

INTELIGÊNCIA ARTIFICIAL GENERATIVA NAS CIÊNCIAS EXATAS, BIOLÓGICAS E HUMANAS: UMA ABORDAGEM DETALHADA DA ENGENHARIA DE PROMPT



<https://doi.org/10.22533/at.ed.1661125170314>

Data de aceite: 06/08/2025

Márcio Mendonça

Universidade Tecnológica Federal do
Paraná
PPGEM-CP - Programa de Pós-
Graduação em Engenharia Mecânica CP/
PG
Cornélio Procópio - PR
<http://lattes.cnpq.br/5415046018018708>

Vitor Blanc Milani

Universidade Tecnológica Federal do
Paraná
Mestrando - PPGEM-CP - Programa de
Pós-Graduação em Engenharia Mecânica
CP/PG
Cornélio Procópio – PR
<http://lattes.cnpq.br/4504374098250296>

Mário Sérgio Martinelli Medina

Universidade Tecnológica Federal do
Paraná
Técnico de Laboratório de Informática na
UTFPR
Cornélio Procópio – PR
<http://lattes.cnpq.br/6624259960900455>

Fabio Rodrigo Milanez

UnISENAIPR-Campus Londrina –
Londrina-PR
<http://lattes.cnpq.br/3808981195212391>

Iago Maran Machado

Universidade Tecnológica Federal do
Paraná
Mestrando - PPGEM-CP - Programa de
Pós-Graduação em Engenharia Mecânica
CP/PG
Cornélio Procópio – PR
<http://lattes.cnpq.br/3808981195212391>

Daniela Mendonça Oliveira

Mestranda - Programa de Pós-Graduação
em Ensino de Ciências Humanas, Sociais
e da Natureza (PPGEN-CP/LD)
Cornélio Procópio – PR
<http://lattes.cnpq.br/7537622609222737>

Henrique Cavalieri Agonilha

Universidade Filadélfia (Unifil)
Londrina - PR
<http://lattes.cnpq.br/9845468923141329>

Emerson Ravazzi Pires da Silva

Universidade Tecnológica Federal do
Paraná
Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR
<http://lattes.cnpq.br/3845751794448092>

Roberto Bondarik

Universidade Tecnológica Federal do Paraná
Programa de Pós-Graduação em Ensino de Ciências Humanas, Sociais e da Natureza
(PPGEN-CP/LD)
<http://lattes.cnpq.br/6263028023417758>

Fabio Nogueira de Queiroz

Centro Paula Souza
Professor Fatec
Ourinhos – SP
<http://lattes.cnpq.br/4466493001956276>

Eduardo Pegoraro Heinemann

Universidade Tecnológica Federal do Paraná Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR
<http://lattes.cnpq.br/0964474292409084>

Marco Antônio Ferreira Finocchio

Universidade Tecnológica Federal do Paraná Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio
<http://lattes.cnpq.br/8619727190271505>

Vicente de Lima Gongora

UnISENAIPR-Campus Londrina
Londrina-PR
<http://lattes.cnpq.br/6784595388183195>

Angelo Feracin Neto

Universidade Tecnológica Federal do Paraná
Departamento Acadêmico de Engenharia Elétrica (DAELE)
Cornélio Procópio-PR
<http://lattes.cnpq.br/0580089660443472>

Armando Paulo da Silva

Universidade Tecnológica Federal do Paraná
Programa de Pós-Graduação em Ensino de Ciências Humanas, Sociais e da Natureza
(PPGEN-CP/LD)
Cornélio Procópio
<http://lattes.cnpq.br/6724994186659242>

Michelle Eliza Casagrande Rocha

Universidade Norte do Paraná – Unopar – Anhanguera
Londrina-PR
<http://lattes.cnpq.br/4411484670091641>

RESUMO: A Inteligência Artificial Generativa (IAG) vem se destacando como tecnologia disruptiva nas ciências exatas, biológicas e humanas, revolucionando processos e metodologias de pesquisa e aplicação prática. Essencial nessa transformação está a Engenharia de *Prompt*, técnica que consiste na elaboração de instruções estruturadas e detalhadas para orientar modelos generativos como GPT, DALL-E e *Midjourney*. Nas ciências exatas, a IAG auxilia na resolução de problemas matemáticos complexos, automação de provas lógicas e otimização computacional, com *prompts* garantindo precisão e coerência nas respostas, além de acelerar simulações e modelagens físicas. Nas ciências biológicas, a aplicação da IAG se destaca em genética, medicina personalizada e bioinformática. *Prompts* adequadamente construídos facilitam diagnósticos precisos, geração de hipóteses clínicas e desenvolvimento de novas moléculas farmacêuticas, otimizando o uso de grandes bases de dados biológicos. Em ciências humanas, especialmente relevante é o uso da IAG para gerar conteúdos educativos personalizados, análises socioculturais detalhadas e textos contextualizados emocional e culturalmente. Além disso, tem potencial significativo na análise e geração de evidências jurídicas, onde *prompts* estruturados auxiliam na produção de documentos legais, sistematização de provas e interpretação de textos legais com rigor ético e coerência argumentativa. Portanto, a Engenharia de *Prompt* é uma abordagem estratégica e essencial para o sucesso da IAG, exigindo equilíbrio entre clareza, precisão e criatividade, assegurando operações éticas e eficazes dos modelos generativos nas diversas áreas do conhecimento.

