucro operacional = 101.180.000 / 580.465.000 = 0,1743

Margem de lucro líquido = Lucro líquido / Receita total

Margem de lucro líquido = 91.675.000 / 580.465.000 = 0,1579

Se você não conseguir calcular, por favor, imprima:

Cálculo falhou!

Não consigo encontrar o valor de [nome dos itens], que é essencial para calcular os índices.

Por favor, não inicie a auditoria até que eu diga "Auditar!". Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input."

(Saída-LLM): Processado - Aguardando próximo input.

6

Por favor, mantenha a descrição em mente ao calcular os índices financeiros, estabeleça isso como Regra 3 e siga esta regra para todas as instruções seguintes, a menos que seja solicitado que você ignore a regra. Por favor, não inicie a auditoria até que eu diga "Auditar!". Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input."

(Saída-LLM): Processado - Aguardando próximo input.

(Entrada-Auditor): Aqui estão algumas explicações para os nomes das características:

[Explicação para os nomes das características]

Por favor, não inicie a auditoria até que eu diga "Auditar!". Em vez disso, apenas retorne a mensagem de saída "Processado - Aguardando próximo input."

(Saída-LLM): Processado - Aguardando próximo input.

3

(Entrada-Auditor): Existem dois tipos de cenários de saída após o cálculo dos índices financeiros em uma tabela de banco de dados tabular.

O primeiro cenário de saída é que você é capaz de calcular com sucesso o índice. Abaixo está um exemplo do formato de mensagem que deve ser gerado quando o índice é calculado com sucesso:

Cálculo concluído!

[Substitua pelo índice calculado]

O segundo cenário de saída é que você não consegue calcular o índice com sucesso. Abaixo está um exemplo do formato de mensagem que deve ser gerado quando o índice não é calculado com sucesso:

Cálculo falhou!

[Substitua pela justificativa]

4

(Entrada-Auditor): Por favor, analise a seguinte demonstração de resultados, referida como Input1, para calcular os três índices financeiros.

Data de referência, tipo de período, código de moeda, número de ações, lucro por ação, receita total, lucro bruto, lucro operacional, lucro líquido, Despesas gerais e administrativas.

31-12-2023; 12M; R\$; 566000000; 10,21; 391565000; 350601000; 171134000; 62567000; 854000.

Auditar!

(Saída-LLM): ...

(Entrada-Auditor): Input1, Input 2 e Input3 são as demonstrações de resultados da empresa para 2023, 2022 e 2021, respectivamente. Por favor, analise os três índices calculados e forneça uma breve análise qualitativa da tendência. A saída esperada deve ser:

A seguinte tendência é observável:

[Descrições da tendência]

Explicação detalhada da tendência e insights:

[Insights da tendência]

(Saída-LLM): ...}

7

Fonte: Elaborado pelos autores (2024).

Além disso, o modelo permitiu a criação de planos de trabalho detalhados, alinhados aos objetivos da auditoria e ajustados para diferentes contextos regulatórios e empresariais. Essa etapa foi essencial para a adaptação do modelo às necessidades específicas de cada auditoria, como mostrado na Figura 5.

Figura 5.

Criação de Plano De Trabalho Detalhado

```
(Entrada-Auditor): Como especialista em planejamento e criação de programa de auditoria, especialmente para empresas que lidam com amianto em seus produtos, você é solicitado a criar um programa de auditoria para uma empresa fictícia chamada Química S.A. Esta empresa utilizou amianto em qualquer quantidade para fabricar freios de 1950 a 2000. Desde 2000, seus produtos contêm 1 por cento de amianto, que é o limite legal. Por favor, crie um programa de auditoria que se concentre especificamente nos riscos e responsabilidades relacionados ao amianto.

(Saída-LLM): ...
```

Fonte: Elaborado pelos autores (2024).

Em termos de segurança, a decisão de executar a solução em um ambiente *offline* foi estratégica para garantir que os dados confidenciais das auditorias não fossem expostos a redes públicas. Isso foi essencial para cumprir os requisitos da Lei Geral de Proteção de Dados (LGPD) no Brasil, que impõe severas restrições ao tratamento de dados pessoais e financeiros. Além disso, destacamos que, embora essa abordagem *offline* ofereça maior segurança, ela também limita o acesso a atualizações contínuas do modelo, exigindo estratégias de atualização manual para manter o modelo relevante.

