

**MINISTÉRIO DA DEFESA  
EXÉRCITO BRASILEIRO  
GAB CMT EX – CIE  
ESCOLA DE INTELIGÊNCIA MILITAR DO EXÉRCITO**



**CURSO AVANÇADO DE INTELIGÊNCIA PARA OFICIAIS**

**TRABALHO DE CONCLUSÃO DE CURSO**



**EMPREGO DE CHATBOTS DE *LLM* NA ANÁLISE DE INTELIGÊNCIA**

**Brasília  
2024**

TC LÚCIO JERÔNIMO

**EMPREGO DE CHATBOTS DE *LLM* NA ANÁLISE DE INTELIGÊNCIA**

Trabalho de Conclusão de Curso apresentado à Escola de Inteligência Militar do Exército, como requisito para a obtenção do Grau de Pós-graduação *Lato Sensu* de **Especialização em Análise de Inteligência**.

Orientadores: Ten Cel EDUARDO **SCHWARZER**  
Cap CRISTIANO MONTEIRO **NUNES**

**Brasília**  
**2024**

J56e Jerônimo, Lúcio

**EMPREGO DE CHATBOTS DE *LLM* NA ANÁLISE DE INTELIGÊNCIA/** Lúcio  
Jerônimo - 2024.  
42 f. : il.

Trabalho de Conclusão de Curso (Especialização em Análise de Inteligência) -  
Escola de Inteligência Militar do Exército (EsIMEx), 2024.  
Orientadores: TC Eduardo Schwarzer e Cap Cristiano Monteiro Nunes.

1. Exército Brasileiro 2. Análise de Inteligência 3. Inteligência Artificial 4. *Large Language Model* 5. Chatbot

TC LÚCIO JERÔNIMO

## EMPREGO DE CHATBOTS DE *LLM* NA ANÁLISE DE INTELIGÊNCIA

Trabalho de Conclusão de Curso apresentado à Escola de Inteligência Militar do Exército, como requisito para a obtenção do Grau de Pós-graduação *Lato Sensu* de **Especialização em Análise de Inteligência**.

Aprovado em \_\_\_ de \_\_\_ de 2024.

COMISSÃO DE AVALIAÇÃO:

---

MARCELO DO NASCIMENTO **VAILLANT** – TC – Presidente  
Escola de Inteligência Militar do Exército

---

EDUARDO **SCHWARZER** – TC – Membro  
Escola de Inteligência Militar do Exército

---

THIAGO DE SOUZA **GONÇALVES** – Maj – Membro  
Escola de Inteligência Militar do Exército

---

CRISTIANO MONTEIRO **NUNES** – Cap – Membro  
Centro de Inteligência do Exército

## RESUMO

O aumento exponencial de informações disponíveis representa um desafio significativo para os Analistas de Inteligência, especialmente no contexto militar. Este Trabalho de Conclusão de Curso (TCC) investiga a viabilidade e a eficácia do uso de chatbots baseados em *Large Language Models (LLMs)* no Sistema de Inteligência do Exército (SIEx). O objetivo é melhorar o processamento e a análise de grandes volumes de dados, permitindo que os analistas identifiquem padrões, tendências e ameaças potenciais de maneira mais eficiente. A metodologia adotada inclui uma revisão bibliográfica, análise comparativa de chatbots e avaliação de desempenho, focando em três principais categorias de aplicação: funcionalidades básicas de *LLM*, Técnicas de Análise Estruturada (TAE) e níveis complexos de análise de inteligência. A pesquisa propõe o uso de modelos *open source*, especificamente o Llama 3 da Meta, devido à sua flexibilidade, capacidade de adaptação e conformidade com padrões de segurança. Técnicas como a Geração Aumentada de Recuperação (*RAG*) e o *LoRA Fine Tuning* foram destacadas como métodos eficazes para customização e integração desses modelos em bases de dados legadas do SIEx. Os principais resultados indicam que a implementação de chatbots de *LLM* pode aumentar significativamente a eficiência e a precisão das análises de inteligência, ao mesmo tempo em que garante a segurança e a confidencialidade das informações. A solução proposta foi comparada com o ChatGPT-4o, mostrando que, embora o modelo da OpenAI tenha desempenho superior em algumas métricas, o Llama 3 se destacou pela governança da informação e adequação ao contexto específico do SIEx. Conclui-se que o emprego de chatbots de *LLM* é viável e benéfico para a Análise de Inteligência no Exército Brasileiro. Recomenda-se a implementação de um chatbot baseado no modelo Llama 3, com foco na integração segura e eficiente com sistemas legados. Trabalhos futuros podem explorar como a IA pode contribuir com a Análise de Inteligência, destacando a produção específica de Técnicas de Análise Estruturada, o uso de *LLMs* proprietários e a automatização de processos de obtenção de conhecimento a partir de diversas Fontes de Inteligência.

Palavras-chave: Exército Brasileiro. Análise de Inteligência. Inteligência Artificial. *Large Language Model (LLM)*. Chatbots.

## **ABSTRACT**

The exponential increase in available information presents a significant challenge for Intelligence Analysts, especially in the military context. This Final Paper investigates the feasibility and effectiveness of using chatbots based on Large Language Models (LLMs) in the Brazilian Army Intelligence System (SIEEx). The objective is to improve the processing and analysis of large volumes of data, enabling analysts to identify patterns, trends, and potential threats more efficiently. The methodology adopted includes a literature review, comparative analysis of chatbots, and performance evaluation, focusing on three main application categories: basic LLM functionalities, Structured Analytic Techniques (SATs), and complex levels of intelligence analysis. The research proposes the use of open-source models, specifically Meta's Llama 3, due to its flexibility, adaptability, and compliance with security standards. Techniques such as Retrieval-Augmented Generation (RAG) and LoRA Fine Tuning were highlighted as effective methods for customizing and integrating these models into SIEEx's legacy databases. The main results indicate that implementing LLM chatbots can significantly enhance the efficiency and accuracy of intelligence analyses while ensuring the security and confidentiality of information. The proposed solution was compared with ChatGPT-4o, showing that although OpenAI's model performed better in some metrics, Llama 3 excelled in information governance and suitability for the specific context of SIEEx. It is concluded that the use of LLM chatbots is feasible and beneficial for Intelligence Analysis in the Brazilian Army. The implementation of a chatbot based on the Llama 3 model is recommended, focusing on secure and efficient integration with legacy systems. Future works can explore how AI can further contribute to Intelligence Analysis, highlighting the specific production of structured analytic techniques, the use of proprietary LLMs, and the automation of knowledge acquisition processes from various intelligence sources.

**Keywords:** Brazilian Army. Intelligence Analysis. Artificial Intelligence. Large Language Model (LLM). Chatbots.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>7</b>
<b>2</b>	<b>APLICABILIDADE DE <i>LLM</i> NA ANÁLISE DE INTELIGÊNCIA.....</b>	<b>11</b>
2.1	A METODOLOGIA DE PRODUÇÃO DO CONHECIMENTO.....	12
2.2	TÉCNICAS DE ANÁLISE ESTRUTURADA (TAE).....	13
2.3	NÍVEIS DE ANÁLISE DE INTELIGÊNCIA.....	14
<b>3</b>	<b>SOLUÇÕES DE <i>LLM</i>.....</b>	<b>17</b>
3.1	DESENVOLVIMENTO DE MODELOS PRÓPRIOS DE <i>LLM</i> .....	17
3.2	MODELOS FECHADOS E/OU PROPRIETÁRIOS DE LICENÇAS RESTRITIVAS.....	18
3.3	CUSTOMIZAÇÃO DE MODELOS ABERTOS ( <i>OPEN SOURCE</i> ).....	21
3.4	TÉCNICAS DE CUSTOMIZAÇÃO E INTEGRAÇÃO DE <i>LLM</i> EM BASES DE DADOS LEGADAS DO SIEX.....	23
<b>4</b>	<b>PROPOSTA DE CHATBOT PARA ANÁLISE DE INTELIGÊNCIA .....</b>	<b>26</b>
4.1	IMPLEMENTAÇÃO DO CHATBOT DE <i>LLM</i> .....	28
4.2	EMPREGO E EXPERIMENTO DO CHATBOT DE <i>LLM</i> PARA ANÁLISE DE INTELIGÊNCIA.....	30
<b>5</b>	<b>CONCLUSÃO.....</b>	<b>37</b>
	<b>REFERÊNCIAS.....</b>	<b>39</b>
	APÊNDICE A – Análise Prescritiva gerada pelo Chatbot Llama 3.....	41
	APÊNDICE B – Análise Prescritiva gerada pelo ChatGPT 4o.....	42

## 1 INTRODUÇÃO

O ser humano experimenta, atualmente, um dos momentos mais relevantes do seu constante processo evolutivo. As tecnologias disruptivas, como a Inteligência Artificial (IA), já são realidades em atendimento aos clientes, aplicativos, serviços web e diagnósticos na área de saúde, por exemplo.

Segundo Devanny, Dylan e Grossfeld (2023), o potencial das aplicabilidades da IA é tão poderoso que alguns autores já consideram seu impacto como análogo a outra revolução industrial.

Conceitos como *machine learning*, *deep learning* e *large language model* começam a se descortinar para a sociedade digital. Tudo isso, se mesclando a ideias mais consolidadas, como *big data*, internet das coisas (IoT), redes sociais, conectividade, armazenamento em nuvem entre outros, que já fazem parte do vernáculo comum.

Com isso, o aumento exponencial de informações disponíveis apresenta um dilema significativo para o ser humano, conforme afirma Hendrickson (2018). Qualquer informação está a um clique de distância. Porém, o desafio é buscar aquilo que tem relevância e veracidade.

Nesse sentido, a sociedade está imersa no conceito da pós-verdade<sup>2</sup> - que se refere a uma situação na qual os fatos objetivos têm menos influência na formação da opinião pública do que apelos emocionais e crenças pessoais. Assim, as emoções, as narrativas e as percepções pessoais têm mais peso do que os fatos verificáveis na moldagem das opiniões e na formulação de políticas (D'Ancona, 2017).

A Inteligência Militar – parte das ciências militares – também vem acompanhando esse processo evolutivo baseado em tecnologia. Os analistas de inteligência compartilham o mesmo problema enfrentado pela sociedade: como

---

<sup>1</sup> Oficial de Comunicações do Exército Brasileiro - Academia Militar das Agulhas Negras (2002). Mestre em Ciências Militares – Escola de Aperfeiçoamento de Oficiais (2010). Pós-graduado pela Escola de Comando e Estado-Maior do Exército (2019). jeronimo.lucio@eb.mil.br

<sup>2</sup> A origem do termo "pós-verdade" pode ser rastreada até a década de 1990, mas ganhou destaque mundial em 2016, quando o *Oxford Dictionaries* escolheu "pós-verdade" (*post-truth*) como a palavra do ano.

processar grandes quantidades de informações, notícias, publicações, comentários – em diversas plataformas e meios de comunicações, somado a um tempo exíguo para entregar produtos de relevância (Devanny, Dylan e Grossfeld 2023). Tudo isso, em um espectro de fontes que permeiam os grandes consórcios de comunicações, passa por colaboradores, outras agências e influenciadores digitais, alcançando até as pessoas comuns – que utilizam somente um *smartphone* para suas postagens em redes sociais.

Para enfrentar essa dinâmica, o uso de tecnologias com Inteligência Artificial embarcada representa uma resposta coerente e exequível. Especificamente, o uso de soluções tecnológicas seguras, como chatbots baseados em *Large Language Models (LLMs)*, emerge como uma abordagem promissora, uma vez que tais soluções já estão em produção em outras áreas do conhecimento humano, podendo impactar positivamente como uma ferramenta para os analistas de Inteligência (Plum, 2023).

As aplicações de Linguagem de Larga Escala são modelos de inteligência artificial que usam técnicas de aprendizado de máquina para compreender e produzir texto avançado. Esses modelos são treinados em grandes conjuntos de dados textuais com o objetivo de aprender as estruturas e padrões da linguagem humana. Eles têm a capacidade de executar uma ampla gama de tarefas de processamento de linguagem natural, como traduzir idiomas automaticamente, criar texto, responder a perguntas e analisar sentimentos (OpenAI, 2024a).

