

CGU-Insight: Inteligência artificial a serviço da auditoria interna

André Luiz Monteiro da Rocha¹ e Tatiana Popia Correa²

Resumo: A auditoria governamental, assim como diversas áreas profissionais, está passando pelo desafio de enfrentar um aumento significativo de informações e dados para a avaliação. O enfrentamento desta questão encontra estratégia relevante no uso de inteligências artificiais. A capacidade de identificar padrões e automatizar tarefas torna o uso essencial. É neste contexto que a Controladoria-Geral da União (CGU) implementa a ferramenta intitulada CGU-Insight. Como metodologia de desenvolvimento, a ferramenta utiliza modelos de IA Generativa da OpenAI que são acessados por uma API. Os módulos, por sua vez, foram implementados com o uso de Engenharia de Prompt. O CGU-Insight utiliza, ainda, a técnica de Retrieval-Augmented Generation (RAG) para auxiliar na análise de documentos, considerando as diversas etapas de um trabalho de auditoria, conforme preconizado pela Orientação Prática de autoria da própria CGU. O resultado obtido foi uma ferramenta que evolui de forma considerável a avaliação de documentos, ainda que existam limitações técnicas a serem aprimoradas oriundas da própria origem dos dados (incompletos, desatualizados, de baixa qualidade, entre outros), bem como segurança de dados e integração com a ferramenta comumente utilizada para auditoria pela organização (e-CGU).

Palavras-chave: Auditoria; avaliação; documento ia. CGU-insight.

1. INTRODUÇÃO

A auditoria interna governamental tem por missão avaliar a aplicação dos recursos públicos e fomentar a melhoria da gestão. Nos últimos anos, porém, esse trabalho vem sendo impactado pelo crescimento exponencial do volume de dados e documentos digitais produzidos pela Administração Pública. Contratos, legislações, notas fiscais e relatórios técnicos — muitas vezes em formatos não estruturados — exigem triagens extensas que consomem tempo valioso e desviam o foco dos auditores de análises estratégicas (Sun, Li, Lu & Guo, 2024).

Além de identificar irregularidades e propor melhorias, o auditor atua em um ciclo de atividades que compreende planejamento, execução, comunicação dos resultados e, finalmente, monitoramento. É nessa etapa final que se verifica a efetiva agregação de valor do trabalho: as recomendações precisam ser acompanhadas até seu pleno atendimento. A Orientação Prática: Serviços de Auditoria da Controladoria-Geral da União (CGU) destaca que, após o envio do relatório final, cabe à unidade auditada documentar tempestivamente as providências adotadas; por sua vez, os auditores devem avaliar se essas medidas atendem, de forma adequada e suficiente, às

1. Auditor Federal de Finanças e Controle. Graduado em Engenharia de Computação pela Universidade Católica Dom Bosco (2003) e pós-graduado em Prevenção e Combate a Desvios de Recursos Públicos pela Universidade Federal de Lavras-MG (2022). Coordenador-Geral de Auditoria de Tecnologia da Informação da CGU (2018 - 2021). Coordenador-Geral de Inteligência de Dados (2021 - 2022). Chefe o Núcleo Estratégico de Prospeção e Ciência de Dados da CGU-MS (2024 -).

2. Auditora Federal de Finanças e Controle. Graduada em Ciência da Computação pela Universidade Federal de Mato Grosso do Sul. Chefe do Núcleo de Ações Especiais na CGU-MS (2019 - 2022). Chefe o Núcleo Estratégico de Prospeção e Ciência de Dados da CGU-SC (2023 -).

recomendações emitidas — o que pode demandar diligências, exames adicionais ou nova avaliação (Brasil, CGU/SFC, 2022). Em síntese, o desafio atual não se limita à análise inicial dos achados: estende-se ao acompanhamento contínuo de grandes volumes de evidências, dentro de prazos cada vez mais curtos e sob pressão por resultados robustos.

A literatura aponta que esse esforço de leitura e classificação manual pode comprometer a qualidade da auditoria, restringindo a elaboração de achados e recomendações de alto impacto. Paralelamente, cresce a expectativa de que as Unidades de Auditoria Interna entreguem resultados mais ágeis, com maior capacidade de detectar irregularidades e gerar valor para a Administração.

Nesse cenário, a Inteligência Artificial (IA) surge como aliada estratégica. Modelos de linguagem, aprendizado de máquina e análise semântica já demonstram capacidade de extrair informações, classificar documentos e identificar padrões suspeitos, automatizando tarefas repetitivas sem perder precisão (Appelbaum, 2017).

