

Formação em Fundamentos Computacionais de IA e LLMs para Profissionais de Produto: Um Relato de Experiência em Contexto Industrial

Vitória P. Firmino^{1,2}, Janaína N. S. Lopes¹, Valéria Q. Reis^{1,3}, Anderson C. Lima¹, Bruno M. Nogueira¹

¹Faculdade de Computação – Universidade Federal de Mato Grosso do Sul (UFMS)
Campo Grande – Brasil

{vitoria.firmino, janaina.nogueira, valeria.reis,
anderson.lima, bruno.nogueira}@ufms.br

²Cortex – São Paulo – Brasil

³Institute of Information Systems – Leuphana Universität Lüneburg – Alemanha

Abstract. *The incorporation of Artificial Intelligence-based systems, especially large language models, has increased the impact of decisions made during the software development. Product professionals play a strategic role in this process, yet they often lack in-depth technical training regarding such systems. This paper presents the design and evaluation of a course on the computational foundations of AI aimed at this audience in an industrial context. The research is characterized as an experience report involving a short-term educational intervention. Data collection was conducted through questionnaires administered before and after the course. The results indicate an increase in participants' self-perceived conceptual understanding, as well as in their perceived ability to analyze architectural implications and associated risks.*

Resumo. *A incorporação de sistemas baseados em Inteligência Artificial, especialmente modelos de linguagem de grande escala, tem ampliado o impacto das decisões tomadas no desenvolvimento de software. Profissionais de Produto desempenham papel estratégico nesse processo, mas frequentemente não possuem formação técnica aprofundada sobre esses sistemas. Este trabalho apresenta a criação e a avaliação de um curso de fundamentos computacionais de IA voltado a esse público em contexto industrial. A pesquisa caracteriza-se como um relato de experiência com intervenção formativa de curta duração. A coleta de dados ocorreu por meio de questionários aplicados antes e após o curso. Os resultados indicam aumento na autopercepção de compreensão conceitual e na capacidade percebida de analisar implicações arquiteturais e riscos associados.*

1. Introdução

A disrupção tecnológica provocada pelo uso de Inteligência Artificial (IA), especialmente por meio da IA generativa e dos denominados *Large Language Models* (LLMs), tem redefinido a forma como produtos tecnológicos são concebidos, projetados e avaliados. O

avanço na escala desses modelos, treinados com grandes volumes de dados e bilhões de parâmetros ampliou significativamente sua capacidade de executar diferentes tarefas, favorecendo sua incorporação em produtos e serviços amplamente utilizados no cotidiano [Brown et al. 2020].

Sistemas baseados em LLMs apresentam natureza probabilística e desafios relacionados à rastreabilidade de falhas, avaliação e explicabilidade de seus resultados, ampliando a complexidade de seu desenvolvimento e implantação em contextos organizacionais [Bender et al. 2021, Cooper 2024b]. Nesse cenário, decisões tomadas nas fases iniciais do desenvolvimento, como definição do problema, escolha da abordagem técnica, estabelecimento de métricas de avaliação e definição de níveis de autonomia, influenciam diretamente a arquitetura, o comportamento e os riscos associados ao sistema final. Estudos recentes indicam que grande parte das falhas em projetos de IA não decorre apenas de limitações técnicas, mas também de dificuldades organizacionais relacionadas a expectativas irreais, desalinhamento com necessidades do negócio e fragilidades de governança [Cooper 2024b, Cooper 2026]. À medida que modelos baseados em IA passam a integrar funcionalidades centrais de produtos digitais, torna-se relevante promover uma compreensão mais aprofundada de seu funcionamento e limitações, de modo a qualificar decisões ao longo do ciclo de desenvolvimento [Cooper 2024a, Cooper 2025b].

Diante desse cenário, a formação profissional emerge como elemento relevante para sustentar decisões mais responsáveis em contextos de IA generativa. No Brasil, esse entendimento é reforçado por diretrizes institucionais como a Base Nacional Comum Curricular (BNCC) [Ministério da Educação 2018], que explicita, na área de Computação, a necessidade de analisar potencialidades, riscos e limites da IA [Ministério da Educação 2022], e pela Estratégia Brasileira de Inteligência Artificial (EBIA), que destaca a formação e capacitação de recursos humanos como eixo estruturante para o uso responsável dessas tecnologias [Ministério da Ciência, Tecnologia e Inovações 2021]. Em conjunto, essas diretrizes evidenciam que o avanço da IA depende não apenas da formação de pesquisadores e desenvolvedores, mas também da qualificação de profissionais envolvidos na concepção, gestão e tomada de decisão sobre sistemas baseados em IA.

No contexto industrial, profissionais de Produto, como *Product Owners* (POs), *Product Managers* (PMs), *Product Designers* (PDs) e *Heads* de Produto, ocupam papéis centrais no desenvolvimento de sistemas computacionais, sendo responsáveis por definir problemas, selecionar soluções, estabelecer critérios de qualidade e negociar aspectos como custo, escalabilidade, desempenho e risco. Entretanto, muitos desses profissionais possuem formações provenientes de áreas diversas, frequentemente fora da Tecnologia da Informação. Embora essa diversidade contribua para perspectivas de negócio e visão estratégica, profissionais que atuam em papéis decisórios podem apresentar diferentes níveis de familiaridade com fundamentos computacionais relacionados à IA. Estudos recentes destacam que a alfabetização em IA constitui fator relevante para adoção bem-sucedida dessas tecnologias em contextos organizacionais [Cooper 2025a]. Nesse sentido, compreender potencialidades, limitações e causas recorrentes de falha em projetos de IA torna-se relevante para apoiar decisões estratégicas e reduzir expectativas irreais sobre essas tecnologias [Cooper 2025a, Cooper 2024b].