Um dos principais exemplos de *Large Language Model* é o *Generative Pre-trained Transformer (GPT)*, desenvolvido pela *OpenAI*<sup>3</sup> e lançado em novembro de 2022, como ChatGPT 3.0. Com sua primeira versão lançada em junho de 2018, o *GPT* é amplamente utilizado em aplicativos devido à sua capacidade de produzir texto coerente e contextualmente relevante em uma variedade de aplicações.

Desse modo, tais modelos têm aptidão para realizarem atividades e processos de análise de grandes quantidades de documentos, produzindo sumarização, tradução e relacionamento. Tais ações podem contribuir para uma Análise de Inteligência mais efetiva e relevante. Assim, os chatbots de *LLM* podem contribuir significativamente com as tarefas de um analista de Inteligência, fornecendo análises

---

<sup>3</sup> A *OpenAI* é uma empresa de pesquisa em inteligência artificial fundada em 2015 e tem como objetivo principal promover o desenvolvimento seguro e benéfico da inteligência artificial para o benefício de toda a humanidade. Suas contribuições incluem a criação de modelos de linguagem avançados, como o *GPT (Generative Pre-trained Transformer)*, cuja aplicação é o ChatGPT, bem como pesquisas inovadoras em uma variedade de áreas da IA.

baseadas em evidências, que são essenciais para o fornecimento de conhecimentos que atendam às necessidades dos decisores.

A Estratégia Nacional de Inteligência (ENINT) já ampara e fomenta o emprego da Inteligência Artificial como ferramenta para melhoria das atividades de Inteligência:

O cenário de evolução tecnológica implica também a crescente produção e armazenamento de grandes volumes de dados nos meios digitais (big data). A obtenção e a análise dessas quantidades massivas de dados ensejam oportunidades para a atividade de Inteligência, seja ela brasileira ou adversa. São os casos da utilização de aplicações para análise de vínculos, entendimento de contextos, localização de pessoas e de lugares e uso de inteligência artificial e de técnicas analíticas para grandes conjuntos de dados (*analytics*) (Brasil, 2017, p. 14).

O Sistema de Inteligência do Exército (SIEEx), por meio do Programa Lucerna e materializado pelo Projeto Hermes, além de orientar o desenvolvimento e adequação dos meios de tecnologia da informação e comunicações (MTIC), prospecta a utilização de IA para suas atividades, em especial na Análise de Inteligência, visando ampliar a capacidade de análise de seus profissionais (Brasil, 2014). Desse modo, nota-se um alinhamento do SIEEx, não somente com a Estratégia Nacional de Inteligência, mas com a tendência natural do uso de IA nas soluções e desafios da sociedade moderna.

A despeito do uso de chatbots por outras áreas do conhecimento, a Análise de Inteligência carece de interfaces que ofereçam maior segurança no tratamento das informações. O ChatGPT, notoriamente o chatbot mais popular atualmente, armazena as pesquisas e respostas (*inputs e outputs*) em um histórico nos servidores da OpenAI – não atendendo aos requisitos da atividade de inteligência, especificamente do ramo Contrainteligência (Plum, 2023). Ademais, todo conteúdo gerado foi previamente “ensinado” para a ferramenta e não se tem o domínio das fontes e suas orientações ou vieses. Com isso, não é possível avaliar a idoneidade da fonte e a veracidade do conteúdo – fatores fundamentais para a produção do conhecimento por parte dos analistas de inteligência (Brasil, 2019).

Desse modo, busca-se soluções que possam trabalhar de forma segura, onde a interação e respostas fiquem preservadas e o conteúdo de análise seja de governança da própria organização, nesse caso o SIEEx.

Assim, o presente estudo científico tem por objeto a Análise de Inteligência. Na formulação do problema, as causas apontam que os chatbots baseados em *LLM* já estão em uso em diversas áreas do conhecimento, mas não de forma segura na Análise de Inteligência.

Nesse viés, pergunta-se, de maneira a fomentar a investigação, como aperfeiçoar a Análise de Inteligência por meio do emprego de Inteligência Artificial?

A hipótese que responde à pergunta de investigação consiste no emprego de chatbots seguros baseados em *LLMs*. Assim, o propósito é empregar ferramentas tecnológicas para melhorar os processos existentes na Análise de Inteligência.

A justificativa da presente investigação científica se ancora no fato dos analistas de inteligência terem uma quantidade excessiva de informação para processar. Soma-se a isso a relevância do presente trabalho, uma vez que poderá impactar positivamente a atividade de análise de Intlg, economizando meios e melhorando resultados.

Dessa forma, o objetivo geral o trabalho é propor um modelo de chatbot para emprego na Análise de Inteligência.

Por meio de revisão bibliográfica, análises comparativas de chatbots e avaliações de desempenho, pretende-se oferecer recomendações práticas para a integração bem-sucedida dessas tecnologias na estrutura de Inteligência Militar.

Para atingir o objetivo proposto, o Capítulo 2 (objetivo específico 1) trará uma abordagem sobre a aplicabilidade de *LLM* na Análise de Inteligência, ou seja, em quais etapas ou processos pode-se implementar o uso de chatbots baseados em *LLM*. O Capítulo 3 (objetivo específico 2) aprofundará os tipos de chatbots baseado em *LLM* disponíveis, bem como suas características. O Capítulo 4 (objetivo específico 3) será a interseção dos dois capítulos anteriores, discorrendo sobre uma proposta de chatbot para Análise de Inteligência. Finalmente, o Capítulo 5 trará as conclusões e recomendações sobre a presente investigação acadêmica.

## 2 APLICABILIDADE DE LLM NA ANÁLISE DE INTELIGÊNCIA

A Análise de Inteligência Militar pode ser definida como um processo sistemático de coleta, avaliação, interpretação e disseminação de informações relevantes para apoiar a tomada de decisões em todos os níveis de condução de conflitos. Envolve a análise de diversas fontes de informação, como imagens de satélite (*IMINT*), relatórios de inteligência humana (*HUMINT*), interceptações de comunicações (*SIGINT*) e dados de inteligência de fontes abertas (*OSINT*). O objetivo é fornecer uma compreensão abrangente do ambiente operacional, incluindo ameaças, vulnerabilidades, oportunidades e tendências, a fim de orientar o planejamento e a execução de operações militares de forma eficaz e adaptativa (*OpenAI, 2024b*).

No âmbito da Doutrina Militar Terrestre (DMT), tem-se a definição que:

Análise de Inteligência é o processo pelo qual as informações coletadas são avaliadas e integradas com informações existentes para produzir conhecimentos que descrevem o ambiente operacional (terreno e considerações civis); o inimigo, as ameaças ou forças oponentes; e como as condições meteorológicas influenciam as operações. É uma abordagem disciplinada e consistente para a resolução de problemas, que auxilia o analista ou Estado-Maior a determinar conclusões precisas e isentas com base em dados disponíveis (Brasil, 2019, p. 2-1).

Assim, infere-se que o papel da Inteligência é “subsidiar a tomada de decisão do comandante. O conhecimento de Inteligência deve ser oportuno, relevante (claro), preciso, preditivo e personalizado” (Brasil, 2019, p. 2-1).

Em um passado recente, os analistas de inteligência não apontavam para os decisores “o que fazer” diante de determinado cenário (Clark, 2022). Tudo porque o levantamento de possíveis soluções era atribuição das células de operações e planejamento. Com isso, a atividade de Inteligência se eximia de uma possível culpa, caso a linha de ação não obtivesse êxito ou estivesse errada. Por outro lado, a Inteligência ficava relegada a um segundo plano, uma vez que trazia um quadro de consciência situacional – que na maioria das vezes já era de conhecimento, pelo menos parcial, dos decisores.

Atualmente a Inteligência, em sentido amplo, busca um papel mais atuante no processo decisório. Assim, os produtos de Inteligência vão além da descrição e predição – buscam, também, destacar as possíveis ações para o tema em estudo – nível denominado Inteligência Prescritiva.

## 2.1 A METODOLOGIA DE PRODUÇÃO DO CONHECIMENTO

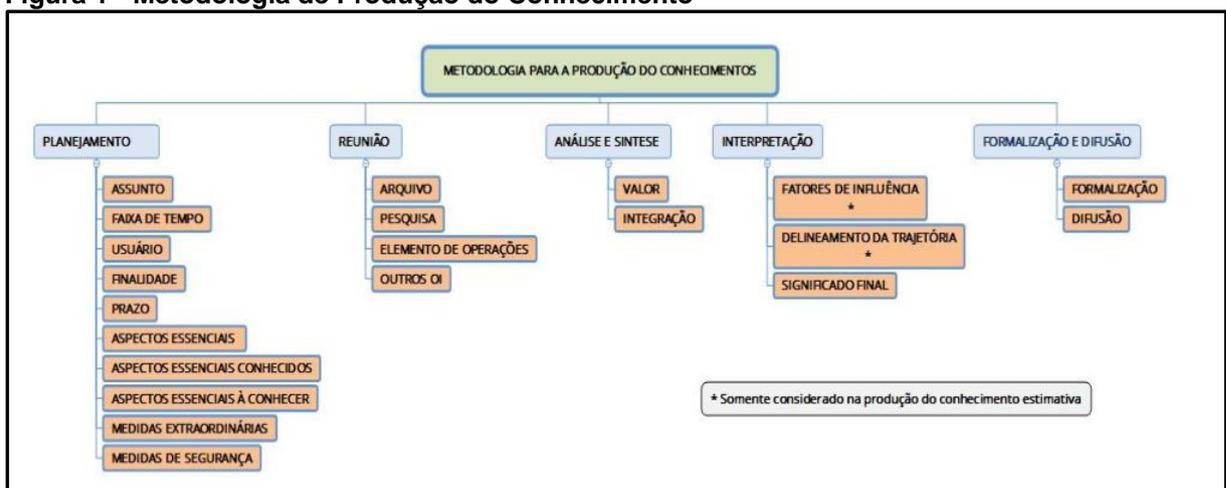
A Metodologia para a Produção do Conhecimento consiste na sequência ordenada de procedimentos executados pelo analista, com vistas à produção de um conhecimento de Inteligência de forma racional e com melhores resultados.

Segundo o Manual de Produção do Conhecimento de Inteligência, é necessário que o analista conheça e empregue a metodologia preconizada, a fim de: garantir que todos os aspectos do problema sejam considerados; produzir um conhecimento em bases científicas; uniformizar procedimentos; e assegurar que o usuário confira credibilidade ao conhecimento produzido (Brasil, 2019).

Essa metodologia é aplicável, no todo ou em parte, para a produção de todos os tipos de conhecimentos de Inteligência. De acordo com as peculiaridades de cada tipo, são observados determinados procedimentos preconizados pela metodologia. Cabe elucidar que os conhecimentos de inteligência, doutrinariamente, são: Informe, Informação, Avaliação e Estimativa.

Conforme previsto no Manual de Produção do Conhecimento (Brasil, 2019), a Metodologia de Produção do Conhecimento (MPC) contempla cinco fases distintas, a saber: planejamento, reunião, análise e síntese, interpretação e formulação e difusão, conforme ilustrado na Figura 1.

**Figura 1 - Metodologia de Produção do Conhecimento**



Fonte: Brasil (2019).

Amer (2022) *apud* Plum (2023) mapeou oito ações ou funcionalidades que os chatbots de LLM são capazes de desempenhar. Em síntese, esses robôs têm aptidão para resumir, gerar e reescrever textos, buscar palavras-chaves, classificar e agrupar

entidades, extrair informações específicas e traduzir idiomas.

Desse modo, infere-se que os supracitados chatbots, cujas funcionalidades foram apresentadas, podem ser de grande valia para o analista de Inteligência – principalmente nas fases iniciais do MPC – no planejamento e reunião. Assim, tem-se o primeiro caso de aplicação de *LLM* na Análise de Inteligência, que em síntese pode ser definido como a utilização das funcionalidades de um chatbot, para as tarefas iniciais de uma análise.

## 2.2 TÉCNICAS DE ANÁLISE ESTRUTURADA (TAE)

Segundo Beebe e Pherson (2015), as Técnicas de Análise Estruturadas (TAE) fornecem aos analistas de Inteligência uma variedade de ferramentas que podem mitigar seus desafios cognitivos e evitar falhas como percepção errônea, lapsos de memória e vieses. Porém, condicionado ao emprego da TAE mais adequada para o caso concreto, ou seja, saber qual, como e quando utilizar determinada ferramenta.