Apesar dos resultados promissores, o estudo identificou algumas limitações que precisam ser abordadas em futuras implementações. Uma das principais limitações foi a dependência da versão do modelo LLM instalada no momento da implementação, o que pode influenciar a *performance* dependendo das atualizações ou melhorias disponíveis posteriormente. Esse fator ressalta a importância de manter o modelo atualizado para aproveitar os avanços mais recentes em aprendizado de máquina e processamento de linguagem natural.

A ideia central é que os auditores utilizem os *prompts* aqui apresentados como base e fonte de inspiração para aprimorar ou desenvolver seus próprios *prompts*, adaptando-os para melhor atender às suas demandas específicas e contextos individuais. Essa flexibilidade é

essencial para personalizar o modelo de acordo com as necessidades particulares de cada auditoria.

Outra limitação identificada foi a necessidade de refinar ainda mais os *prompts* em contextos muito específicos ou altamente regulados, como auditorias governamentais. Embora o modelo tenha demonstrado flexibilidade em vários cenários, tarefas que exigem um alto grau de personalização podem demandar mais iterações e ajustes para alcançar o nível de precisão necessário.

Os resultados deste estudo indicam que o uso de modelos de IA assistidos por LLMs, adaptados por meio de *prompts* personalizados e ajuste fino, pode transformar significativamente o campo da auditoria. A capacidade do modelo de automatizar tarefas críticas e se adaptar a diferentes contextos sugere um caminho promissor para a adoção de tecnologias de IA em auditorias com grandes volumes de dados. Além disso, a eficiência e a precisão que o modelo oferece podem liberar os auditores para focarem em áreas mais estratégicas e subjetivas do processo, como a interpretação de resultados e a tomada de decisões críticas.

Em última análise, a integração dessas tecnologias na auditoria representa uma evolução importante para o setor, com potencial para melhorar a eficácia, reduzir o tempo de análise e aumentar a segurança e a conformidade com as regulamentações vigentes. De acordo com Dong *et al.* (2024), a incorporação de LLMs em praticamente todos os campos de contabilidade e finanças tem o potencial de aumentar significativamente a eficiência e a eficácia, permitindo que os profissionais assistidos por LLMs trabalhem de forma mais produtiva do que aqueles que não utilizam essa assistência.

5 Conclusões

Avaliamos aspectos fundamentais para a implementação do projeto em uma empresa de auditoria, ressaltando a importância de examinar detalhadamente os pontos técnicos, operacionais e econômicos. Essa análise criteriosa é indispensável para garantir que a implantação ocorra de maneira eficiente, permitindo que a empresa não apenas alcance melhorias significativas em seus processos, mas também enfrente de forma proativa os desafios identificados, assegurando assim o sucesso do projeto em um ambiente de auditoria cada vez mais tecnológico.

A viabilidade técnica destaca a necessidade de instalação das ferramentas e do modelo LLM, além da integração e interoperabilidade das novas tecnologias. A implementação requer

a instalação de *software* especializado e a aquisição de *hardware* de alto desempenho, visto que o processamento do modelo demanda uma capacidade computacional elevada. Além disso, a interface do usuário é simples e prática, o que elimina a necessidade de um entendimento avançado de programação para operá-lo, facilitando a adesão por parte dos auditores.

A viabilidade econômica sugere que a implementação em uma empresa de auditoria independente é relativamente acessível, especialmente devido ao uso de ferramentas *open source*. Isso reduz custos relacionados a licenciamento de *software*, sendo que a maior parte do investimento está associada à aquisição de computadores de alta *performance*, capazes de suportar a execução do modelo LLM.

Na avaliação operacional, foram identificados alguns obstáculos, como a resistência à mudança por parte da equipe e deficiências em habilidades técnicas. Para enfrentar esses desafios, foram propostas estratégias de transição, incluindo treinamento especializado e capacitação da equipe, de modo a garantir uma adoção mais suave dos novos métodos de auditoria. Já a análise de viabilidade legal e regulatória assegura que todas as leis e regulamentações aplicáveis, especialmente no que tange à segurança da informação e proteção de dados, estão sendo cumpridas, em conformidade com legislações como a LGPD.

Os principais riscos do projeto são escassez de recursos financeiros, falta de *expertise* técnica da equipe e lentidão na execução do modelo LLM. Entretanto, para mitigar esses riscos, podem ser adotadas estratégias robustas, como planejamento orçamentário detalhado, contratação de especialistas qualificados e aquisição de *hardware* de alto desempenho, garantindo uma execução mais eficiente e segura.