Foi justamente para responder a esses desafios que foi desenvolvido o CGU-Insight — aplicação web que integra IA Generativa ao fluxo de auditoria. O sistema oferece módulos para análise documental, síntese de informações, geração de rascunhos de achados e recomendações e avaliação das providências da gestão. Assim, a ferramenta entrega *insights* — que o auditor revisa, valida e aperfeiçoa — liberando tempo para atividades de maior valor agregado, como a definição de critérios, extensão de testes e interlocução com a administração auditada.

1.1 O que é o CGU-insight?

O CGU-Insight é uma aplicação web que emprega modelos de Inteligência Artificial (IA) para auxiliar na condução de auditorias, oferecendo um conjunto de funcionalidades focadas na análise de documentos e geração de insights relevantes para os trabalhos de auditoria.

2. METODOLOGIA E FERRAMENTAS UTILIZADAS

A concepção do CGU-Insight surgiu a partir de uma iniciativa de André Luiz Monteiro da Rocha, do Núcleo Estratégico de Análise e Prospecção de Dados da CGU em Mato Grosso do Sul (NEP/CGU-MS).

O trabalho envolveu, de forma articulada, várias frentes:

- NEP/CGU-MS – concepção da solução, definição da arquitetura tecnológica, programação de todo o núcleo da aplicação e manutenção do backlog funcional;
- NEP/CGU-SC – implementação de módulos complementares e desenvolvimento relacionado a issues específicas, como aprimoramento de prompts e correção de bugs;
- DTI – provisão de infraestrutura e padrões de segurança da informação;
- DIE, CGATI/DG/SFC, CGU-BA – contribuições para os Módulos ETP e TR;
- CGPES/DG/SFC – contribuições para o Módulo Trilhas de Pessoal;
- Equipe multidisciplinar da CGDATA/DIE/SE, CGPLA/SFC e regionais – apoio com discussão técnica;
- Beta-testers de diversas unidades – validação dos módulos em auditorias reais.

Optou-se por uma metodologia ágil e iterativa, organizada em sprints mensais. O código-fonte foi mantido em repositório Git, com cada incremento registrado como *issue* e submetido a *pull request* para revisão entre pares.

2.1 Tecnologias Empregadas

- Backend: FastAPI, empacotado em contêineres Docker.
- Frontend: Streamlit.
- Inteligência Artificial: modelos GPT acessados via Azure OpenAI, combinados a RAG (Retrieval-Augmented Generation).
- Armazenamento temporário: Redis.
- Extração de texto: Apache Tika.
- Orquestração: Docker Compose.

2.2 Abordagens de Inteligência Artificial Generativa Aplicadas

A Inteligência Artificial Generativa é um campo da IA que se enquadra na subárea do Deep Learning. Sua principal capacidade é gerar conteúdo novo e original, como texto, imagens, áudio ou código, em vez de apenas analisar dados existentes. Exemplos notórios dessa tecnologia são modelos como o GPT (da OpenAI) e o Gemini (da Google).

2.2.1 IA Generativa com LLMs (GPT-4o / GPT-4.1 via Azure OpenAI)

O CGU-Insight utiliza modelos de IA Generativa da OpenAI, como *gpt-4o*, *gpt-4.1*, que são acessados e integrados ao sistema por meio de uma API (Interface de Programação de Aplicativos). A ferramenta envia trechos de documentos ou informações escritas diretamente nos campos da interface, em texto puro, para a API do modelo. Isso permite que o CGU-Insight aproveite o poder desses modelos para gerar resumos, extrair informações-chave e auxiliar na análise de documentos de auditoria, sem a necessidade de manter e treinar o modelo internamente. A comunicação via API garante que o sistema possa enviar dados para o modelo e receber as respostas geradas de forma eficiente.

2.2.2 Engenharia de Prompt (Prompt Engineering)

Um prompt é uma entrada (*input*) fornecida a um modelo de Inteligência Artificial Generativa (GenAI) que serve para guiar a sua saída (*output*). Essa entrada pode ser textual — como “Escreva um poema sobre árvores” — ou pode assumir outras formas, incluindo imagens, áudio, vídeos, ou uma combinação dessas modalidades. (Sun, Li, Lu, & Guo, 2024)

A capacidade de interagir com modelos de IA através de prompts, especialmente com linguagem natural, torna-os fáceis de usar e flexíveis para uma ampla gama de casos de uso. Saber como estruturar e avaliar prompts de forma eficaz é essencial para utilizar esses modelos, pois prompts melhores geralmente levam a resultados aprimorados em diversas tarefas. (Sander Schulhoff, 2024)

A engenharia de prompt é um processo iterativo de desenvolvimento de um prompt, que envolve a modificação ou alteração da técnica de *prompting* utilizada. É considerada uma habilidade essencial para interagir e utilizar eficazmente os sistemas de Inteligência Artificial Generativa (GenAI), como os Modelos de Linguagem Grandes (LLMs), para obter resultados aprimorados em diversas tarefas. (Sun, Li, Lu, & Guo, 2024).