Em complemento, as supracitadas técnicas são eficazes para resgatar o analista de Inteligência do seu processo de pensamento intuitivo e do lugar comum. Assim, as TAE são capazes de levar esses profissionais a pensarem de maneira crítica e de forma distinta dos demais, visando gerar novas ideias, considerar alternativas incomuns e colaborar de maneira mais eficiente (Beebe e Pherson, 2015).

Dessa maneira, os chatbots de *LLM* podem trabalhar na geração de Técnicas de Análise Estruturadas, sendo um facilitador para as tarefas do analista de Inteligência. O Quadro 1 identifica as principais TAE atualmente em uso, extraídas do Manual de Produção do Conhecimento de Inteligência (Brasil, 2019). Foram elencadas, ainda, as TAE que podem ser confeccionadas pelos chatbots, de acordo com o princípio da simplicidade.

**Quadro 1 - Categorias e Técnicas de Análise Estruturada (TAE)**

CATEGORIA	TÉCNICA DE ANÁLISE ESTRURURADA (TAE)
Decomposição e Visualização	Cronologias e Linhas do Tempo
	Análise de Vínculos
	Mapas Mentais
	Planilha de Análise Padrão
Geração de Ideias	<i>Brainstorming</i> Estruturado
	<i>Starbursting</i>
Cenário e Indicadores	Cenários Simples
	Análise de Futuros Alternativos

	Indicadores
Geração e Avaliação de Hipóteses	Análise de Hipóteses Concorrentes (ACH)
	Detecção de Dissimulação
Avaliação de Causa e Efeito	Pensamento de Fora para Dentro ( <i>Outside-In Thinking</i> )
	Avaliação de Pressupostos-Chave
	Análise do Chapéu Vermelho ( <i>Red Hat Analysis</i> )
Análise de Desafios	Método Delphi
	Autocrítica Estruturada
	E se?
	Análise Pré-Mortem
	Advogado do Diabo
	Time Vermelho
Apoio à Decisão	Matriz <i>SWOT</i>

Fonte: Brasil, 2019.

Diante das técnicas do Quadro 1, elencou-se para confecção pelo chatbot aquelas mais simples e conhecidas pelos analistas, de maneira que os resultados alcançados possam ser facilmente avaliados pelo maior número de analistas. Com isso, as seguintes TAE foram elencadas como objeto de estudo:

- Cronologias e Linhas do Tempo;
- Mapas Mentais;
- *Brainstorming* estruturado; e
- *Starbursting*.

### 2.3 NÍVEIS DE ANÁLISE DE INTELIGÊNCIA

Segundo Clark (2022), a Análise Descritiva concentra-se na narrativa dos eventos presentes ou em curso. O analista assume a responsabilidade de discernir as ameaças e oportunidades associadas a um desafio atual enfrentado por um cliente, geralmente o decisor. Isso frequentemente envolve a consideração de diversos fatores, como os políticos, econômicos e psicossociais. No contexto das Forças Armadas, essa abordagem é denominada consciência situacional. Assim, o produto da Análise de Inteligência tem seu foco em responder o que aconteceu ou está acontecendo.

A Análise Diagnóstica é um tipo de análise que se concentra em entender e explicar eventos ou situações com base em evidências e dados disponíveis. Este tipo de Inteligência tem como objetivo identificar as causas subjacentes e os fatores que influenciam um determinado acontecimento, situação ou comportamento. A

inteligência diagnóstica é essencial para desvendar as motivações, intenções e capacidades de atores envolvidos, permitindo que analistas possam fornecer uma compreensão aprofundada e contextualizada dos eventos. Assim, a inteligência diagnóstica deve responder “por quê” determinado evento está ocorrendo, além de responder “o que se segue” – ou seja, o que pode ocorrer em consequência da situação apresentada. A análise diagnóstica deve seguir os aspectos levantados pela inteligência descritiva. Esses conhecimentos estão interligados e interdependentes.

A Análise Prospectiva também é denominada preditiva ou antecipatória, embora seja reconhecido que o futuro não pode ser precisamente previsto, dada a multiplicidade de possibilidades. O propósito do analista é identificar as alternativas mais plausíveis. Isso geralmente requer uma análise das forças ou fatores preponderantes que podem influenciar o curso futuro dos eventos. Essa abordagem envolve uma investigação detalhada e resulta na formulação de diversos cenários futuros potenciais. Devido ao uso das leis da probabilidade na produção desses produtos prospectivos, eles são categorizados como probabilísticos (Clark, 2022).

A Análise Prescritiva é aquela que aponta alternativas ou linhas de ação que o decisor poderá tomar, face ao conhecimento apresentado – diagnóstico ou prospectivo. Assim, a Inteligência Prescritiva representa um avanço em relação às abordagens descritivas ou antecipatórias, pois não apenas descreve ou prevê eventos, mas também recomenda opções para o decisor. Nas esferas de Inteligência Militar, como mencionado, os analistas não tinham autorização para fornecer esse tipo de aconselhamento, já que não estava dentro do escopo de suas funções. No entanto, há indícios de uma mudança doutrinária, à medida que os analistas de Inteligência e seus clientes colaboram mais estreitamente (Clark, 2022).

Com a apresentação dos níveis de Análise, tem-se a proposta mais complexa da aplicabilidade de *LLM* na Análise de Inteligência – que é a conjugação dos níveis de Análise com os tipos de conhecimento de Inteligência.

Assim, o chatbot baseado em *LLM* poderá analisar um alvo ou situação de forma completa, seguindo uma metodologia de produção do conhecimento – que será previamente configurada e refinada, apresentando um produto final, próximo ao que os analistas de inteligência são capazes de produzir.

Nesse caso, o nível de refinamento e configuração do chatbot deve ser detalhado e completo, assim como os comandos do usuário, para que a Inteligência

Artificial tenha todos os subsídios necessários para chegar mais próximo do produto esperado.

Diante disso, conclui-se parcialmente que a aplicação de modelos de *LLM* podem ser empregados em três categorias na produção do conhecimento, em distintos graus de complexidade, conforme o Quadro 2.

**Quadro 2 – Aplicabilidade de LLM na produção do conhecimento**

<b>Categoria</b>	<b>1. Funcionalidades de um Chatbot LLM</b>	<b>2. Técnicas de Análise Estruturada (TAE)</b>	<b>3. Conhecimento Intlg dentro dos níveis análise</b>	
<b>Produto ou Ação</b>	<ul style="list-style-type: none"> <li>- Resumir</li> <li>- Gerar</li> <li>- Reescrever</li> <li>- Buscar</li> <li>- Classificar</li> <li>- Agrupar</li> <li>- Extrair</li> <li>- Traduzir</li> </ul>	<ul style="list-style-type: none"> <li>- Cronologias e Linhas do Tempo</li> <li>- Mapas Mentais</li> <li>- Brainstorming</li> <li>- Starbursting</li> <li>- Matriz SWOT</li> </ul>	Produto	<ul style="list-style-type: none"> <li>- Informe</li> <li>- Informação</li> <li>- Apreciação</li> <li>- Estimativa</li> </ul>
			Nível de Análise	<ul style="list-style-type: none"> <li>- Descritiva</li> <li>- Diagnóstica</li> <li>- Prospectiva</li> <li>- Prescritiva</li> </ul>

Fonte: o autor.

### 3 SOLUÇÕES DE LLM

Neste capítulo, serão apresentadas as soluções de chatbots de *LLMs* disponíveis mais utilizadas, visando a proposta da solução mais adequada para apoio aos Analistas de Inteligência. Atualmente, existem inúmeros modelos de *LLM* em utilização. As soluções vão desde ferramentas proprietárias, acessíveis em versões *web*, como o ChatGPT-4o, da *OpenAI*, até aplicações de fonte aberta para instalação local ou infraestrutura em nuvem.

Para tanto, serão discutidas as possibilidades de desenvolvimento de modelos próprios de *LLM*; a utilização de modelos proprietários disponíveis; e a customização de modelos *open source* (código aberto), com a possibilidade de integração com base de dados própria. Cabe destacar que com a crescente preocupação com a segurança de dados e a integridade dos sistemas de Inteligência Artificial, torna-se condicionante explorar arquiteturas que maximizem a segurança sem comprometer a funcionalidade e eficiência dos dados e do próprio sistema.

#### 3.1 DESENVOLVIMENTO DE MODELOS PRÓPRIOS DE LLM

Modelos de Linguagem de Larga Escala, como o *GPT (Generative Pre-trained Transformer)* da *OpenAI*, requerem uma quantidade significativa de recursos computacionais para treinamento e desenvolvimento. Segundo Brown et al. (2020), o treinamento de um modelo como o GPT-3, por exemplo, envolve o uso de centenas de *GPUs*<sup>4</sup> especializadas durante semanas ou até meses, o que implica em custos operacionais extremamente altos.

Essa necessidade de *hardware* especializado, é uma barreira significativa. Esses recursos são necessários para processar os vastos conjuntos de dados e complexas redes neurais envolvidas, o que pode ser restritivo para muitas organizações.

Além disso, desenvolver um *LLM* próprio está fora do escopo e missão principal do SIEx, que poderia se beneficiar diretamente de aplicações prontas ou ajustes em

---

<sup>4</sup> *GPU* (do inglês *Graphic Processor Unit* - Unidade de Processamento Gráfico), também conhecida como placa de vídeo, é um circuito dedicado no interior de um computador ou dispositivo móvel, projetado para processar gráficos e imagens com alta velocidade e eficiência. As *GPUs* originalmente eram usadas para renderizar gráficos 3D em jogos e aplicativos multimídia, mas sua poderosa arquitetura paralela as tornou ideais para outras tarefas computacionais intensas, como processamento de linguagem natural (*PLN*) e aprendizado de máquina (*ML*).

modelos já existentes. Focar no desenvolvimento interno de tecnologias tão complexas poderia desviar recursos de outras áreas alinhadas às atividades fim.

Vanian (2023) aponta o rápido avanço da tecnologia de IA generativa, em especial os *Large Language Models*, citando o próprio ChatGPT. O referido autor destaca os altos custos envolvidos no desenvolvimento e operação de tais modelos. O treinamento de um *LLM* como o ChatGPT pode custar milhões de dólares, exigindo infraestrutura computacional robusta e expertise especializada.

Como exemplo, analistas e tecnólogos estimam que o processo de treinamento do ChatGPT-3, da *OpenAI*, pode ter custado mais de 4 milhões de dólares (Vanian, 2023). Esse custo não abrange a infraestrutura e atualização do modelo, cujos valores podem chegar facilmente a mais de 1 milhão de dólares por dia de operação.

Desse modo, o desenvolvimento de um modelo próprio de *LLM* para chatbot no contexto do SIEx é atualmente inviável devido às limitações técnicas (pessoal e material) e, principalmente, do ponto de vista financeiro. Alternativas como a customização e o *fine-tuning*<sup>5</sup> de modelos pré-existentes são recomendados para alcançar objetivos específicos de maneira eficiente e econômica.

### 3.2 MODELOS FECHADOS E/OU PROPRIETÁRIOS DE LICENÇAS RESTRITIVAS

Os modelos de linguagem de grande escala proprietários, como o ChatGPT-4o da *OpenAI*, Gemini da Google e Copilot da Microsoft, ilustram o estado da arte dos *Large Language Models*, genericamente denominados como Inteligência Artificial. Estes modelos, embora robustos, estão sujeitos a licenças restritivas que limitam a flexibilidade de uso e customização, trazendo desafios distintos, especialmente em contextos sensíveis como no presente trabalho.

Como ilustração de modelos proprietários, citam-se as principais em uso atualmente:

**ChatGPT-4o (*OpenAI*):** trata-se do modelo com mais de um trilhão de parâmetros<sup>6</sup>, proporcionando um desempenho excepcional em tarefas de processamento de

---

<sup>5</sup> *Fine-tuning* refere-se ao processo de ajustar um modelo de *LLM* pré-treinado para tarefas ou domínios específicos. Assim, para que o modelo desempenhe bem em tarefas específicas, ele precisa ser ajustado.

<sup>6</sup> Parâmetros em *LLMs* referem-se aos pesos e vieses nas redes neurais que constituem o modelo. Cada parâmetro é um valor numérico ajustado durante o treinamento do modelo para minimizar o erro entre as previsões e os resultados esperados. Quanto mais parâmetros, maior a capacidade do modelo gerar respostas mais complexas e coerentes.

linguagem natural. Desenvolvido nos EUA, o GPT-4o é amplamente reconhecido por sua capacidade de gerar textos coerentes e contextualmente relevantes em diversas aplicações, desde chatbots até criação de conteúdo.