PALAVRAS-CHAVE: Inteligência Artificial Generativa, Instanciações da IAG, Engenharia de *prompt*

GENERATIVE ARTIFICIAL INTELLIGENCE IN THE EXACT, BIOLOGICAL, AND HUMAN SCIENCES: A DETAILED APPROACH TO PROMPT ENGINEERING

ABSTRACT: Generative Artificial Intelligence (GenAI) has emerged as a disruptive technology across the exact, biological, and human sciences, revolutionizing research processes, methodologies, and practical applications. Central to this transformation is Prompt Engineering, a technique that consists of crafting structured, detailed instructions to guide generative models such as GPT, DALL-E, and Midjourney. In the exact sciences,

GenAI assists in solving complex mathematical problems, automating formal proofs, and performing computational optimization, with prompts ensuring precision and coherence in responses while accelerating simulations and physical modelling. In the biological sciences, GenAI applications stand out in genetics, personalized medicine, and bioinformatics. Well-crafted prompts facilitate accurate diagnoses, the generation of clinical hypotheses, and the development of new pharmaceutical molecules, optimizing the use of large biological databases. In the human sciences (humanities), GenAI is particularly relevant for generating personalized educational content, producing detailed sociocultural analyses, and creating texts that are emotionally and culturally contextualized. It also holds significant potential for the analysis and generation of legal evidence, where structured prompts support the production of legal documents, the systematization of evidence, and the interpretation of legal texts with ethical rigor and argumentative coherence. Therefore, Prompt Engineering is a strategic and essential approach for the success of GenAI, requiring a balance among clarity, precision, and creativity, and ensuring the ethical and effective operation of generative models across diverse domains of knowledge.

KEYWORDS: Generative Artificial Intelligence, instantiations of GenAI, *Prompt Engineering*

INTRODUÇÃO

A Inteligência Artificial Generativa (IAG) representa um dos avanços tecnológicos mais disruptivos da atualidade, promovendo transformações profundas nos campos das ciências exatas, biológicas e humanas. Ao contrário da inteligência artificial tradicional, voltada para tarefas específicas e previsíveis, a IAG é capaz de criar conteúdo de forma autônoma, como textos, imagens, sons, códigos e até simulações, a partir de grandes volumes de dados previamente aprendidos (GOODFELLOW et al., 2014; BROWN et al., 2020). Esse novo paradigma ampliou significativamente o potencial de aplicação da inteligência artificial, não apenas como ferramenta de automação, mas como agente de criação e inovação.

No centro desse movimento emergente está a Engenharia de *Prompt* — a prática de estruturar entradas (*prompts*) que direcionam e refinam a produção dos modelos generativos. Trata-se de um campo em rápido desenvolvimento, essencial para garantir que as respostas geradas sejam coerentes, relevantes, precisas e eticamente aceitáveis. Segundo Reznick et al. (2023), a engenharia de *prompt* torna-se a ponte entre a intenção humana e a produção algorítmica, exigindo habilidades que combinam clareza linguística, conhecimento técnico e sensibilidade contextual.

Nas ciências exatas, a aplicação da IAG tem se mostrado especialmente eficaz na resolução de equações diferenciais, na modelagem de sistemas físicos complexos e na otimização de algoritmos. Estudos como os de Andrews et al. (2022) destacam a utilização de modelos generativos para acelerar simulações científicas, reduzir custos computacionais e promover descobertas inovadoras em áreas como física teórica e engenharia computacional.

Neste trabalho iremos instanciar os empregos na análise de um circuito eletrônico e robótica. Assim como o caminho cognitivo do desenvolvimento do *prompt*.

Na área das ciências biológicas e da saúde, a IAG vem ganhando espaço em práticas como medicina personalizada, predição genômica, triagem de medicamentos e diagnóstico assistido por imagem. Zhang et al. (2021) evidenciam que o uso de algoritmos generativos tem potencial para identificar novos compostos químicos com propriedades farmacológicas, além de auxiliar na geração de hipóteses clínicas e na interpretação de exames com maior precisão. Topol (2019) complementa ao afirmar que a IA, quando aplicada com responsabilidade, pode humanizar a medicina ao liberar médicos para uma atuação mais empática e estratégica.

Por sua vez, nas ciências humanas e sociais, a IAG abre novas possibilidades para a produção de conteúdos educativos personalizados, análise de fenômenos socioculturais, interpretação de textos históricos e geração automatizada de documentos legais. Floridi e Cowsls (2022) alertam, contudo, que o uso ético da IA nessas áreas requer critérios claros de transparência, equidade e responsabilidade, especialmente quando as decisões impactam diretamente indivíduos e grupos sociais.