Conclui-se, portanto, que os riscos associados ao projeto são baixos e que as estratégias de mitigação e medidas preventivas, se adequadamente planejadas e implementadas, potencializam a implantação do projeto. A viabilidade técnica, econômica, operacional e legal/regulatória é favorável, indicando que a implementação do modelo LLM na auditoria pode proporcionar melhorias significativas na eficiência e precisão dos processos, além de garantir a proteção dos dados sensíveis envolvidos. A flexibilidade dos LLMs permitirá que os auditores personalizem a aplicação desses modelos, tornando o processo de auditoria mais adaptável às necessidades organizacionais. Ademais, a execução deste projeto demonstrou que a instalação e operação dos modelos são tarefas relativamente simples, podendo ser replicadas por firmas de auditoria sem a necessidade de treinamento técnico avançado.

Referências

- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., Bernstein, M. S., Bohg, J., Bosselut, A., Brunskill, E., Brynjolfsson, E., Buch, S., Card, D., Castellon, R., Chatterji, N., Chen, A., Creel, K., Davis, J. Q., Demszky, D., Donahue, C., Doumbouya, M., Durmus, E., Ermon, S., Etchemendy, J., Ethayarajh, K., Fei-Fei, L., Finn, C., Gale, T., Gillespie, L., Goel, K., Goodman, N., Grossman, S., Guha, N., Hashimoto, T., Henderson, P., Hewitt, J., Ho, D. E., Hong, J., Hsu, K., Huang, J., Icard, T., Jain, S., Jurafsky, D., Kalluri, P., Karamcheti, S., Keeling, G., Khani, F., Khattab, O., Koh, P. W., Krass, M., Krishna, R., Kuditipudi, R., Kumar, A., Ladhak, F., Lee, M., Lee, T., Leskovec, J., Levent, I., Li, X. L., Li, X., Ma, T., Malik, A., Manning, C. D., Mirchandani, S., Mitchell, E., Munyikwa, Z., Nair, S., Narayan, A., Narayanan, D., Newman, B., Nie, A., Niebles, J. C., Nilforoshan, H., Nyarko, J., Ogut, G., Orr, L., Papadimitriou, I., Park, J. S., Piech, C., Portelance, E., Potts, C., Raghunathan, A., Reich, R., Ren, H., Rong, F., Roohani, Y., Ruiz, C., Ryan, J., Ré, C., Sadigh, D., Sagawa, S., Santhanam, K., Shih, A., Srinivasan, K., Tamkin, A., Taori, R., Thomas, A. W., Tramèr, F., Wang, R. E., Wang, W., Wu, B., Wu, J., Wu, Y., Xie, S. M., Yasunaga, M., You, J., Zaharia, M., Zhang, M., Zhang, T., Zhang, X., Zhang, Y., Zheng, L., Zhou, K., & Liang, P. (2021). On the opportunities and risks of foundation models. *arXiv preprint arXiv:2108.07258*.
<https://doi.org/10.48550/arXiv.2108.07258>.
- Chen, M., Tworek, J., Jun, H., Yuan, Q., Pinto, H. P. D. O., Kaplan, J., Edwards, H., Burda, Y., Joseph, N., Brockman, G., Ray, A., Puri, R., Krueger, G., Petrov, M., Khlaaf, H., Sastry, G., Mishkin, P., Chan, B., Gray, S., Ryder, N., Pavlov, M., Power, A., Kaiser, L., Bavarian, M., Winter, C., Tillet, P., Petroski Such, F., Cummings, D., Plappert, M., Chantzis, F., Barnes, E., Herbert-Voss, A., Hebggen Guss, W., Nichol, A., Paino, A., Tezak, N., Tang, J., Babuschkin, I., Balaji, S., Jain, S., Saunders, W., Hesse, C., Carr, A. N., Leike, J., Achiam, J., Misra, V., Morikawa, E., Radford, A., Knight, M., Brundage, M., Murati, M., Mayer, K., Welinder, P., McGrew, B., Amodei, D., McCandlish, S., Sutskever, I., & Zaremba, W. (2021). Evaluating large language models trained on code. *arXiv preprint arXiv:2107.03374*.
<https://doi.org/10.48550/arXiv.2107.03374>.
- Dong, M. M., Stratopoulos, T. C., & Wang, V. X. (2024). A scoping review of ChatGPT research in accounting and finance. *International Journal of Accounting Information Systems*, 55, 100715. <https://doi.org/10.1016/j.accinf.2024.100715>.
- Freitas, M. M., Sallaberry, J. D., Silva, T. B. J., & Rosa, F. S. (2024). Application of Chatgpt 4.0 for solving accounting problems. *GCG: revista de globalización, competitividad y gobernabilidad*, 18(2), 49-64. DOI: <https://doi.org/10.58416/GCG.2024.V18.N2.03>
- Hillebrand, L., Deußer, T., Dilmaghani, T., Kliem, B., Loitz, R., Bauckhage, C., & Sifa, R. (2022a, August). Kpi-bert: A joint named entity recognition and relation extraction model for financial reports. In *2022 26th International Conference on Pattern Recognition (ICPR)* (pp. 606-612). IEEE.
<https://doi.org/10.1109/ICPR56361.2022.9956191>.
- Hillebrand, L., Deußer, T., Dilmaghani, T., Kliem, B., Loitz, R., Bauckhage, C., & Sifa, R. (2022b, December). Towards automating numerical consistency checks in financial