**ChatGPT-3.5** (*OpenAI*): como predecessor do GPT-4, o GPT-3.5 ainda impressiona com suas capacidades robustas. Trata-se do modelo mais utilizado no mundo. Conta com 6 bilhões de parâmetros, ele é utilizado em uma variedade de aplicações que exigem compreensão e geração de texto de alta qualidade, oferecendo um equilíbrio entre desempenho e eficiência.

**Gemini Ultra e Pro** (Google): estes modelos representam um grande avanço no processamento de linguagem, com foco em diversas aplicações linguísticas. São modelos altamente versáteis, sendo capazes de adaptarem-se a diferentes contextos e tarefas, desde tradução até análise de sentimentos.

**CoPilot** (Microsoft): integrando-se com ferramentas de produtividade e desenvolvimento, CoPilot auxilia desenvolvedores ao sugerir códigos e completando tarefas automaticamente. Este modelo é especialmente útil em ambientes de programação, aumentando a eficiência e reduzindo o tempo de desenvolvimento.

**Bard** (Google): especializado em IA de conversação e buscas integradas, Bard é um *LLM* projetado para fornecer respostas precisas e relevantes em tempo real. É utilizado em motores de busca e assistentes virtuais, visando melhorar a experiência do usuário com interações mais naturais e informativas.

**Claude 3** (Anthropic e Amazon): desenvolvido com um foco especial em segurança e ética, esse modelo visa minimizar os riscos associados à IA, como vieses e mal-entendidos. Este modelo é projetado para fornecer respostas seguras e confiáveis. Não está disponível para o Brasil.

**Grok 1** (X, anteriormente parte do Google): este modelo é fruto dos esforços da *Alphabet* para criar soluções robustas de IA. Embora os detalhes sobre seu licenciamento sejam limitados, Grok 1 é conhecido por suas inovações em processamento de linguagem, oferecendo capacidades avançadas de compreensão e geração de texto.

**Olympus** (Amazon): parte do crescente portfólio de IA da Amazon, Olympus é projetado para aplicações de IA conversacional. Embora os detalhes sobre suas especificações sejam limitados, ele é utilizado em serviços de atendimento ao cliente

e assistentes virtuais, destacando-se por sua capacidade de interação natural com os usuários.

**PaLM 2** (DeepMind): Desenvolvido pela DeepMind, parte do conglomerado *Alphabet*, essa IA é focada em modelagem de linguagem preditiva. Este modelo é reconhecido por sua capacidade de prever sequências de texto com alta precisão, sendo utilizado em diversas aplicações que exigem entendimento profundo do contexto linguístico.

**Ernie 4** (Baidu): Este modelo desenvolvido na China se concentra na compreensão e geração de linguagem. Ernie 4 é projetado para lidar com múltiplos idiomas e contextos culturais, destacando-se em aplicações que exigem alta adaptabilidade linguística e precisão.

Pelos exemplos citados, infere-se uma popularização dos *LLM* disponíveis para diversas aplicações. Seguindo as leis de mercado, grande parte dessas soluções oferecem acesso gratuito, com possibilidade de aumento das funcionalidades nas versões pagas. Existe também a possibilidade de contratação empresarial de modelos fechados, porém com custos elevados, visando atender soluções corporativas com grandes demandas, como servidores de jogos *online*, por exemplo.

Assim, esses *LLM* de código proprietário, geralmente, são acessíveis somente através de *APIs*<sup>7</sup>, que não fornecem acesso direto aos parâmetros internos do modelo. Isso restringe de forma considerável as possibilidades de uso e personalização. Segundo Raji e Smart (2020), essa limitação impõe barreiras à inovação, pois os usuários não podem modificar os modelos para atender a necessidades específicas ou explorar plenamente seu potencial. Essa restrição é particularmente problemática em áreas onde a customização poderia levar a melhorias na segurança das aplicações.

A dependência de modelos *LLM* de terceiros também sugere preocupações sobre a governança e a segurança. Como Bostrom e Yudkowsky (2014) apontam, a utilização de infraestruturas de TIC de terceiros pode comprometer o controle sobre os dados sensíveis, uma questão inegociável na Análise de Inteligência. A integração de tecnologia externa em sistemas críticos pode expor organizações a riscos de vazamentos de dados ou acessos não autorizados. Assim, tudo que for pesquisado

---

<sup>7</sup> API (do inglês Application Programming Interfaces – Interface de aplicação de programação) são interfaces que permitem que diferentes softwares se comuniquem e interajam. No contexto de *LLMs* e chatbots, as *APIs* fornecem uma maneira fácil de acessar e usar os recursos de um *LLM* treinado, sem a necessidade de conhecimento técnico aprofundado sobre o modelo ou hardware subjacente.

na solução proprietária será de conhecimento dos detentores da ferramenta, comprometendo a segurança da informação.

Desse modo, é fundamental aumentar a conscientização sobre os riscos associados ao uso de chatbots de *LLM* de terceiros no contexto da Contraineligência, particularmente na Segurança da Informação.

Paralelamente aos aspectos de Segurança da Informação, O'Neil (2016) aponta que a falta de transparência nos modelos de IA pode levar a decisões automatizadas que não são facilmente auditáveis ou explicáveis, aumentando o risco de erros ou informações imprecisas. A autora se refere à inteligência artificial como uma caixa preta, onde somente quem programou sabe realmente que algoritmo está rodando.

Nesse sentido, Plum (2023) evidencia que os modelos de *LLM* podem gerar informações incorretas, derivando sobremaneira das respostas esperadas. Em sua investigação utilizando o ChatGPT 3, o autor aponta que:

Foi possível confirmar, portanto, que o *prompt* foi tratado de maneira equivocada pela IA. Essa é uma ocorrência extremamente relevante, que pode induzir o operador ao erro em diversas situações. Reforça-se, portanto, a ideia de sempre realizar a verificação daquilo que está sendo tratado pela IA (Plum, 2023, p. 31).

Por dedução, infere-se que tal fenômeno não é exclusividade de modelos proprietários. Assim, qualquer solução abordada nessa investigação poderá apresentar comportamento semelhante, em maior ou menor grau.

A adoção de modelos *LLM* proprietários, apesar de oferecer vantagens em termos de tecnologia de ponta, apresenta desafios significativos que precisam ser geridos. As restrições impostas pelas licenças, os riscos à segurança e a necessidade de conscientização sobre essas tecnologias exigem uma abordagem proativa, especialmente em contextos sensíveis como na Análise de Inteligência. É imperativo que o SIEx considere esses fatores ao integrar *LLMs* em seus sistemas, para garantir tanto a efetividade quanto a segurança dos seus processos.

### 3.3 CUSTOMIZAÇÃO DE MODELOS ABERTOS (*OPEN SOURCE*)

A adoção de Modelos de Linguagem de Grande Escala *open source* está ganhando terreno, principalmente devido à flexibilidade que oferecem para customização e integração. Modelos como Llama da Meta, Alpaca, Vicuña, e Mistral são exemplos proeminentes de *LLMs* que são disponibilizados sob licenças de código

aberto, permitindo expressivas modificações e adaptações às necessidades específicas dos usuários. Esses modelos são frequentemente desenvolvidos por consórcios que envolvem colaborações entre instituições acadêmicas e empresas, refletindo uma tendência crescente na democratização do acesso à tecnologia de ponta em Inteligência Artificial (Wolf et al., 2020).

Da mesma forma, o Falcon 7B, desenvolvido por uma colaboração internacional de pesquisadores, busca oferecer um modelo de linguagem adaptável a contextos culturais específicos, um avanço significativo para a aplicação global de IA.

Em resumo, as principais soluções *LLM* de código aberto tem características de interesse para a Análise de Inteligência, como se comprova a seguir:

**Llama 2 (Meta):** este modelo é conhecido por sua adaptação flexível e capacidade de customização, possuindo até 175 bilhões de parâmetros. Desenvolvido nos EUA, Llama 2 é amplamente utilizado em aplicações que exigem ajustes específicos para diferentes necessidades, proporcionando alto desempenho em diversas tarefas de processamento de linguagem natural.

**Llama 3 (Meta):** com versões de 8 e 70 bilhões de parâmetros, Llama 3 destaca-se pela sua capacidade de aprendizado contínuo e adaptação a novos dados. Desenvolvido nos EUA, este modelo é ideal para ambientes dinâmicos onde a atualização constante e a melhoria contínua são essenciais para manter a relevância e a precisão, necessitando de menos requisitos computacionais para sua operação.

**Alpaca (Stanford):** adaptado para diversas aplicações de linguagem natural, possui 7 bilhões de parâmetros e é desenvolvido nos EUA. Este modelo é reconhecido pela sua versatilidade e eficiência, sendo utilizado em uma ampla gama de contextos, desde chatbots até análise de texto.

**Vicuña (EleutherAI):** com 13 bilhões de parâmetros, é altamente customizável para diferentes contextos e linguagens. Desenvolvido nos EUA, este modelo permite ajustes específicos para maximizar o desempenho em tarefas variadas, oferecendo flexibilidade e precisão em suas aplicações.

**Mistral (HuggingFace):** focado em baixa latência e eficiência computacional, Mistral possui 7 bilhões de parâmetros. Desenvolvido nos EUA, este modelo é ideal para aplicações que exigem respostas rápidas e processamento eficiente, sendo amplamente utilizado em ambientes com recursos computacionais limitados.

**Falcon 7B (TII):** Adaptável a contextos culturais específicos e multilinguagem, Falcon 7B possui 7 bilhões de parâmetros. Desenvolvido nos Emirados Árabes, este modelo é conhecido por sua capacidade de lidar com diferentes idiomas e nuances culturais, tornando-se uma escolha popular para aplicações globais.

Nota-se uma considerável variedade de aplicações disponíveis para viabilizar soluções locais. A capacidade de customizar esses modelos não se limita apenas à adaptação de suas capacidades linguísticas ou ao treinamento com banco de dados específicos, mas também à integração com sistemas existentes de maneira segura e eficiente. Modelos como Alpaca e Vicuña, oferecem *frameworks* que podem ser ajustados para melhorar a interação usuário-máquina, como atendimento ao cliente ou análises de dados de inteligência.

Dessa forma, especificamente para o SIEEx, torna-se atrativo focar em modelos *open source*, pela flexibilidade que oferecem em termos de adaptação e integração segura em sistemas existentes. Soma-se a isso o custo reduzido para se adotar modelos de código aberto, uma vez que o investimento será praticamente da infraestrutura, considerando que a implementação da LLM propriamente dita, bem como suas atualizações, não terão custos diretos.

No presente trabalho, a motivação para utilização de soluções locais é a confidencialidade dos dados, uma vez que o banco de dados e as consultas não ficariam na nuvem de terceiros. Soma-se a isso, o controle de vieses existentes em *LLM* treinados em ambientes não controlados – uma vez que o chatbot de código fechado geralmente “aprendeu” com um banco de dados que não se tem acesso.

Ademais, é salutar mencionar que a segurança da informação no emprego de Chatbots de *LLM* exigem implementações como técnicas de criptografia de dados em repouso e em trânsito, autenticação e autorização robusta dos usuários e compartimentação de dados sensíveis. Além disso, protocolos para a detecção e resposta a incidentes de segurança.

### 3.4 TÉCNICAS DE CUSTOMIZAÇÃO E INTEGRAÇÃO DE *LLM* EM BASES DE DADOS LEGADAS DO SIEEX

Além de elencar um modelo *LLM* compatível com o projeto em estudo, cabe ressaltar que esse modelo deverá interagir com um banco de dados preexistente, possibilitando que a Inteligência Artificial gere conhecimento de um repositório

confiável. Para tanto, são necessárias técnicas de customização e integração, que tem papel tão relevante quanto o modelo de *LLM* propriamente dito.

Uma técnica significativa nesse contexto é a Geração Aumentada de Recuperação (*Retrieval-Augmented Generation - RAG*). Essa técnica combina a geração de texto baseada em modelos de linguagem com um sistema de recuperação de informações, permitindo ao modelo consultar um conjunto de dados ou uma base de conhecimento durante o processo de geração de resposta. Isso melhora a precisão e a relevância das respostas geradas ao permitir que o modelo de linguagem acesse informações específicas e contextuais no momento da geração de texto (Lewis et al., 2020).