A análise e geração de evidências jurídicas, por exemplo, tornam-se mais precisas e acessíveis com o uso de modelos generativos capazes de processar vastos volumes de texto normativo e jurisprudencial. Nesses contextos, a engenharia de *prompt* permite formular perguntas juridicamente relevantes, estruturar argumentos com base em precedentes e produzir relatórios com rigor técnico e clareza argumentativa (SURESH et al., 2022).

De forma similar as aplicações das áreas de conhecimento, duas instanciações serão utilizadas, reconhecimento de uma mesma foto manipulada, e na área de engenharia da computação, a qual poderia auxiliar o profissional embasar uma argumentação peça de defesa de possíveis problemas em um computador.

Portanto, a engenharia de *prompt* configura-se como uma habilidade estratégica, interdisciplinar e essencial para o uso eficaz da IAG. Seu domínio implica não apenas conhecimento técnico sobre os modelos, mas também sensibilidade ética, criatividade linguística e competência crítica. À medida que a IAG se torna cada vez mais presente nos ambientes acadêmico, científico e profissional, torna-se urgente fomentar a formação de especialistas capazes de dialogar entre as áreas e aplicar a engenharia de *prompt* com responsabilidade, inovação e precisão.

FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL GENERATIVA VERSUS INTELIGÊNCIA ARTIFICIAL CLÁSSICA

A evolução da Inteligência Artificial (IA) pode ser compreendida por meio da distinção entre seus paradigmas fundamentais: a Inteligência Artificial Clássica (IAC) e a Inteligência Artificial Generativa (IAG). Enquanto a IAC tem suas bases no raciocínio simbólico e na manipulação explícita de regras lógicas, a IAG é fundamentada em arquiteturas estatísticas

de aprendizado profundo, sendo projetada para gerar novos conteúdos com base em distribuições probabilísticas aprendidas a partir de grandes volumes de dados (N. Miralem, *et al*, 2024).

A IAC, também conhecida como GOFAI (*Good Old-Fashioned Artificial Intelligence*), é centrada em estruturas formais e lógicas, como redes semânticas, sistemas especialistas e raciocínio baseado em regras. Esses sistemas operam a partir de conhecimento codificado manualmente por especialistas, priorizando a explicabilidade e a transparência do processo decisório (RUSSELL; NORVIG, 2013). Exemplos notáveis incluem os sistemas de diagnóstico médico baseados em regras, como o *MYCIN*, e mecanismos de planejamento automático como *STRIPS*.

Por outro lado, a IAG emerge a partir do avanço das redes neurais profundas, notadamente com o desenvolvimento dos modelos transformadores, como o *GPT* (*Generative Pre-trained Transformer*), *BERT* e *DALL·E*. Esses modelos não operam a partir de regras explícitas, mas sim pela modelagem de distribuições estatísticas complexas sobre dados textuais, visuais ou multimodais. O conhecimento é internalizado de forma implícita nos pesos das redes neurais, tornando o processo de geração dependente de representações latentes (BOMMASANI *et al.*, 2021).

A distinção epistemológica entre esses dois paradigmas é marcante. Enquanto a IAC busca replicar o raciocínio humano por meio da lógica formal e da decomposição algorítmica de problemas, a IAG adota uma abordagem conexionista, em que a inferência é baseada em padrões aprendidos, muitas vezes opacos ao escrutínio humano (LECUN *et al.*, 2015). Isso levanta questões críticas sobre interpretação e controle ético, dado que sistemas generativos frequentemente operam como “caixas-pretas”.

Além disso, a IAG apresenta uma capacidade única de generalização criativa, sendo capaz de sintetizar conteúdos originais, como textos, imagens e códigos, a partir de *prompts* que especificam intenções de forma não determinística. Essa propriedade contrasta com a rigidez dos sistemas clássicos, cuja capacidade de adaptação a contextos inéditos é limitada sem reprogramação ou intervenção humana direta (BENGIO *et al.*, 2021).

Ambos os paradigmas, entretanto, não são mutuamente excludentes. Há um movimento recente na literatura que propõe abordagens híbridas, integrando o raciocínio simbólico da IAC com a aprendizagem estatística da IAG, a fim de combinar robustez interpretativa com flexibilidade adaptativa (GARCEZ; LAMB; GORI, 2019). Essa convergência pode ser observada em modelos de *Neuro-Symbolic AI*, que visam superar as limitações de cada abordagem isoladamente.

Portanto, compreender os fundamentos da IAC e da IAG é essencial para a formulação de soluções mais eficazes e eticamente alinhadas, sobretudo em domínios críticos como saúde, justiça e educação, onde tanto a explicabilidade quanto a criatividade são exigências complementares.

Inicia texto com clareza: é importante evitar ambiguidades para que o modelo entenda exatamente o que se espera. Dizer “Fale sobre energia” é vago e pode levar a respostas sobre energia elétrica, solar ou até “energia pessoal”; já “Explique como funciona a geração de energia solar fotovoltaica em residências urbanas” define recorte e direção, aumentando a chance de uma resposta correta e completa.

A objetividade também conta: em vez de “Estou querendo aprender sobre como os computadores funcionam e queria que você me desse um texto explicando isso, pode ser?”, que é informal e disperso, prefira “Escreva um texto introdutório explicando, em linguagem simples, como funcionam os computadores”, que vai direto ao ponto.