- reports. *In 2022 IEEE International Conference on Big Data (Big Data)* (pp. 5915-5924). IEEE. <https://doi.org/10.1109/BigData55660.2022.10020308>.
- Kok, T. (2023). *Generative LLMs and Textual Analysis in Accounting: (Chat) GPT as Research Assistant?* Available at SSRN. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4429658.
- Longpre, S., Hou, L., Vu, T., Webson, A., Chung, H. W., Tay, Y., Zhou, D., Le, Q. V., Zoph, B., Wei, J., & Roberts, A. (2023). The flan collection: Designing data and methods for effective instruction tuning. *arXiv preprint arXiv:2301.13688*. Retrieved from <https://proceedings.mlr.press/v202/longpre23a.html>.
- Metaxa, D., Park, J. S., Robertson, R. E., Karahalios, K., Wilson, C., Hancock, J., & Sandvig, C. (2021). Auditing algorithms: Understanding algorithmic systems from the outside in. *Foundations and Trends® in Human-Computer Interaction*, 14(4), 272-344. <http://dx.doi.org/10.1561/11000000083>.
- Mökander, J., Schuett, J., Kirk, H. R., & Floridi, L. (2023). Auditing large language models: a three-layered approach. *AI and Ethics*, 1-31. <https://doi.org/10.1007/s43681-023-00289-2>.
- Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., Zhang, C., Agarwal, S., Slama, K., Ray, A., Schulman, J., Hilton, J., Kelton, F., Miller, L., Simens, M., Askell, A., Welinder, P., Christiano, P. F., Leike, J., & Lowe, R. (2022). Training language models to follow instructions with human feedback. *Advances in Neural Information Processing Systems*, 35, 27730-27744. Retrieved from https://proceedings.neurips.cc/paper_files/paper/2022/hash/b1efde53be364a73914f58805a001731-Abstract-Conference.html.
- Sarker, I. H. (2024). LLM potentiality and awareness: a position paper from the perspective of trustworthy and responsible AI modeling. *Discover Artificial Intelligence*, 4(1), 40. <https://doi.org/10.1007/s44163-024-00129-0>.
- Schreyer, M., Sattarov, T., Gierbl, A., Reimer, B., & Borth, D. (2020, October). Learning sampling in financial statement audits using vector quantised variational autoencoder neural networks. *Proceedings... First ACM International Conference on AI in Finance* (pp. 1-8). <https://doi.org/10.1145/3383455.3422546>.
- Schultz, M., & Tropmann-Frick, M. (2020). *Autoencoder neural networks versus external auditors: Detecting unusual journal entries in financial statement audits*. Access on 13th November, 2020. Retrieved from <https://aisel.aisnet.org/hicss-53/os/risks/3/>
- Sebastian, G. (2023). Privacy and data protection in ChatGPT and other AI Chatbots: strategies for securing user information. *International Journal of Security and Privacy in Pervasive Computing (IJSPPC)*, 15(1), 1-14. Retrieved from: <https://www.igi-global.com/article/privacy-and-data-protection-in-chatgpt-and-other-ai-chatbots/325475>

Vasarhelyi, M. A., Moffitt, K. C., Stewart, T., & Sunderland, D. (2023). Large language models: An emerging technology in accounting. *Journal of emerging technologies in accounting*, 20(2), 1-10. <https://doi.org/10.2308/JETA-2023-047>.

Wei, J., Wang, X., Schuurmans, D., Bosma, M., Xia, F., Chi, E., Le, Q. V., & Zhou, D. (2022). Chain-of-thought prompting elicits reasoning in large language models. *Advances in Neural Information Processing Systems*, 35, 24824-24837. Retrieved from https://proceedings.neurips.cc/paper_files/paper/2022/hash/9d5609613524ecf4f15af0f7b31abca4-Abstract-Conference.html.