A principal vantagem do uso de *RAG* é que ela não requer treinamento adicional ou recursos computacionais elevados. Isso é particularmente vantajoso para o SIEx, pois permite a integração de modelos de *LLM* com bases de dados legadas, adaptando o modelo para responder de acordo com as especificidades e requisitos do ambiente de Inteligência.

Essa abordagem destaca a importância da interface com o banco de dados. Não se trata de “ensinar” mais parâmetros para a IA (*LLM*), mas sim permitir que a aplicação acesse um repositório onde estão os conteúdos a serem analisados. Isso facilita a manutenção da confidencialidade e a segurança dos dados manipulados, já que o ajuste pode ser realizado internamente, com controle total sobre os dados e processos.

Portanto, a técnica de *RAG* mostra-se adequada para a customização e integração eficaz de *LLMs* em ambientes com requisitos específicos, como os encontrados no SIEx. Essas técnicas não apenas melhoram a funcionalidade dos chatbots ao permitir que eles respondam de maneira mais completa e adaptada, mas também facilitam a integração com as bases de dados legadas do SIEx.

O *LoRA Fine Tuning (Low-Rank Adaptation)* é outra técnica de customização amplamente utilizada para *LLMs*, particularmente útil na adaptação de modelos pré-treinados para tarefas específicas, com um custo computacional relativamente baixo. Hu et al. (2021) introduziram essa abordagem, que consiste em ajustar apenas uma pequena fração dos parâmetros do modelo através da adição de matrizes de baixo posto. Esta técnica permite modificações consideráveis na funcionalidade do modelo

sem a necessidade de reajustar todos os seus parâmetros, facilitando uma customização eficiente e menos onerosa.

No contexto dos chatbots de *LLM*, o *LoRA Fine Tuning* oferece a vantagem de permitir uma adaptação rápida do modelo a novos contextos ou bases de dados sem a necessidade de extensos períodos de treinamento ou recursos computacionais elevados. Assim, permite a integração de modelos de *LLM* com bases de dados legadas, adaptando o modelo para responder de acordo com as especificidades e requisitos do ambiente de inteligência. Além disso, a flexibilidade do *LoRA* facilita a manutenção da confidencialidade e a segurança dos dados manipulados, pois independe de fatores externos, com controle total sobre os dados e processos.

Tanto a técnica de *RAG* quanto o *LoRA Fine Tuning* são adequações necessárias para a customização e integração eficaz de *LLMs* em ambientes com requisitos específicos. Essas técnicas não apenas melhoram a funcionalidade dos chatbots ao permitir que eles respondam de maneira mais completa e adaptada, mas também oferecem uma abordagem prática para a integração com sistemas legados, mantendo a segurança e a integridade dos dados na Análise de Inteligência.

## 4 PROPOSTA DE CHATBOT PARA ANÁLISE DE INTELIGÊNCIA

Neste capítulo, será apresentada uma proposta para a implementação de um chatbot para Análise de Inteligência, considerando as discussões anteriores sobre as características dos chatbots e os requisitos específicos para essa atividade.

Pelo exposto no capítulo anterior, é recomendável, especificamente para o SIEx, focar em modelos *open source*. Tal assertiva se justifica pela segurança que esses modelos oferecem, atendendo de maneira satisfatória os requisitos macros de segurança da informação – solução local, com gestão e operação do sistema no modo *on-premise*<sup>8</sup>.

Além disso, cabe destacar outra justificativa fundamental, que são os custos envolvidos. Modelos de código fonte aberto tem um custo consideravelmente inferior às outras soluções, concentrando as aplicações de recursos basicamente na infraestrutura ou sua adaptação.

Assim, pela flexibilidade que oferecem em termos de segurança, custos e adaptação, infere-se que o caminho a ser percorrido passa pelos modelos de fonte aberta.

Dentre tais modelos, o Llama 3 se destaca por sua capacidade de processar e gerar linguagem natural com alta precisão, o que é fundamental para o entendimento de contextos complexos e a geração de *insights* detalhados a partir de grandes volumes de dados, como por exemplo, a geração de Técnicas de Análise Estruturadas.

Esse modelo possui versões com 8 e 70 bilhões de parâmetros, o que implica em uma posição intermediária em comparações com outros modelos. Dessa forma, o Llama 3 apresenta um desempenho satisfatório, sem necessitar de elevados requisitos computacionais.

Diferente de modelos mais restritos, esse modelo oferece flexibilidade e uma capacidade extensiva de treinamento específico, o que permite sua customização para atender às necessidades peculiares do Sistema de Inteligência do Exército e se integrar como uma ferramenta de apoio à Análise de Inteligência.

---

<sup>8</sup> o termo “*on-premise*” se refere à prática de hospedar softwares, servidores e sistemas de TI localmente, dentro das instalações físicas de uma organização. Diferentemente dos sistemas hospedados na nuvem, as soluções *on-premise* são instaladas, operadas e gerenciadas diretamente nas instalações corporativas

Pelo estudo apresentado no Capítulo 3, o *LLM* Mistral também atenderia em boas condições, pelas suas características técnicas. Entretanto, o desenvolvedor do modelo também foi considerado como fator de escolha. Como o Llama é desenvolvido pela gigante Meta, sugere-se uma continuidade nos investimentos em Inteligência Artificial e constantes atualizações no modelo.

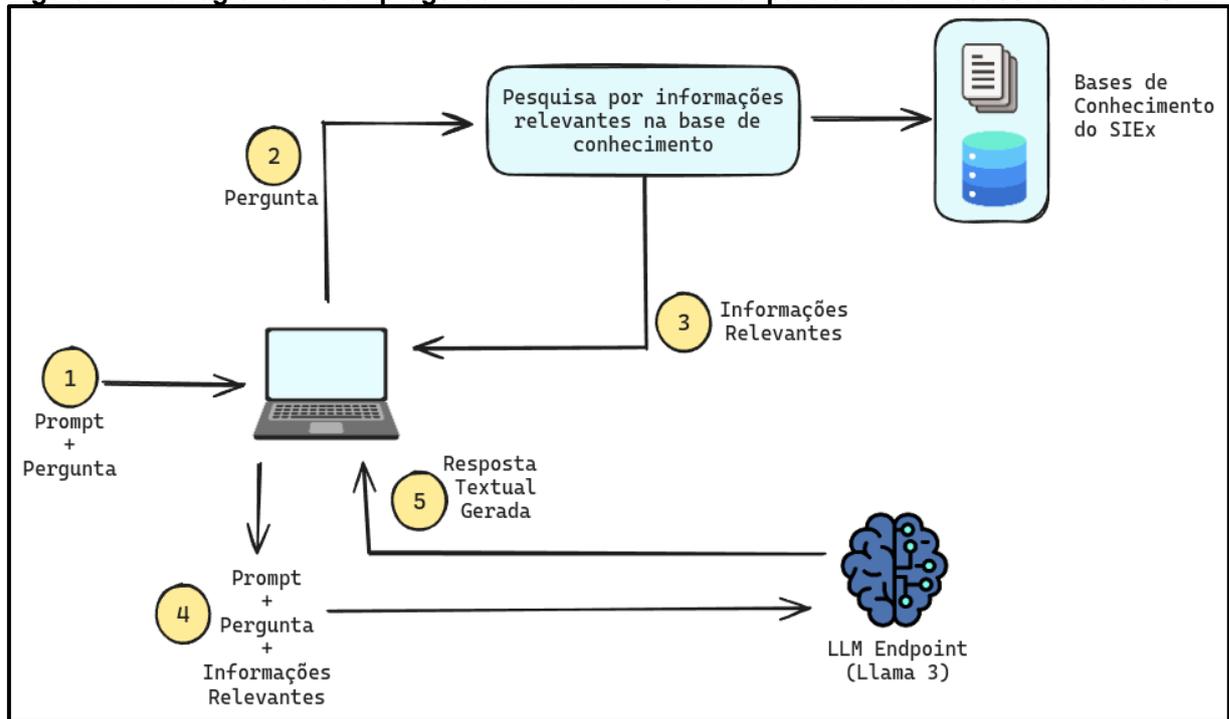
Com isso, o modelo mais adequado para o emprego em Análise de Inteligência proposto pela presente investigação acadêmica é o Llama 3.

Ademais, conclui-se, ainda de maneira parcial, que a customização deve abarcar a técnica *RAG*, pois oferece a vantagem de fornecer respostas mais precisas e atualizadas, especialmente em tarefas intensivas em conhecimento, além de integrar-se facilmente com bases de conhecimento existentes e lidar com informações dinâmicas (Borek, 2023).

Dessa forma, os dados, conhecimentos e produtos já armazenados em dispositivos preexistentes poderão ser acessados e interpretados pelo chatbot de *LLM*, gerando respostas alinhadas com o contexto do Sistema de Inteligência do Exército.

Em consequência, baseado no Llama 3, com customização *RAG*, chega-se a um sistema cujo fluxo é representado pela Figura 2. Após a pergunta ou interação (*prompt*) do usuário – representada pelo Passo 1, ocorre a pesquisa por informações relevantes no banco de dados do SIEx (Passo 2). As informações relevantes são agrupadas (Passo 3) e confrontadas com o modelo Llama 3 (Passo 4), que fornece mais informações dos seus próprios parâmetros, para finalmente gerar uma resposta para o usuário (Passo 5).

Figura 2 – Fluxograma do emprego do LLM em um Chatbot para atender necessidades do SIEx



Fonte: o autor.

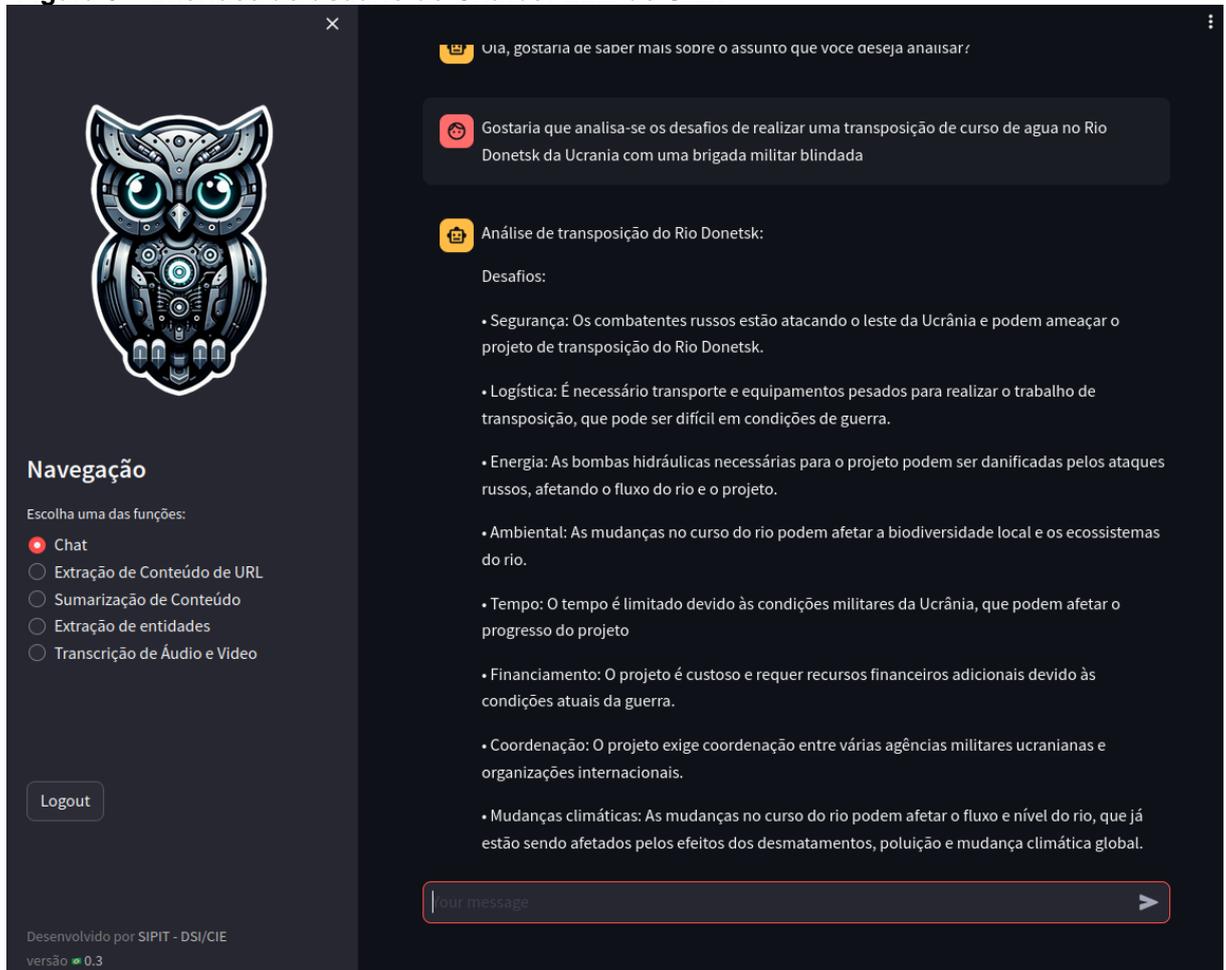
#### 4.1 IMPLEMENTAÇÃO DO CHATBOT DE LLM

A implementação do chatbot de LLM para Análise de Inteligência envolve várias fases, começando pela integração de dados de Inteligência até o desenvolvimento de interfaces específicas para os analistas. Esta seção apresenta exemplo de etapas, desde a coleta de dados até a interface de usuário final, garantindo que todas as operações respeitem as normas de segurança e privacidade, dentro do contexto da Contraineligência.