Segundo (Sun, Li, Lu, & Guo, 2024) os prompts são frequentemente construídos usando templates de prompt, que são funções contendo uma ou mais variáveis que serão substituídas por algum tipo de mídia (geralmente texto) para criar um prompt. Por

exemplo, o template “Classifique o tweet como positivo ou negativo: {TWEET}” se torna um prompt quando um tweet específico é inserido em {TWEET}.

Componentes comuns de um prompt incluem:

- Papel (“Role” ou “Persona”): Atribui um papel ou persona específico ao GenAI, o que pode melhorar a escrita e o estilo do texto. Por exemplo, pedir para o modelo “Você é um assistente especialista em criar Matriz de Achado de Auditoria”.
- Diretiva: A intenção central do prompt, geralmente na forma de uma instrução ou pergunta. Pode ser explícita (como “Crie uma Matriz de Achados”) ou implícita (como em um exemplo de tradução “Night: Noche Morning:”).
- Exemplos (Exemplars ou “Shots”): Demonstrações que orientam o GenAI na execução de uma tarefa. O “few-shot prompting” (prompting de poucas tentativas) é um paradigma onde o GenAI aprende uma tarefa com apenas alguns exemplos. O “one-shot prompting” (prompting de uma tentativa) utiliza apenas um exemplo.
- Informações Adicionais: Contexto extra que pode ser incluído no prompt para auxiliar o GenAI.
- Instruções de Estilo: Modificam o estilo da saída, e não sua estrutura, por exemplo, “Escreva um parágrafo claro e conciso”.
- Formatação de Saída: Instruções para que o GenAI gere informações em formatos específicos, como CSVs ou Markdown.

Os módulos do CGU-Insight foram implementados com o uso de Engenharia de Prompt e utilização dos componentes citados.

2.2.3 Geração Aumentada por Recuperação (RAG)

Modelos de linguagem em larga escala pré-treinados, como GPT-4o e outros, armazenam conhecimento factual em seus parâmetros após a fase de treinamento, mas sua capacidade de acessar e manipular esse conhecimento é limitada, levando a um desempenho inferior em tarefas intensivas em conhecimento em comparação com arquiteturas específicas para essas tarefas. Eles também podem não conseguir expandir ou revisar facilmente sua memória e podem produzir “alucinações”. (Lewis, 2020)

RAG, que significa Retrieval-Augmented Generation (Geração Aumentada por Recuperação), é uma técnica que combina a memória paramétrica (conhe-

cimento aprendido nos pesos do modelo) de um modelo de linguagem pré-treinado com uma memória não-paramétrica explícita (conhecimento recuperado de uma base de dados ou documentos externos, que é acessada por meio de um mecanismo de recuperação). (Lewis, 2020).

2.2.4 Etapas

Desde o início até o MVP, transcorreram aproximadamente 12 meses. O processo seguiu quatro etapas recorrentes:

- Mapeamento de casos de uso prioritários (análise documental, geração de achados, monitoramento de recomendações);
- Prototipagem rápida em Streamlit para validar fluxos diretamente com auditores;
- Integração incremental de componentes de IA generativa, afinando *prompt engineering*, métricas de qualidade e tempo de resposta;
- Testes em auditorias reais, que orientaram ajustes finos, inclusão de novas funcionalidades e correções de segurança.

Com essa abordagem, o CGU-Insight evoluiu de uma prova de conceito para uma aplicação web, disponível para qualquer auditor interessado em testar a solução. Hoje, o sistema oferece sugestões e insights – como rascunhos de achados, recomendações e resumos de documentos – mas a decisão final e o aperfeiçoamento permanecem 100% sob responsabilidade do auditor.