A contextualização serve para adaptar conteúdo, tom e profundidade ao seu propósito; por exemplo, “Explique a Revolução Francesa para alunos do ensino médio, com linguagem acessível e exemplos históricos” orienta o vocabulário e o nível de detalhe adequados ao público. Indicar o formato da resposta evita desencontros: “Liste 5 vantagens da energia eólica em formato de tópicos com breves explicações”

Especificar um papel ou estilo também ajuda a calibrar a linguagem: “Escreva como se fosse um professor explicando para alunos de engenharia elétrica os princípios do transformador ideal” induz um tom técnico e didático. Incluir exemplos ou restrições ajusta ainda mais o resultado; ao pedir “Crie um parágrafo explicativo sobre fotossíntese, sem usar termos técnicos difíceis, e com um exemplo aplicado ao cotidiano”, desse modo alinha a resposta ao público-alvo.

Organize a resposta em tópicos.” Em síntese, bons *prompts* equilibram clareza, precisão e criatividade para orientar o modelo e garantir respostas éticas, eficazes e alinhadas à sua finalidade.

RESULTADOS E DISCUSSÕES

A IAG, por meio da rede *transformer* que atualmente capacidade de análise de imagem igual ou melhor que as redes convolucionais como o *Yolo V8* (Carion, 2020), ressalta-se que se trata de um artigo do *Journal Springer Natures*, por exemplo. A tabela 1 mostra esse comparativo

| Critério | <i>Transformers (ViT, DETR, Swin)</i> | <i>YOLO (v5, v8)</i> | <i>Fontes / Artigos</i> |
|--|--|---|--|
| Capacidade de foco em detalhes | Alta — a atenção global capta regiões pequenas e fornece contexto. | Limitada — opera com grades e janelas prédefinidas. | Carion <i>et al.</i> , 2020; Liu <i>et al.</i> , 2021. |
| Detecção de objetos pequenos | Superior com Deformable DETR e Swin. | Inferior, em geral requer ajustes específicos. | Zhu <i>et al.</i> , 2021; Ultralytics (YOLOv8). |
| Precisão em imagens com ruído/occlusão | Robusta — lida bem com objetos sobrepostos ou parcialmente visíveis. | Mais fraca em cenários visuais complexos. | Carion <i>et al.</i> , 2020; Zhu <i>et al.</i> , 2021. |

| | | | |
|--|--|---|--|
| Segmentação de bordas/ contornos | Excelente com MaskDETR, Segmenter e Swin. | Básica — segmentação majoritariamente por <i>bounding boxes</i> retangulares. | Liu <i>et al.</i> , 2021; DETR + MaskRCNN. |
| Velocidade de inferência (tempo real) | Mais lenta, com maior latência. | Muito rápida, adequada a sistemas embarcados e tempo real. | Ultralytics, 2023; Carion <i>et al.</i> , 2020. |
| Análise semântica e contextual | Alta — interpreta relações espaciais e contexto global. | Baixa — detecta objetos com compreensão limitada do cenário. | Dosovitskiy <i>et al.</i> , 2021; Carion <i>et al.</i> , 2020. |
| Requisitos computacionais | Altos — demanda GPU robusta e tempo de treinamento prolongado. | Eficiente — otimizado para inferência rápida em hardware limitado. | ICLR 2021 (ViT); Documentação YOLOv8. |
| Desempenho em benchmarks (mAP) | Melhor em mAP@0,75 e AP_small; maior precisão para objetos difíceis. | Melhor em mAP@0,5, com excelente velocidade. | COCO benchmarks; Ultralytics; artigos de DETR e Swin. |

Tabela 1. Comparação entre redes as respectivas fontes da comparação.

Reconhecimento de imagens, direito, humanas

Neste caso a mesma foto a imagem 2, cópia distorcida da imagem 1 foi visivelmente manipulada e apresenta como fotos diferentes

a IAG pode analisar e apresentar uma probabilidade de serem iguais ou não. Dois prompts bem elaborados podem quantificar essa análise e auxiliar de maneira decisiva na tomada de decisão do profissional



Imagem 1. Comparação entre duas imagens comuns para confirmação de identidade.



Imagem 2. Comparação entre duas imagens comuns para confirmação de identidade.

A análise de similaridade entre as imagens foi conduzida com apoio de um modelo de Inteligência Artificial Generativa (IAG) multimodal de grande porte (por exemplo, GPT-4.0), com o objetivo de qualificar e quantificar evidências além da mera inspeção visual. Embora até um avaliador leigo — como uma criança de 10 anos — consiga perceber semelhanças, tal procedimento é inerentemente subjetivo; por isso, empregou-se a IAG para estruturar a argumentação e reduzir ambiguidades (cf. Y. Yang *et al.*, 2025).