- 1. Coleta e Preparação de Dados:** Conforme discutido no Capítulo 3, a integridade e a segurança dos fatores são primordiais. O chatbot será alimentado com dados provenientes de fontes confiáveis e do próprio banco de dados do SIEx, garantindo que a análise esteja livre de vieses e erros.
- 2. Treinamento do Modelo:** O Llama 3 será treinado com dados específicos de Inteligência, utilizando técnicas de aprendizado supervisionado e transferência de aprendizado para garantir que o modelo esteja bem ajustado às tarefas de análise específicas do SIEx.
- 3. Desenvolvimento da Interface de Usuário:** A interface será projetada para ser intuitiva para os analistas, facilitando a interação com o chatbot e permitindo que comandos complexos sejam executados de maneira simples e eficiente. Além disso,

tal customização também visa especificar funcionalidades mais utilizadas, como descrito no Capítulo 2. Tarefas como sumarização, tradução ou a confecção de uma Técnica de Análise Estruturada poderão ser implementadas como atalhos dessa interface, conforme Figura 3.

**Figura 3 – Interface do usuário do Chatbot LLM do SIEx**



Fonte: Subseção de Desenvolvimento, Divisão de Suporte à Inteligência, Centro de Inteligência do Exército, 2024.

4. **Testes e Validação:** o chatbot passará por uma série de testes para garantir sua precisão e eficácia. Avaliações contínuas também serão implementadas para adaptar e melhorar o sistema com base no *feedback* dos analistas. Cabe destacar a importância da participação de especialistas experientes e não especialistas, possibilitando avaliar o conteúdo e a funcionalidade da solução.

Devem ser considerados os aspectos éticos e de segurança na implementação de tecnologias de IA, especialmente no contexto de Análise de Inteligência. As políticas de uso do chatbot serão claramente definidas para evitar qualquer forma de

abuso ou má utilização da tecnologia, garantindo que todas as operações estejam em conformidade com a legislação vigente.

#### 4.2 EMPREGO E EXPERIMENTO DO CHATBOT DE *LLM* PARA ANÁLISE DE INTELIGÊNCIA

No experimento comparativo, testou-se o Llama 3 com a técnica *RAG*, tendo seu desempenho avaliado por metodologia específica e comparado com o desempenho de uma solução amplamente utilizada – o ChatGPT 4o. Tal comparação visa verificar se a solução proposta de *LLM* tem capacidade de gerar respostas coerentes.

A metodologia da avaliação utilizou as métricas conforme o Quadro 3. A avaliação se valeu de metodologia cujas métricas variaram em uma escala de 1 à 5, referentes a: Insuficiente, Regular, Bom, Muito Bom, Excelente – respectivamente. Também foi utilizado a convenção (+) e (-) quando se refere a uma métrica de resultado binário.

**Quadro 3 – Metodologia de avaliação**

<b>Métrica</b>	<b>Descrição</b>
Precisão e Acurácia	Medir a exatidão das respostas fornecidas pelo <i>LLM</i> em comparação com respostas corretas ou esperadas.
Compreensão Contextual	Avaliar a capacidade do modelo de entender e manter contexto em conversas ou textos longos.
Velocidade de Resposta	Avaliar o tempo necessário para o modelo processar a entrada e gerar uma resposta.
Cobertura de Conhecimento	Medir a extensão do conhecimento do modelo e a frequência de suas atualizações para incluir novos dados e eventos.
Governança da Informação	Capacidade dos dados compartilhados com modelo se manterem dentro da organização.

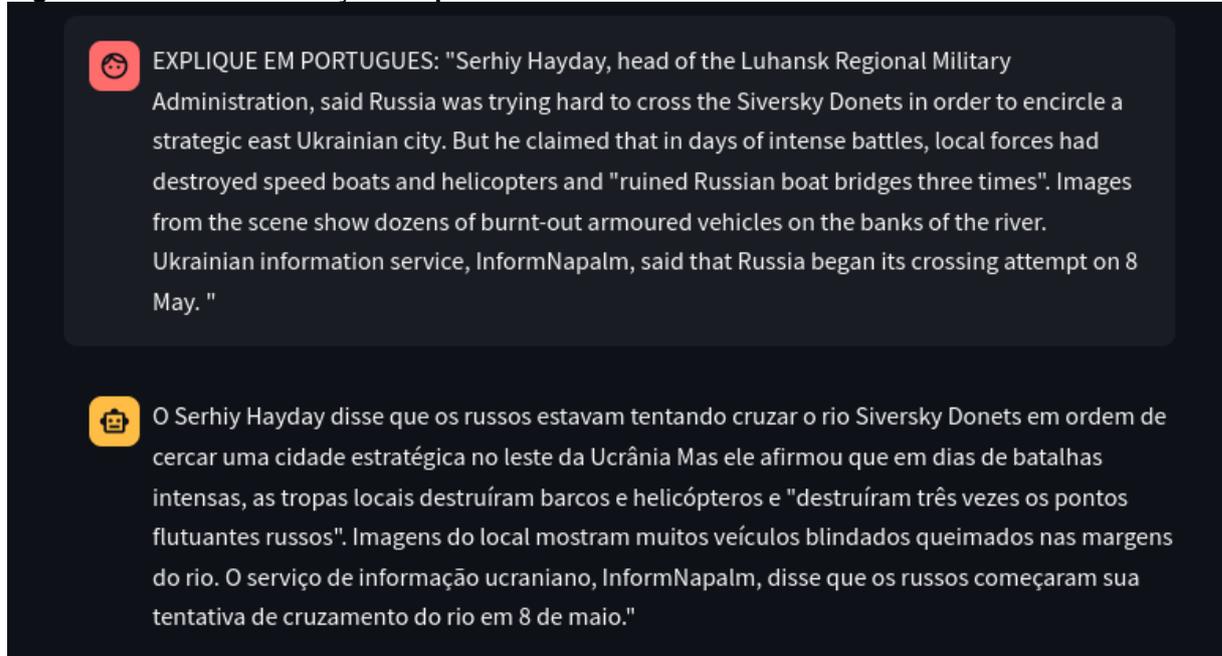
Fonte: o autor.

A partir da matéria “*Bloody river battle was third in three days - Ukraine official*” da BBC (Williams e Pona, 2022), disponível em < <https://www.bbc.com/news/world-europe-61399440>> foram executados os Experimentos 1 e 2:

**Experimento 1: Empregar as Funcionalidades de um Chatbot de *LLM***, que representa a Categoria 1 das aplicabilidades de *LLM* na Metodologia de Produção de Conhecimento (fases de Planejamento e Reunião), conforme definido no Capítulo 2.

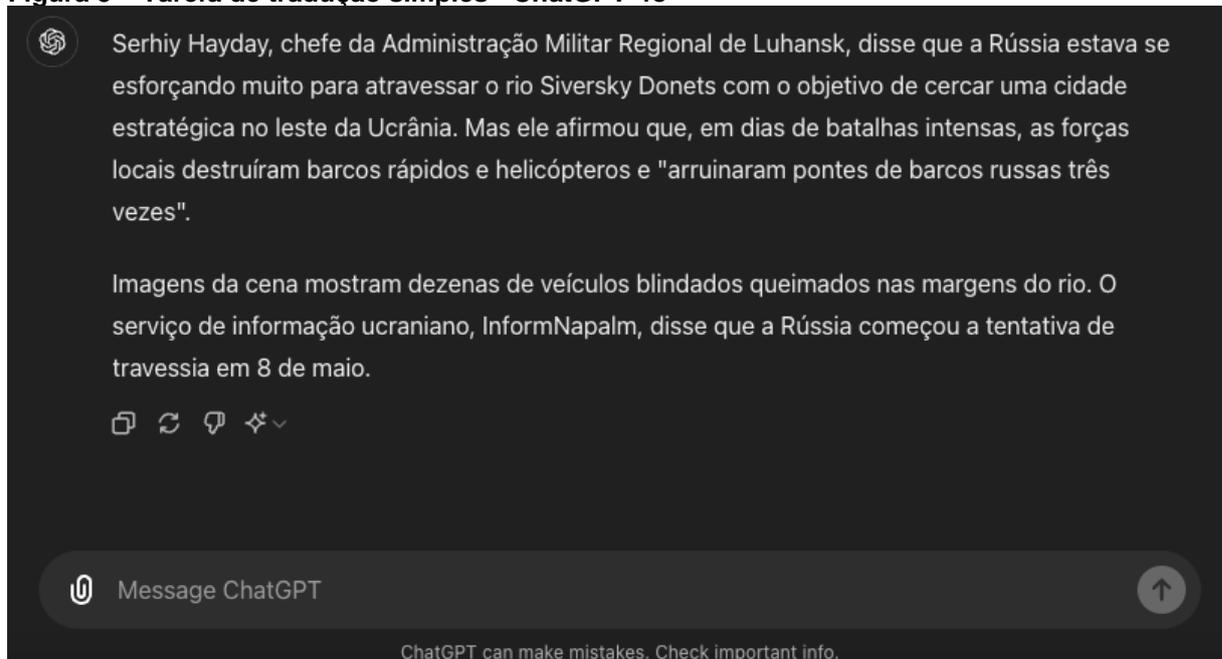
Assim, inicialmente foi solicitado para os chatbots traduzirem um fragmento do texto em estudo, tendo os resultados apresentados nas Figura 4 (Llama 3) e Figura 5 (ChatGPT 4o).

**Figura 4 – Tarefa de tradução simples - Llama 3**



Fonte: o autor.

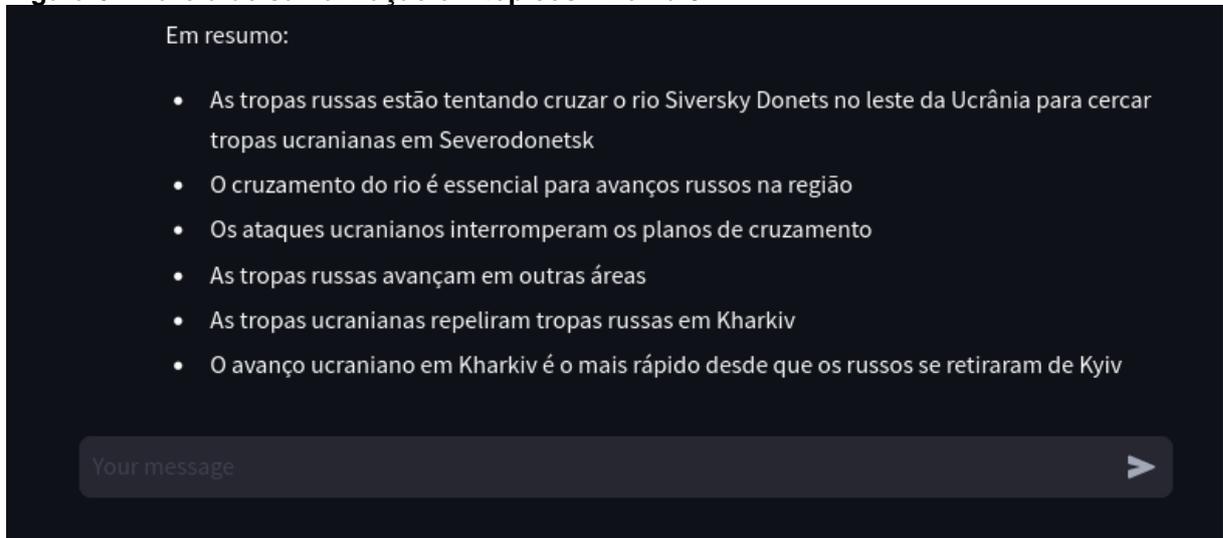
**Figura 5 – Tarefa de tradução simples - ChatGPT-4o**



Fonte: o autor.