3. RESULTADOS E IMPACTOS OBTIDOS

O CGU-Insight utiliza a técnica de *Retrieval-Augmented Generation (RAG)* para auxiliar na análise de documentos em diversas etapas do trabalho de auditoria, como a verificação do atendimento a recomendações, a avaliação de Estudos Técnicos Preliminares (ETPs) e Termos de Referência (TRs), além da análise de trilhas de pessoal.

Um exemplo prático ocorre quando o gestor responde a uma recomendação no sistema e-CGU. Nesse processo, ele preenche informações sobre o cumprimento ou não da recomendação e anexa documentos comprobatórios. O CGU-Insight, por meio de integração com a API do sistema e-CGU, acessa a tarefa correspondente, realiza o download dos arquivos anexados, extrai seu conteúdo textual e con-

verte trechos do texto (chamados *chunks*) em vetores de embeddings, que são armazenados em um banco de vetores.

Durante a análise, o sistema realiza uma busca semântica nesse banco, recuperando apenas os trechos mais relevantes dos documentos para compor uma resposta fundamentada. Essa abordagem permite ao modelo gerar respostas mais precisas, ancoradas nos dados fornecidos pelos próprios gestores.

3.1 Vantagens do uso de RAG

A utilização da técnica RAG no CGU-Insight oferece algumas vantagens para a análise de documentos de auditoria. Primeiramente, a principal delas é a precisão e a confiabilidade das informações. Ao ancorar as respostas em trechos extraídos diretamente dos documentos anexados pelos gestores, o sistema reduz o risco de alucinações — informações inventadas pelos modelos de linguagem — e garante que cada análise seja baseada em evidências reais.

Essa abordagem de busca e recuperação de trechos relevantes também garante a fundamentação e a rastreabilidade das respostas, permitindo que o auditor saiba exatamente de onde a informação foi retirada. Isso é fundamental para a transparência e a validação do trabalho de auditoria.

Além disso, o RAG aumenta a eficiência e a contextualização da análise. Em vez de processar documentos inteiros, o sistema recupera apenas os trechos mais relevantes para a pergunta ou tarefa em questão. Isso não só acelera o processo, poupando o tempo do auditor que teria que ler manualmente longos documentos, como também fornece um contexto preciso para o modelo, que pode gerar respostas mais focadas e detalhadas.

Essa técnica torna o processo de análise escalável, permitindo que o sistema lide com um volume crescente de documentos de forma rápida, já que a busca semântica em bancos de vetores é extremamente eficiente.

Por fim, a abordagem otimiza o uso do modelo de linguagem, reduzindo custos e recursos computacionais ao evitar que o modelo precise ler e processar arquivos extensos, tornando a análise mais prática e econômica para a instituição.

3.2 Limitações do RAG

Apesar das grandes vantagens, a implementação do RAG também apresenta algumas limitações que precisam ser consideradas.

Uma das principais limitações é a dependência da qualidade dos dados de origem. Se os documentos anexados pelos gestores forem de baixa qualidade, estiverem incompletos, desatualizados ou contiverem informações incorretas, o sistema de RAG simplesmente irá recuperá-las e o modelo pode gerar respostas baseadas nesses dados falhos.

Outro ponto crítico é o processamento de documentos complexos. Se os arquivos forem PDFs com tabelas, imagens, layouts inconsistentes ou estruturas complexas, a extração de texto pode ser comprometida, resultando em “chunks” incompletos ou sem sentido. Se a informação não for extraída corretamente, a busca e a geração da resposta serão afetadas negativamente.

Além disso, a eficácia da recuperação semântica pode ser um desafio. O sistema pode ter dificuldade em diferenciar significados semelhantes de uma mesma palavra ou em encontrar nuances em tópicos muito específicos. Isso pode levar à recuperação de trechos que não são os mais relevantes, fazendo com que o modelo gere uma resposta incompleta ou menos precisa do que o esperado.

Há também o risco de descontextualização, onde um trecho relevante é recuperado, mas a falta de contexto ao redor desse trecho pode fazer com que o modelo o interprete de forma errada.

Ademais, sistemas RAG podem ser vulneráveis a falhas de conteúdo, onde o usuário faz uma pergunta cuja resposta simplesmente não existe na base de documentos. Nesses casos, o ideal seria que o modelo de IA generativa informasse que não tem a resposta, mas existe o risco de que ele tente criar uma resposta plausível, mas incorreta, apenas para não “admitir” a falta de informação.

3.3 Processamento Assíncrono

No CGU-Insight, o processamento de arquivos e a interação com o modelo de IA são feitos de forma assíncrona. Assim, após enviar uma solicitação, o usuário pode continuar utilizando o sistema enquanto a análise ocorre em segundo plano, recebendo a resposta em poucos instantes.