Foram executadas duas análises guiadas por engenharia de *prompt*. Na primeira, solicitou-se uma estimativa da probabilidade de as fotografias diferirem, isto é, de apresentarem diferenças visíveis ou detectáveis mesmo mantendo constantes pose, cenário, iluminação e dispositivo de captura. O modelo identificou três classes principais de variação: (i) movimentos involuntários e micro variações posturais, decorrentes de microexpressões faciais e pequenas tensões musculares; condições de captura, incluindo variações sutis de iluminação, ângulo, foco e compressão; e mudanças naturais do corpo ao longo do tempo, como crescimento de cabelo/barba e flutuações de peso. Adicionalmente, destacou-se a contribuição biomecânica do membro superior, que possui aproximadamente sete graus de liberdade (ombro ≈ 3 , cotovelo ≈ 1 , punho ≈ 3); pequenas variações angulares já deslocam milímetros ou centímetros a orientação do rosto e do documento, tornando improvável a reprodução exata do enquadramento. A inferência resultante foi: a identidade pixel a pixel é virtualmente nula, ao passo que a manutenção da identidade semântica (“mesma pessoa, mesma pose”) tende a permanecer alta em sistemas robustos de reconhecimento, desde que as variações sejam pequenas.

Na segunda análise, instruiu-se o modelo a desconsiderar manipulações superficiais (cor, tom, compressão ou brilho) e concentrar-se no conteúdo essencial. Nessa configuração, a IAG apontou correspondências estruturais entre as imagens: mesma pessoa e pose geral, com vestimenta, óculos, expressão e inclinação da cabeça compatíveis; mesmo documento (posição, inclinação e elementos gráficos internos concordantes); e mesmo

cenário, com fundo e iluminação equivalentes. A presença de datas distintas no rodapé de uma das composições (por exemplo, “09/09/2020” e “19/08/2020”) foi considerada irrelevante para a conclusão técnica, pois não altera a equivalência do conteúdo essencial. Assim, concluiu-se que as imagens são equivalentes do ponto de vista semântico, e que as diferenças residuais atribuíveis a cor/tom/compressão não descaracterizam a identidade da pessoa, do documento e do enquadramento.

Problema de caso da área de engenharia eletrônica, computação, área de exatas

A partir do *prompt* “analisar, como especialista em engenharia da computação, os possíveis problemas de hardware que levam um computador *gamer* a reiniciar de forma intermitente”, a IAG delimitou oito classes principais de causas e propôs um roteiro de diagnóstico.

Em síntese, a fonte de alimentação (PSU) surge como vetor recorrente de instabilidade quando há subdimensionamento de potência (p. ex., fonte de 500 W em sistema que demanda ≈ 650 W sob carga), perda de eficiência por envelhecimento de capacitores ou qualidade inferior de componentes, distribuição inadequada de corrente em múltiplos trilhos de +12 V, e *ripple*/ruído excessivo nas linhas de alimentação. Tais condições precipitam quedas momentâneas de tensão em picos de consumo típicos de GPUs e CPUs de alto desempenho, culminando em resets.

O superaquecimento é outra causa frequente, por montagem térmica deficiente (dissipador mal instalado, pasta térmica ressecada/ausente), ventoinhas com falha ou fluxo de ar insuficiente no gabinete, cenário agravado por *overclock* ou ambiente quente. Leituras incorretas de sensores podem acionar proteções, e nas *GPUs* a refrigeração inadequada de *VRMs* e memórias resulta em desligamentos por proteção térmica/energética.

Na memória *RAM*, destacam-se falhas intermitentes de módulos, mau contato/oxidação em slots DIMM, incompatibilidades de frequência e timings em kits mistos e perfis de *overclock* instáveis. Tais fatores geram erros esporádicos que, sob carga, precipitam reinicializações.

Quanto à placa-mãe, observam-se capacitores estufados/vazando, problemas nos *VRMs* da CPU (especialmente com *overclock*), BIOS corrompida ou firmware instável que afetam o POST, além de curtos intermitentes por trilhas danificadas ou soldas frias, cuja detecção usualmente requer instrumentação específica.

A GPU pode induzir *resets* por sobrecarga térmica de núcleo/VRAM, conectores *PCIe* mal encaixados/oxidados, cabos auxiliares (6/8 pinos) defeituosos ou perfis de *overclock* instáveis aplicada via software. Na CPU, embora menos comum, ocorrem instabilidades de *overclock*, falhas internas de silício e danos de pinagem (LGA/PGA) associados a trocas de *cooler*/limpeza.

Em armazenamento, SSDs/NVMe com firmware problemático ou conexões frouxas podem provocar quedas momentâneas de energia lógica e resets; em HDDs, curto no motor ou PCB danificada pode injetar ruído elétrico no barramento e desestabilizar o sistema. Por fim, problemas de energia externa — tensão oscilante, aterramento ausente/deficiente e interferências eletromagnéticas — aumentam a probabilidade de reinicializações; nesses casos, recomenda-se condicionamento por UPS (*no-break*) com regulação automática de tensão (AVR) e verificação do circuito/aterramento.