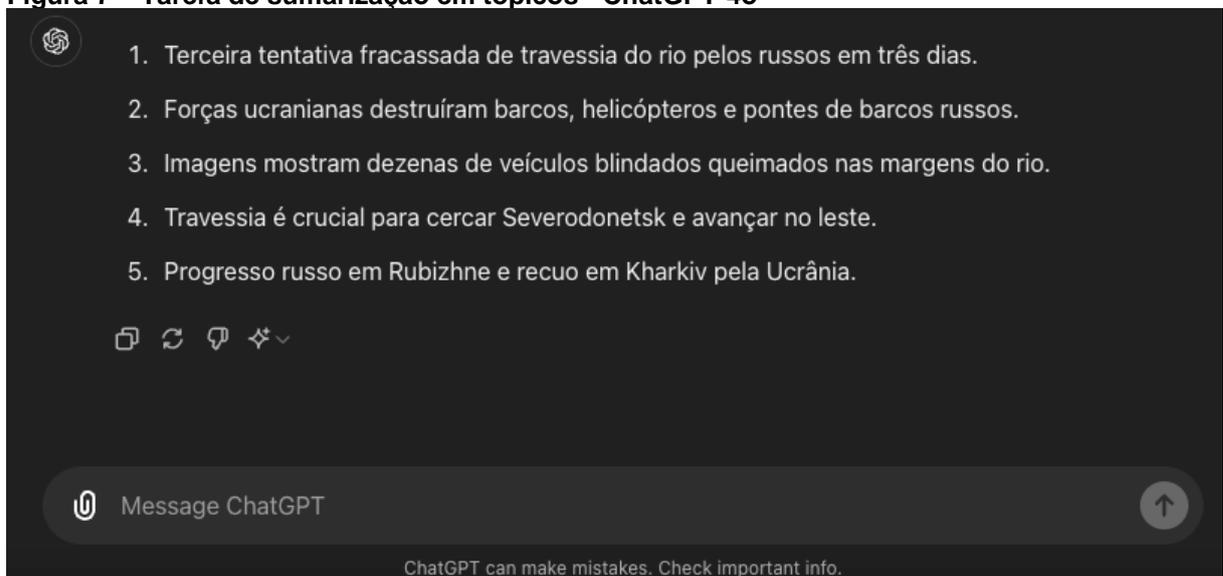
Posteriormente, foi solicitado uma sumarização da matéria, tendo os resultados apresentados nas Figura 6 (Llama 3) e Figura 7 (ChatGPT 4o).

**Figura 6 – Tarefa de sumarização em tópicos - Llama 3**



Fonte: o autor.

**Figura 7 – Tarefa de sumarização em tópicos - ChatGPT-4o**



Fonte: o autor.

Infere-se que ambos chatbots apresentaram outputs coerentes. Na tradução, ambas soluções apresentaram resultados semelhantes, com variações aceitáveis. Entretanto, na sumarização percebe-se uma ligeira superioridade na precisão e acurácia do ChatGPT 4o, que em dois tópicos conseguiu sintetizar a matéria – relatando que era a terceira tentativa dos russos de cruzarem o rio *Siversky Donets*,

mas que os ucranianos destruíram uma quantidade expressiva de meios inimigos, frustrando mais uma vez a transposição de curso d'água russa.

Assim, o ChatGPT obteve vantagem na avaliação das métricas no Experimento 1, conforme descrito no Quadro 4:

**Quadro 4 – Resultados do Experimento 1**

<b>Métrica</b>	<b>Llama 3</b>	<b>ChatGPT 4o</b>
Precisão e Acurácia	4	5
Compreensão Contextual	5	5
Velocidade de Resposta	5	4
Cobertura de Conhecimento	4	5
Governança da Informação	+	-

Fonte: o autor.

**Experimento 2: Empregar Técnicas de Análise Estruturada (TAE)**, que representa a Categoria 2 das aplicabilidades de *LLM* na Metodologia de Produção de Conhecimento, conforme definido no Capítulo 2. Esse experimento teve como objetivo realizar a decomposição e visualização do contexto apresentado, com a TAE Cronologia e Linha do Tempo. Os resultados obtidos foram condensados no Quadro 5.

Figura 8 – Cronologia e Linha do Tempo - Llama 3

 crie uma linha do tempo com os eventos que podem ser considerados o stopim da daguerra entre ukrania e russia iniciada em fevereiro de 2022. Coloque a resposta em topicos por data.

 • 2014: Crimeia é anexado pela Rússia após referendo disputado. O presidente ucraniano Viktor Yanukovich fugiu do poder após protestos em Kiev que resultaram em centenas de mortes. O governo interino ucraniano se afasta da Rússia, levando à guerra civil no leste do país.

• 2019: Volodymyr Zelenskyy vence as eleições presidenciais como candidato independente e promete acabar com a guerra em Donbas.

• 2021: Zelenskyy e Putin se encontram em Genebra e discutem a crise em Donbas. Putin exige que Zelenskyy aceite um tratado que reconheceria os territórios ocupados como independentes.

• Fevereiro 2022: Putin ordena invasão da Ucrânia após negociações frustradas entre Zelenskyy e o líder russo. O exército russo invade a Ucrânia por toda fronteira, provocando a maior guerra europeia desde o fim da Segunda Guerra Mundial.

Por sua vez, sintetize em 3 sentenças:

• Um conjunto de eventos diplomáticos fracassados levaram à invasão russa da Ucrânia em fevereiro de 2022 após anos de tensão entre os dois países desde 2014.

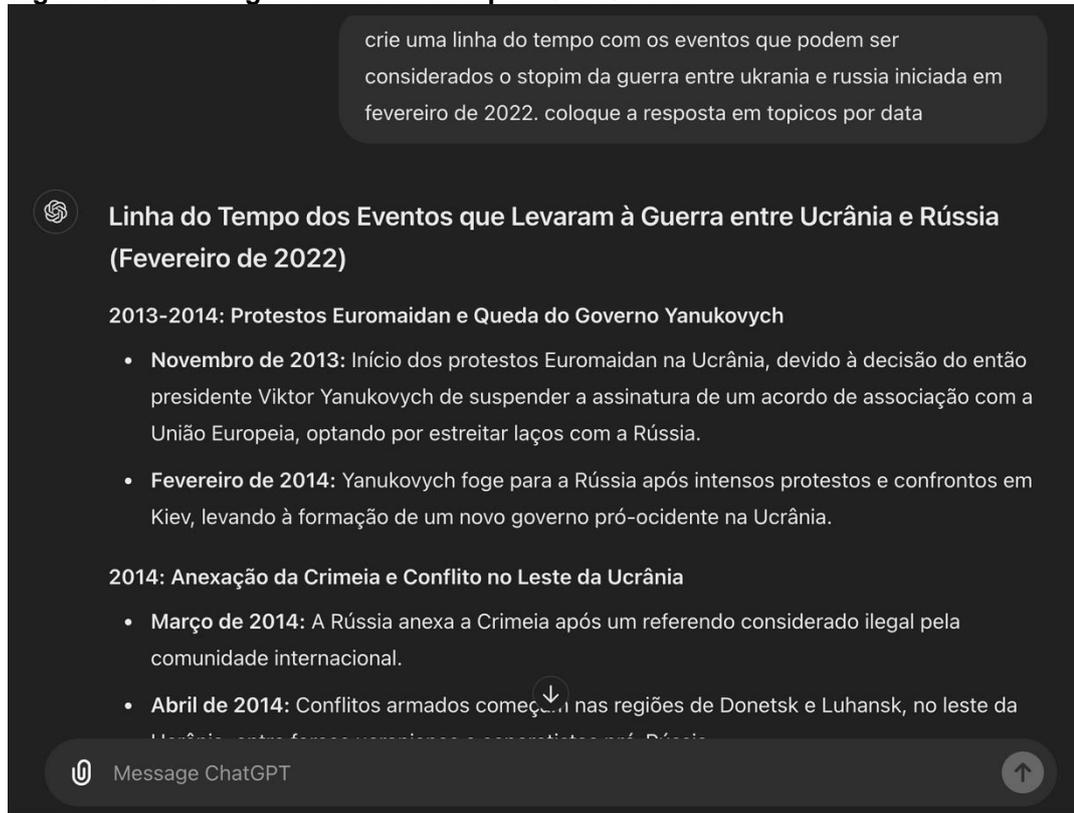
• O conflito começou em 2014 após a anexação russa da Crimeia após uma disputada referendo que levou à guerra civil no leste ucraniano.

• Em fevereiro de 2022, o presidente Putin invadiu a Ucrânia após negociações frustradas sobre a Crimeia e os territórios ocupados no leste da Ucrânia desde 2014.

Your message 

Fonte: o autor.

**Figura 9 – Cronologia e Linha do Tempo - ChatGPT 4o**



Fonte: o autor.

**Quadro 5 – Resultados do Experimento 2**

Métrica	Solução IA SIEx	ChatGPT 4o
Precisão e Acurácia	4	5
Compreensão Contextual	4	4
Velocidade de Resposta	5	4
Cobertura de Conhecimento	3	5
Governança da Informação	+	-

Fonte: o autor.

**Experimento 3: Produzir Conhecimento de Inteligência dentro dos níveis Análise.** Esse experimento visava produzir uma Apreciação até o nível da Análise Prescritiva, com base na temática da Terra Indígena Yanomami, sem disponibilizar material de apoio para os chatbots. Assim, o ChatGPT notoriamente teve vantagem pois tem consulta à diversas fontes na internet. Os produtos se encontram nos apêndices deste trabalho. O ChatGPT-4o apresentou melhor desempenho geral, mas o Llama 3 respondeu de forma satisfatória. Os resultados obtidos foram condensados no Quadro 6, e os produtos gerados, nos Apêndices A e B.

**Quadro 6 – Resultados do Experimento 3**

<b>Métrica</b>	<b>Solução IA SIEx</b>	<b>ChatGPT 4o</b>
Precisão e Acurácia	3	4
Compreensão Contextual	3	4
Velocidade de Resposta	5	4
Cobertura de Conhecimento	5	5
Governança da Informação	+	-

Fonte: o autor.

Considerando os experimentos realizados, conclui-se parcialmente que o modelo Llama 3 gerou respostas coerentes, tendo sua avaliação satisfatória segundo a metodologia apresentada. Em comparação com o ChatGPT 4o, nota-se uma vantagem deste sobre a solução local, facilmente justificada pelo nível de maturação e emprego do Chatbot da *OpenAI*.

## 5 CONCLUSÃO

O presente trabalho investigou como o emprego de chatbots baseados em Modelos de Linguagem de Grande Escala pode contribuir com a Análise de Inteligência.

Desta forma, ao final desta investigação, verifica-se a pertinência da realização de estudos visando encontrar soluções para o emprego de chatbots de *LLM* para apoiar os analistas de Inteligência do Sistema de Inteligência do Exército.

Na introdução, a pesquisa destacou o desafio crescente enfrentado pelos analistas de Inteligência, devido ao aumento exponencial de informações disponíveis. A capacidade de processar grandes volumes de dados de maneira eficiente é condição básica para fornecer uma análise coerente, que atenda as demandas do decisor. Aliada a essa problemática, tem-se ainda a escassez de tempo – em que o analista se encontra com uma curta janela temporal para realizar seu trabalho e entregar resultados.

Nesse contexto, a utilização de soluções tecnológicas seguras, como chatbots baseados em *LLMs*, foi colocado como uma hipótese promissora. Esses modelos de inteligência artificial são treinados em grandes conjuntos de dados textuais, permitindo a compreensão e produção de texto avançado, traduzindo idiomas, respondendo perguntas e analisando sentimentos.