Esse modelo foi adotado devido ao grande volume de dados e à complexidade das análises, que envolvem extração de texto e criação de vetores de embeddings. Se o processamento fosse imediato, o sistema ficaria sobrecarregado e pouco responsivo. A execução assíncrona permite atender simultaneamente vários usuários, mantendo estabilidade, rapidez e uma experiência de uso fluida.

3.3.1 Módulos do CGU-Insight

As funcionalidades do sistema são organizadas em módulos, o que possibilita expansão gradual:

- **Recomendações** – avalia o cumprimento de recomendações de auditoria.
- **Achados de Auditoria** – registra e organiza os achados identificados.
- **Matriz de Achados** – estrutura as constatações em um documento único (critérios, evidências, causas e efeitos).
- **Supervisão** – apoia a análise de papéis de trabalho.
- **Estudo Técnico Preliminar (ETP)** – avalia estudos técnicos preliminares de contratações, inicialmente de TIC.
- **Termo de Referência (TR)** – analisa TRs de contratações, também com foco inicial em TIC.
- **Trilhas de Pessoal** – apoia auditorias sobre pagamentos e registros de servidores.

3.3.2 Módulo Recomendações

Permite verificar o atendimento de recomendações por duas formas:

- **Via API do e-CGU**, acessando diretamente tarefas e documentos anexos;
- **Por parâmetros manuais**, em que o auditor insere dados da recomendação e, se necessário, complementa com arquivos de apoio.

3.3.3 Módulo Matriz de Achados

Apoia a elaboração da matriz de achados, documento que organiza as constatações da auditoria de forma sintética e estruturada. Os campos disponíveis incluem questão e subquestão de auditoria, descrição sumária, critério, condição, evidências, causas, efeitos, boas práticas, recomendações e benefícios esperados. O preenchimento é flexível e pode

ser exportado para planilhas, agilizando relatórios.

3.3.4 Módulo Achados de Auditoria

Permite importar uma matriz já elaborada (em formatos como PDF, DOCX ou XLSX) para gerar automaticamente achados de auditoria. Essa automação reduz o esforço manual e auxilia na produção de relatórios técnicos.

3.3.5 Módulo Supervisão

Suporta a avaliação de documentos-chave da auditoria, como documento de entendimento, matriz de riscos e controles, planejamento e plano amostral. Aceita diversos formatos e facilita o acompanhamento da conformidade dos trabalhos.

3.3.6 Módulo Estudo Técnico Preliminar (ETP)

Destina-se à análise de estudos técnicos preliminares que embasam contratações. Inicialmente, contempla contratações de Tecnologia da Informação, mas poderá ser expandido para outras áreas.

3.3.7 Módulo Termo de Referência (TR)

Verifica a adequação dos TRs às exigências legais e normativas. O módulo assegura que o documento contenha informações essenciais, como objeto, prazos, fundamentação e referência ao ETP.

3.3.8 Módulo Trilhas de Pessoal

Suporta auditorias transversais na folha de pagamento federal, verificando conformidade de rubricas e cadastros de servidores. A análise depende da integração via API com o e-CGU, a partir da qual os resultados podem ser consultados diretamente no sistema.

3.4 Os Desafios da Integração

O CGU-Insight foi projetado para atuar como uma ponte, integrando a Inteligência Artificial Generativa ao Sistema e-CGU. Essa arquitetura, no entanto, apresenta desafios importantes que precisam ser gerenciados para garantir a eficácia e a segurança da ferramenta.

O principal desafio é a segurança de dados. Ao processar os arquivos dentro do próprio ambiente do CGU-Insight, a plataforma visa proteger informações sensíveis. Isso evita que os documentos de auditoria sejam enviados diretamente para os servi-

dores externos dos modelos de linguagem, minimizando o risco de exposição de dados confidenciais. No entanto, essa abordagem exige um ambiente de processamento robusto e seguro, com protocolos de criptografia e acesso restrito para garantir que as informações sejam manipuladas com a máxima proteção.

Outro ponto é a complexidade técnica da integração. O CGU-Insight precisa manter uma comunicação estável e confiável com o Sistema e-CGU por meio de endpoints de API. Qualquer instabilidade nessa conexão pode interromper o fluxo de trabalho, impactando a análise de documentos.