Roteiro de diagnóstico recomendado. Proceder de forma escalonada: (i) testar com PSU de qualidade e potência adequada (preferencialmente 80 Plus Gold ou superior), avaliando estabilidade sob carga; (ii) monitorar temperaturas em tempo real (p. ex., *HWMonitor/HWiNFO*) e inspecionar montagem térmica/pasta e *airflow*; (iii) executar MemTest86 e revisar encaixe/limpeza dos *DIMMs*; (iv) isolar a GPU (testar vídeo integrado e, inversamente, outra GPU), verificando conectores/cabos *PCIe*; (v) inspecionar a placa-mãe (capacitores, trilhas, oxidação, empeno), resetar/atualizar a BIOS e remover qualquer *overclock*; (vi) verificar integridade física da CPU e do soquete; checar armazenamento (firmware, cabos, saúde) e dissipação dos controladores; repetir os testes em outro circuito elétrico com aterramento verificado e, se possível, sob UPS com AVR.

Observa-se que a existência dessas oito classes de falhas potenciais eleva a complexidade do diagnóstico e pode comprometer a confiabilidade operacional mesmo em equipamentos novos, nos quais erros de montagem, dimensionamento inadequado ou defeitos de fabricação são plausíveis. A abordagem acima prioriza causas mais prováveis, reduz vieses e fornece trilha de auditoria técnica adequada a relatórios na área de Engenharia Eletrônica/Computação.

Problema de caso da área de medicina

Prompt: Analise como um médico especialista radiografia (raio-x) desse joelho humano.

Como um médico especialista em radiologia, ao analisar a radiografia de joelhos humanos como a da imagem fornecida, consideram-se diversos aspectos anatômicos e patológicos. Abaixo, segue uma análise descritiva com base visual da imagem:




Imagem 3. Joelho humano com possível fratura.

Análise radiográfica dos joelhos (projeção anteroposterior em ortostatismo). A radiografia apresenta projeção AP em posição ortostática, com boa qualidade técnica, contraste e nitidez suficientes para avaliação óssea. Observam-se contornos regulares do fêmur distal, sem evidências de fraturas nem de lesões líticas ou escleróticas; as superfícies articulares da tíbia proximal estão bem delineadas, com preservação da arquitetura trabecular; a fíbula proximal é parcialmente visível e não exhibe alterações grosseiras.

A articulação femorotibial mostra espaço articular visualmente simétrico entre os lados direito e esquerdo, sem sinais de colapso significativo, e alinhamento sem evidências de valgo. Não se identificam osteócitos, o que sugere ausência de artrose de grau moderado a grave.

A patela não é totalmente avaliada nesta incidência — observa-se apenas sua densidade sobreposta ao fêmur distal —, sendo recomendável complementar com projeção lateral e axial (*skyline*) para análise específica. De modo geral, não há sinais radiográficos de fraturas, esclerose subcondral, osteofitos ou redução assimétrica do espaço articular que indiquem doença degenerativa avançada; tampouco se notam lesões osteolíticas ou massas.

Conclusão presumida: exame sem alterações ósseas evidentes, com espaços articulares preservados e sem sinais de desalinhamento ou doença degenerativa significativa. Para investigação de meniscos, ligamentos e cartilagens, a ressonância magnética é o método indicado e deve ser considerada conforme a hipótese clínica.

Considerações sobre o uso de IAG na interpretação em contextos sensíveis. A utilização de sistemas de Inteligência Artificial Generativa (IAG) para apoio à análise radiográfica pode incrementar padronização e produtividade; contudo, a credibilidade dos achados depende da supervisão por especialista.

Profissionais familiarizados com IAG tendem a integrar melhor suas saídas ao raciocínio clínico e aos limites do método (Mendonça et al., 2025). Persistem, entretanto,

limites epistêmicos e técnicos: modelos generativos operam de forma probabilística, sem compreensão semântica genuína; podem gerar “alucinações” (informações falsas ou imprecisas) e, muitas vezes, carecem de rastreabilidade suficiente para auditoria do processo decisório, tensionando requisitos de explicabilidade (Raji *et al.*, 2020).

No domínio da ética médica, destacam-se riscos relativos ao consentimento informado (uso de dados e interação com IA), vieses decorrentes de populações sub-representação nos dados de treinamento — com potencial de amplificar iniquidades diagnósticas (Obermeyer *et al.*, 2019) — e a possibilidade de indevida substituição do julgamento clínico por automatismos. Em síntese, a IAG deve ser posicionada como ferramenta auxiliar, com protocolos de validação, registro das condições de uso e revisão por profissional habilitado, especialmente quando as conclusões radiológicas possam impactar decisões assistenciais ou judiciais.

Além disso, aplicações e riscos no Judiciário. No âmbito judicial, a Inteligência Artificial Generativa (IAG) pode auxiliar na elaboração de minutas de sentença, na análise de jurisprudência e como suporte à mediação.

Esses usos, contudo, introduzem riscos específicos: decisões enviesadas, uma vez que modelos treinados sobre julgados pretéritos tendem a reproduzir discriminações históricas e injustiças sistêmicas; lacunas de responsabilização, pois permanece controvérsia sobre quem responde por um erro decisório mediado por IA — o magistrado, o desenvolvedor ou a instituição —, o que configura um dos principais entraves jurídicos (CATH *et al.*, 2018); e ameaças à imparcialidade, na medida em que a automatização pode “sugerir” resultados ancorados em correlações estatísticas, e não em princípios jurídico-normativos universais, tensionando o devido processo e a independência judicial.