Para evidenciar a aplicabilidade desse tipo de Inteligência Artificial na Análise de Inteligência, no Capítulo 2 foram abordadas as etapas do processo de produção do conhecimento e como os chatbots de *LLM* poderiam produzir informações úteis para os analistas. Assim, chegou-se a três categorias de uso dos modelos: para apoio inicial, com as funcionalidades próprias de um *LLM*; para geração de Técnicas de Análise Estruturadas (TAE); e, finalmente, para análises mais complexas, com a combinação de tipos de conhecimento com os níveis de análise.

Na sequência, o Capítulo 3 discorreu sobre as alternativas de *LLM* que poderiam ser implementadas para solucionar o presente estudo acadêmico. Foram discutidas as possibilidades de desenvolvimento de *LLM* próprio; utilização de modelos proprietários; e o emprego de *LLM* de fonte aberta.

No Capítulo 4, chegou-se à resposta do problema: a proposta de implementação de um chatbot de *LLM* de código aberto, especificamente o Llama 3 da Meta. A solução apontada destaca que o uso de modelos de fonte aberta oferece

uma solução economicamente viável e segura (no tocante à governança dos dados), permitindo que o banco de dados e as consultas permaneçam sob controle da própria organização. A flexibilidade e a capacidade de adaptação do Llama 3 foram enfatizadas como fatores para sua escolha, considerando também o suporte contínuo e as atualizações frequentes oferecidas pela Meta.

Assim, pelo resultado dos testes, o modelo Llama 3 se demonstrou eficiente com relação à metodologia apresentada e, também, em comparação com o ChatGPT 4o. Com isso, confirma-se a hipótese apresentada, validando que o emprego de chatbots seguros baseados em *LLM* pode aperfeiçoar a Análise de Inteligência no âmbito do Exército Brasileiro.

Pela abrangência do tema, é notório que este estudo não esgotou o assunto. Somam-se a isso a efervescente evolução das IA e a relevância do tema para atividade de Inteligência. Assim, recomenda-se trabalhos futuros nas seguintes vertentes:

- a. *LLM* para produção específica de Técnicas de Análises Estruturadas;
- b. Utilização de *LLM* proprietárias, como ChatGPT 4o e Gemini, na Análise de Inteligência;
- c. *LLM* de fonte aberta para o SIEx – estudo de diferentes opções;
- d. Uso de IA para obtenção do conhecimento, para automatização dos processos nas distintas fontes – ou ainda, estudar por tipo de Fonte de Inteligência;

Além das recomendações acadêmicas, sugere-se também a implementação e testes da solução apresentada, buscando validar os resultados obtidos no presente trabalho acadêmico.

Por fim, conclui-se que o este Trabalho de Conclusão de Curso cumpriu os objetivos estabelecidos em seu escopo, uma vez que a proposta de implementação de um chatbot de *LLM*, especificamente o Llama 3, caso implementado - representará um avanço para a Análise de Inteligência do SIEx, tendo potencial de aumentar a eficiência e precisão das análises, observando-se os requisitos de segurança da informação e, conseqüentemente, otimizando o escasso tempo dos profissionais de Inteligência.

## REFERÊNCIAS

AMER, M. **Large Language Models and where to use them**. 2022. Disponível em: <https://txt.cohere.com/llm-use-cases/>. Acesso em: 14 de maio de 2024.

BOREK, Cecylia. **Comparative evaluation of LLM-Based approaches to Chatbot creation: Implementing a Death Doula Chatbot**. Master's Thesis - Faculty of Information Technology and Communication Sciences, Tampere University, 2023.

BRASIL. Gabinete de Segurança Institucional da Presidência da República. **Estratégia Nacional de Inteligência**. Brasília, 2017. 40 f. Disponível em: <https://acesso.gov.br/>. Acesso em: 15 maio de 2024.

BRASIL. Ministério da Defesa. Exército Brasileiro. Comando de Operações Terrestres. **Produção do Conhecimento de Inteligência - EB70-MT-10.401**. 1ª ed. Brasília, 2019.

BRASIL. Ministério da Defesa. Exército Brasileiro. Estado-Maior do Exército. **Inteligência Militar Terrestre - EB20-MF-10.107**. 2ª ed. Brasília, 2015a.

BRASIL. Ministério da Defesa. Exército Brasileiro. Estado-Maior do Exército. **Inteligência - EB20-MC-10.207**. 1ª ed. Brasília, 2015b.

BRASIL. Portaria nº 100-EME, de 21 de Maio de 2014. Aprova a Diretriz de Implantação do Projeto LUCERNA: **Boletim do Exército nº 22/2015**. Brasília, DF, 2014.

BEEBE, Sarah Miller e PHERSON, Randolph H. **Cases in Intelligence Analysis: Structured Analytic Techniques in Action (Instructor Materials)**. Second Edition. 2015.

BENDER, E. M.; GEBRU, T.; MCMILLAN-MAJOR, A.; e SHMITCHELL, S. **On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?** Proceedings of FAccT, 2021.

BOSTROM, N.; YUDKOWSKY, E. **The Ethics of Artificial Intelligence**. In: Cambridge Handbook of Artificial Intelligence. Cambridge University Press, 2014.

BROWN, T. B., MANN, B., RYDER, N., SUBBIAH, M., KAPLAN, J., DHARIWAI, P., ... e Amodei, D. **Language Models are Few-Shot Learners**. OpenAI Blog, 2020.

CLARK, Robert M. **Intelligence Analysis: A Target-Centric Approach**. 7ª ed. Washington: CQ Press. 2022.

D'ANCONA, Matthew. **Pós-verdade: A Nova Guerra Contra a Verdade e Como Lutar contra ela**. Londres: Ebury Press, 2017.

DEVANNY, Joe, DYLAN, Huw e GROSSFELD, Elena. **Generative AI and Intelligence Assessment**, The RUSI Journal, 168:7, 16-25. 2022.

HENDRICKSON, Noel. **Reasoning for intelligence analysts: a multidimensional**

approach of traits, techniques and targets. Londres, 2018.

HOWARD, J. e RUDER, S. **Universal Language Model Fine-tuning for Text Classification**, 2018. arXiv preprint arXiv:1801.06146.

HU, H., MA, Z., LIU, Z., HOVY, E., e XING, E. P. **LoRA: Low-Rank Adaptation of Large Language Models**, 2021. arXiv preprint arXiv:2106.09685.

LEWIS, P., OGUZ, B., RINOTT, R., RIEDEL, S., e SCHWENK, H. **Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks**, 2020. arXiv preprint arXiv:2005.11401.

O'NEIL, Cathy. **Weapons of Math Destruction**. New York: Crown, 2016.

OPENAI. **Definição do conceito de Large Language Model**. ChatGPT (Modelo GPT-4) [inteligência artificial]. San Francisco: OpenAI, 2023. Disponível em: <https://www.openai.com/chatgpt>. Acesso em: 11 de maio de 2024a.

OPENAI. **Definição de Análise de Inteligência**. ChatGPT (Modelo GPT-4) [inteligência artificial]. San Francisco: OpenAI, 2023. Disponível em: <https://www.openai.com/chatgpt>. Acesso em: 11 de maio de 2024b.

PLUM, Thiago Itamar. **As contribuições de LLM (Large Language Models) para a atividade de HUMINT no SIEx**. 43 f. Orientador: Leandro Chycziy. Trabalho de Conclusão de Curso (Especialização em Análise de Inteligência) - Escola de Inteligência Militar do Exército (EsIME), Brasília – DF, 2023.

RAJI, I. D.; e SMART, A. **AI and the Everything in the Whole Wide World Benchmark**. In: NeurIPS Workshop, 2020

RAJKOMAR, A.; DEAN, J.; e KOHANE, I. **Machine Learning in Medicine**, 2019. The New England Journal of Medicine.

VANIAN, Jonathan. **ChatGPT and generative AI are booming, but at a very expensive price**. CNBC. [13 de março de 2023]. Disponível em: <https://www.cnbc.com/2023/03/13/chatgpt-and-generative-ai-are-booming-but-at-a-very-expensive-price.html>. Acesso em: 27 de maio de 2024.

WILLIAMS, Sophie; PONA, Olga. **Batalha sangrenta no rio foi a terceira em três dias**. BBC News. Disponível em: <https://www.bbc.com/news/world-europe-61399440>. Acesso em: 12 de maio de 2024.

WOLF, T.; DEBUT, L., Sanh, V.; CHAUMOND, J.; DELANGUE, C.; MOI, A. e RUSH, A. M. **HuggingFace's Transformers: State-of-the-art Natural Language Processing**. 2020. arXiv preprint arXiv:1910.03771.

## APÊNDICE A

### Análise Prescritiva gerada pelo Chatbot local Llama 3

#### **Análise Prescritiva: Situação na Terra Indígena Yanomami**

##### **Aspectos essenciais:**

- Yanomamis são um povo indígena que habita uma grande área da Amazônia brasileira, com uma população estimada em mais de 30 mil pessoas.
- Sua forma de vida é baseada na agricultura de subsistência e no cultivo de plantas silvestres.
- Eles são conhecidos por sua cultura rica em lendas e mitos que transmitem seus valores e crenças.

##### **Aspectos secundários:**

- As áreas indígenas onde os yanomamis vivem estão sob ameaça devido às atividades humanas invasivas como mineração, extração florestal e agricultura comercial.
- O contato com os não-indígenas traz doenças que afetam seriamente sua saúde, além de alterá-los culturalmente.
- Eles enfrentam problemas como escassez de alimentos devido à perda do território original e às práticas agrícolas invasivas.

##### **Análise diagnóstica:**

- A população indígena yanomami continuará diminuindo se os problemas de ameaça à sua cultura e à saúde não forem resolvidos.
- As práticas agrícolas sustentáveis e o cuidado ambiental dos yanomamis serão gradualmente desaparecendo devido às pressões externas.
- Os valores e crenças dos yanomamis serão alterados devido ao contato frequente com os não-indígenas.

##### **Análise prescritiva:**

- O governo brasileiro precisa implementar políticas efetivas para garantir o direito dos yanomamis à sua terra tradicional e à autodeterminação cultural.
- Os negócios que operam nas áreas indígenas precisam ser regulamentados estritamente para evitar a destruição ambiental e o contato excessivo com os yanomamis.
- Os yanomamis precisam receber assistência médica especializada e educação para que suas práticas agrícolas se adaptem às mudanças ambientais.

**Conclusão:** O problema dos yanomamis é complexo e multifacetado, envolvendo questões culturais, econômicas, políticas e ambientais. Uma abordagem holística é necessária para preservar seu modo de vida tradicional e garantir que sua cultura seja preservada para futuras gerações.

## APÊNDICE B

Análise Prescritiva gerada através do Chatbot ChatGPT-4o

### **Análise Prescritiva: Situação na Terra Indígena Yanomami**

*O Ministério da Defesa deve intensificar a vigilância e presença militar, colaborar com órgãos ambientais e de saúde, e apoiar iniciativas de educação e infraestrutura para responder de maneira eficaz à crise na Terra Indígena Yanomami.*

#### **Aspectos Essenciais**

A crise na Terra Indígena Yanomami é agravada pela atividade ilegal de garimpo, que provoca destruição ambiental severa e problemas de saúde pública. A região de difícil acesso aumenta os desafios logísticos para qualquer intervenção.

#### **Aspectos Secundários**

A contaminação por mercúrio dos rios e a perda de biodiversidade são consequências diretas do garimpo ilegal, afetando a vida das comunidades indígenas e a sustentabilidade ambiental.

#### **Análise Diagnóstica**

É provável que a continuidade das atividades ilegais de garimpo aumente a instabilidade na região, resultando em mais conflitos e deterioração ambiental e de saúde.

#### **Análise Prescritiva**

1. Fortalecimento da Vigilância e Segurança: Incrementar a presença militar para desencorajar atividades ilegais e estabelecer postos avançados para monitoramento e resposta rápida.
2. Integração com Órgãos Ambientais e de Saúde: Cooperar com o IBAMA e a SESAI para ações integradas de recuperação ambiental e assistência à saúde das populações afetadas.
3. Ações de Impacto Social e Educação: Promover campanhas de educação sobre os direitos indígenas e impactos ambientais do garimpo, incentivando práticas sustentáveis.
4. Infraestrutura e Logística: Desenvolver infraestrutura que facilite o acesso e a segurança das operações militares e de saúde na região.

#### **Conclusão**

Implementando estas ações, o Ministério da Defesa pode mitigar a crise atual e fortalecer a resposta a longo prazo, protegendo a soberania e os direitos das comunidades Yanomami.