Além disso, a plataforma deve ser capaz de lidar com a variedade de formatos de documentos e a quantidade de dados gerados no e-CGU, exigindo um sistema de extração e vetorização de conteúdo eficiente. A manutenção e a evolução contínua dessas APIs também são desafios, pois qualquer atualização em um dos sistemas pode exigir adaptações no outro para garantir a compatibilidade e o bom funcionamento da integração.

3.5 Os Próximos Passos

O CGU-Insight é uma ferramenta em constante evolução, e seu futuro é focado em ampliar sua atuação para cobrir a maior parte das fases de uma auditoria. O objetivo é que a plataforma se torne um apoio integral para o auditor, com módulos específicos para cada etapa do processo.

Isso inclui a análise de riscos, ajudando a identificar áreas de maior vulnerabilidade antes mesmo do início dos trabalhos. Além disso, a ferramenta auxiliará no planejamento de auditoria, sugerindo caminhos e focos de análise. Durante a execução, o CGU-Insight continuará a apoiar na análise documental, como já faz.

Paralelamente a essa expansão de funcionalidades, a integração de mecanismos de segurança se manterá como uma prioridade absoluta. Conforme a ferramenta se torna mais integrada e lida com mais dados confidenciais, a garantia da segurança das informações e a proteção contra acessos não autorizados se tornam cada vez mais fundamentais para a sua evolução e adoção.

4. CONSIDERAÇÕES FINAIS E PRINCIPAIS CONTRIBUIÇÕES

Em suma, o CGU-Insight representa um avanço significativo no campo da auditoria governamental, atuando como um catalisador de eficiência e qualidade. Ao automatizar a análise de documentos por meio de módulos especializados e da tecnologia de IA Generativa, o sistema não apenas agiliza tarefas que antes eram manuais e demoradas, como também eleva a precisão das análises ao ancorar suas respostas em evidências documentais concretas, utilizando a técnica de RAG.

Apesar de desafios inerentes, como a dependência da qualidade dos dados de origem e a complexidade da integração tecnológica, a arquitetura do CGU-Insight — com seu processamento assíncrono e foco na segurança — demonstra um planejamento robusto e escalável.

Olhando para o futuro, a evolução da ferramenta para cobrir todas as fases da auditoria, do planejamento à supervisão, promete transformá-la em um apoio integral para o auditor. O compromisso contínuo com a segurança de dados e aprimoramento tecnológico consolidará o CGU-Insight como uma peça-chave na modernização da fiscalização pública, permitindo que a CGU atenda à crescente demanda por resultados tempestivos e de maior valor para a sociedade.

REFERÊNCIAS

- APPELBAUM, D. K. Big data and analytics in the modern audit engagement: research needs. *Auditing: A Journal of Practice & Theory*, [S.l.], v. 36, n. 4, p. 1–27, 2017. Disponível em: <https://doi.org/10.2308/ajpt-51684>. Acesso em: 18 de julho de 2025.
- BRASIL. Controladoria-Geral da União. Secretaria Federal de Controle Interno. Orientação prática: serviços de auditoria. Brasília, DF: Repositório de Conhecimento da CGU, 2022. Disponível em: <https://repositorio.cgu.gov.br/handle/1/68936>. Acesso em: 18 de julho de 2025.
- BRASIL. Lei nº 14.133, de 1º de abril de 2021. Lei de Licitações e Contratos Administrativos. Brasília, 2021. Disponível em: https://www.planalto.gov.br/ccivil_03/ato2019-2022/2021/lei/L14133.htm. Acesso em: 18 de julho de 2025.
- CGU. Auditoria de pessoal: análise de atos de pessoal – perguntas e respostas. Brasília, DF: Controladoria-Geral da União, 2022. Disponível em: https://basedeconhecimento.cgu.gov.br/bitstream/1/14720/1/Cartilha_de_Pessoal_2022.pdf. Acesso em: 18 de julho de 2025.
- SCHULHOFF, M. I. S. The prompt report: a systematic survey of prompting techniques. 2024. Disponível em: <https://arxiv.org/abs/2406.06608>. Acesso em: 18 de julho de 2025.
- SUN, Y.; LI, J.; LU, M.; GUO, Z. Study of the impact of the big data era on accounting and auditing. 11 mar. 2024. Disponível em: <https://arxiv.org/abs/2406.06608>. Acesso em: 18 de julho de 2025.
- LEWIS, P. et al. Retrieval-augmented generation for knowledge-intensive NLP tasks. 2020. Disponível em: <https://arxiv.org/abs/2005.11401>. Acesso em: 18 de julho de 2025.