Aspectos regulatórios e medidas mitigadoras. Diretrizes internacionais — a exemplo da UNESCO (2021), da OCDE e do *AI Act* da União Europeia — convergem para um modelo baseado em risco, no qual aplicações em justiça e saúde são classificadas como alto risco e, por isso, sujeitas a requisitos reforçados de transparência, supervisão humana significativa e avaliação contínua de desempenho e segurança.

Recomenda-se auditoria independente e, quando pertinente, certificação dos sistemas, com ênfase na verificação de segurança, explicabilidade e mitigação de vieses algorítmicos, tanto na fase de implementação quanto na operação. Ressalta-se a necessidade de participação democrática — incluindo sociedade civil, especialistas e instituições — na definição de parâmetros éticos, visando evitar tecnocracia e garantir legitimidade sociopolítica. A IAG deve atuar como ferramenta de suporte decisório, com responsabilidade definida documentação do ciclo de vida e possibilidade de revisão humana.

ANÁLISE DOS RESULTADOS

A análise dos resultados do artigo *Inteligência Artificial Generativa nas Ciências Exatas, Biológicas e Humanas: uma abordagem detalhada da Engenharia de Prompt* evidencia a centralidade da formulação do prompt na qualidade, auditabilidade e relevância das respostas geradas por IAG em múltiplos domínios.

Na visão computacional, a comparação entre arquiteturas baseadas em atenção (ViT, DETR, Swin) e a família YOLO (v5, v8) revela que Transformers apresentam maior acurácia em detalhes finos, objetos pequenos e resistência a ruído, embora com maior demanda computacional e latência. Em contrapartida, YOLO destaca-se pela eficiência e adequação a sistemas embarcados e aplicações em tempo real, caracterizando um *trade-off* entre precisão e viabilidade operacional (Carion et al., 2020; Liu et al., 2021).

No contexto jurídico, a elaboração de prompts complementares permitiu à IAG avaliar imagens aparentemente distintas como semanticamente equivalentes, fundamentando tecnicamente sua decisão e demonstrando o valor pericial da engenharia de prompt quando acompanhada por documentação processual e validação especializada.

Na análise de falhas computacionais, a investigação de reinicializações intermitentes em hardware identificou oito causas prováveis, estruturadas em um protocolo escalonado de diagnóstico técnico — compatível com práticas de bancada e útil para tomada de decisão em engenharia de sistemas.

Na aplicação médico-radiológica, a interpretação automatizada de radiografia AP dos joelhos resultou em laudo técnico estruturado, com avaliação anatômica detalhada, identificação de sinais de artrose e recomendações complementares. O exemplo reforça o potencial da IAG como ferramenta de apoio didático, triagem e segunda opinião, desde que supervisionada por especialista.

Os achados demonstram a aplicabilidade da IAG em cenários técnico-científicos e forenses, ressaltando que a engenharia de prompt constitui uma competência essencial para garantir profundidade, reprodutibilidade e rigor nas respostas. Recomenda-se, para robustez metodológica, a adoção de protocolos de validação, registro contextual de uso e conformidade ética e normativa.

CONCLUSÃO

A Inteligência Artificial Generativa (IAG), quando guiada por engenharia de prompt ética e criteriosa, revela-se uma ferramenta interdisciplinar de alto impacto nas ciências exatas, biológicas e humanas. A qualidade dos prompts influencia diretamente a relevância e a precisão das respostas, viabilizando desde análises jurídicas até diagnósticos técnicos e clínicos. Casos práticos — como a avaliação de imagens em disputas legais, a identificação de falhas em hardware e a elaboração de laudos radiológicos — evidenciam o potencial da IAG para ampliar a capacidade analítica e apoiar decisões complexas. Contudo, sua aplicação em contextos sensíveis exige supervisão humana qualificada, em função de implicações éticas, epistemológicas e regulatórias.

Consolida-se, assim, a engenharia de prompt como competência transversal e estratégica na mediação entre usuários e sistemas generativos, moldando a forma como o conhecimento é produzido e interpretado.

Recomenda-se como desdobramentos:

1. Desenvolvimento de protocolos de engenharia de prompt por área do conhecimento, com validação empírica interinstitucional;
2. Elaboração de uma taxonomia de erros em prompts, fundamentada em estudos de caso, para fins de formação técnica;
3. Avaliação longitudinal dos impactos da IAG na prática profissional, com foco em tempo, confiabilidade, satisfação e riscos éticos;
4. Integração de mecanismos de explicabilidade (XAI) aos modelos, com justificativa de raciocínio e base de dados;
5. Implementação de ambientes educacionais gamificados com geração adaptativa de conteúdo via IAG;
6. Estudos comparativos entre profissionais com e sem domínio de engenharia de prompt, mensurando desempenho e impacto decisório;
7. Proposição de marcos regulatórios nacionais para o uso da IAG em setores sensíveis, baseados em ética, direitos fundamentais e responsabilização compartilhada.

AGRADECIMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS

ANDREWS, M.; MCDERMOTT, T.; YANG, Y. The role of AI-generated simulations in physics problem solving. *Journal of Computational Science Education*, v. 13, n. 1, p. 45–52, 2022.

BENGIO, Y.; LECUN, Y.; HINTON, G. Deep learning for AI. *Communications of the ACM*, v. 64, n. 7, p. 58–65, 2021.

BOMMASANI, R. et al. On the opportunities and risks of foundation models. *arXiv preprint, arXiv:2108.07258*, 2021. Disponível em: <https://arxiv.org/abs/2108.07258>. Acesso em: 26 jul. 2025.

BROWN, T. Language models are few-shot learners. In: *Advances in Neural Information Processing Systems*, v. 33, p. 1877–1901, 2020.

CARION, N.; MASSA, F.; SYNNAEVE, G.; USUNIER, N.; KIRILLOV, A.; ZAGORUYKO, S. End-to-end object detection with transformers. In: VEDALDI, A.; BISCHOF, H.; BROX, T.; FRAHM, J.-M. (eds.). *Computer Vision – ECCV 2020*. Cham: Springer, 2020. (Lecture Notes in Computer Science, v. 12346). DOI: 10.1007/978-3-030-58452-8_13.

DOSOVITSKIY, A.. An image is worth 16x16 words: transformers for image recognition at scale. In: International Conference on Learning Representations (ICLR), 2021.

FLORIDI, L.; COWLS, J. A unified framework of five principles for AI in society. *Harvard Data Science Review*, v. 4, n. 1, 2022. Disponível em: <https://hdr.mitpress.mit.edu/pub/0jsh9d1>. Acesso em: 25 jul. 2025.

GARCEZ, A. d'Ávila; LAMB, L. C.; GORI, M. *Neuralsymbolic cognitive reasoning*. Cham: Springer, 2019.

GOODFELLOW, I. Generative adversarial nets. In: *Advances in Neural Information Processing Systems*, v. 27, p. 2672–2680, 2014.

LECUN, Y. Deep learning. *Nature*, v. 521, p. 436–444, 2015.

LIU, Z. Swin Transformer: hierarchical vision transformer using shifted windows. In: *IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021.

MENDONÇA, M.. Inteligências artificiais generativas com Python: fundamentos, aprendizado de máquina, redes neurais clássicas e profundas, Transformers e engenharia de prompt para geração de imagens. In: *CIÊNCIA, TECNOLOGIA E INOVAÇÃO NA PERSPECTIVA DAS ENGENHARIAS*. v. 2, cap. 6. [S. l.]: [s. n.], 2025. Disponível em: <https://chatgpt.com/g/g-pmuQfob8d-image-generator>. Acesso em: 27 jul. 2025.

MIRALEM, N.; ŽUNIĆ, A.; COGO, E.; COGO, E.; BEŠIĆ, I. Exploring the visual CAD capabilities of ChatGPT: an experimental study. In: *2024 32nd Telecommunications Forum (TELFOR)*, Belgrade, Serbia, 2024. p. 1–4. DOI: 10.1109/TELFOR63250.2024.10819091.

OPENAI. GPT4 Technical Report. San Francisco: OpenAI, 2023. Disponível em: <https://openai.com/research/gpt-4>. Acesso em: 25 jul. 2025.

REZNICK, A. Prompt engineering for large language models: fundamentals and best practices. *AI Magazine*, v. 44, n. 2, p. 56–69, 2023.

RUSSELL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. 3. ed. Upper Saddle River: Prentice Hall, 2013.

SICILIANO, B.; KHATIB, O. (Ed.). **Springer Handbook of Robotics**. 2. ed. Cham: Springer, 2016.

SURESH, H. Beyond accuracy: behavioral testing of NLP models with CheckList. *Association for Computational Linguistics*, v. 1, p. 490–503, 2022.

TOPOL, E. *Deep medicine: how artificial intelligence can make healthcare human again*. New York: Basic Books, 2019.

ULTRALYTICS. YOLOv8: documentation and benchmarks. 2023. Disponível em: <https://docs.ultralytics.com>. Acesso em: 28 jul. 2025.

XU, H.; QI, C.; JIANG, B.; LIU, T.; ZHENG, L.; GU, X. Enhancing small model performance in educational classification tasks through knowledge distillation. In: *ICASSP 2025 – IEEE International Conference on Acoustics, Speech and Signal Processing*, Hyderabad, India, 2025. p. 1–5. DOI: 10.1109/ICASSP49660.2025.10888451.

YANG, Y. Performance evaluation and application potential of small large language models in complex sentiment analysis tasks. *IEEE Access*, v. 13, p. 49007–49017, 2025. DOI: 10.1109/ACCESS.2025.3549733.

ZHANG, Y. Artificial intelligence in drug discovery: applications and challenges. *Drug Discovery Today*, v. 26, n. 1, p. 80–93, 2021.

ZHU, X. Deformable DETR: deformable transformers for end-to-end object detection. In: *International Conference on Learning Representations (ICLR)*, 2021.