No âmbito da formação em Engenharia de Software (ES) e da aproximação

com a indústria, estudos recentes têm destacado a relevância de experiências colaborativas entre academia e mercado para a qualificação profissional [Goelzer et al. 2025, Romao et al. 2024]. Entretanto, ainda são escassas propostas formativas direcionadas especificamente a profissionais que ocupam papéis decisórios no desenvolvimento de produtos baseados em IA generativa.

Apesar do crescente interesse organizacional em IA, estimativas indicam que apenas 18%–36% das organizações conseguem alcançar os benefícios esperados de projetos de IA, enquanto cerca de 87% dessas iniciativas nunca chegam à fase de produção [Cooper 2024b]. Esse fenômeno, frequentemente descrito como *pilot paralysis*, ocorre quando projetos permanecem restritos a provas de conceito sem alcançar implantação em escala. Evidências sugerem que muitas dessas falhas decorrem de fatores organizacionais e de gestão, como expectativas irreais, escassez de talentos especializados e ausência de integração entre perspectivas técnicas e de negócio [Cooper 2024b]. O desafio torna-se ainda mais evidente diante do avanço de tecnologias baseadas em IA generativa e agentes de software. Relatórios recentes indicam que mais de 40% dos projetos envolvendo sistemas de *agentic AI* poderão ser cancelados até 2027 devido a custos elevados, valor de negócio pouco claro e controles de risco inadequados [Gartner 2025a]. Além disso, menos de 16% dos líderes de engenharia de software consideram que suas organizações estão preparadas para lidar adequadamente com IA [Gartner 2025b]. Esses resultados reforçam que o sucesso na adoção de soluções baseadas em IA depende não apenas de avanços tecnológicos, mas também da capacidade das organizações de tomar decisões informadas sobre quando e como aplicar essas tecnologias no desenvolvimento de produtos digitais.

Nesse contexto, este trabalho investiga em que medida uma formação estruturada e contextualizada em fundamentos computacionais de IA pode contribuir para ampliar a compreensão técnica de profissionais de Produto sobre funcionamento, limitações e riscos associados aos LLMs, qualificando sua capacidade analítica e apoiando decisões mais conscientes no desenvolvimento de produtos baseados em IA generativa. Para isso, foi desenvolvido, aplicado e avaliado um curso voltado a profissionais que atuam diretamente com soluções baseadas em LLMs, buscando também contribuir para a área de Educação em Computação ao discutir como fundamentos técnicos de IA podem subsidiar formações direcionadas a papéis decisórios no desenvolvimento de sistemas computacionais. O estudo orienta-se pelas seguintes questões de pesquisa:

- **QP1:** A participação no curso promove aumento **percebido** de compreensão conceitual sobre fundamentos de IA e LLMs?
- **QP2:** A formação contribui para ampliar a capacidade **percebida** dos participantes de aplicar conceitos de LLMs na definição de arquitetura, avaliação e tomada de decisão em produtos digitais?
- **QP3:** A formação amplia a consciência dos participantes sobre riscos **técnicos, sociais e regulatórios** associados ao uso de LLMs em produtos?

2. Trabalhos Relacionados

No contexto brasileiro, estudos investigam a inserção de fundamentos de IA na Educação Básica, discutindo integração curricular, formação docente e desafios estruturais [Camada and Durães 2020]. No âmbito da Engenharia de Software e da aproximação

entre academia e indústria, estudos recentes destacam a relevância de experiências colaborativas para a qualificação profissional e o fortalecimento de competências técnicas [Goelzer et al. 2025, Romao et al. 2024]. Essas iniciativas discutem boas práticas, desafios de integração institucional e benefícios da colaboração indústria-academia em contextos reais de desenvolvimento de software.

Também são encontrados relatos de experiência voltados à articulação entre ensino, pesquisa e extensão na formação em Engenharia de Software, evidenciando a importância da integração institucional no desenvolvimento de competências acadêmicas e profissionais [Bordin et al. 2023]. Outros estudos discutem desafios técnicos e organizacionais relacionados à adoção de tecnologias avançadas em contextos empresariais, como iniciativas de democratização do uso de *Big Data* em organizações [Jr. and Souza 2023].

Diferentemente das iniciativas analisadas, que se concentram predominantemente na formação de estudantes ou na aplicação técnica de soluções em contextos educacionais e industriais, o presente trabalho direciona-se a profissionais que já atuam em papéis decisórios estratégicos no desenvolvimento de produtos baseados em IA generativa. A pesquisa foca a qualificação técnica aplicada ao contexto industrial, considerando a centralidade das decisões tomadas por profissionais de Produto nas fases iniciais do ciclo de desenvolvimento. Ao propor e avaliar um curso estruturado em fundamentos computacionais de IA voltado a esse público, o estudo busca ampliar discussões formativas ainda pouco exploradas na literatura nacional, articulando fundamentos técnicos de LLMs, análise de riscos e tomada de decisão estratégica.

3. Contexto da Experiência

A experiência relatada foi desenvolvida em parceria entre a Universidade Federal de Mato Grosso do Sul (UFMS) e a Cortex¹, empresa brasileira de tecnologia especializada em soluções de Inteligência Artificial e análise de dados. A crescente adoção de IA generativa e LLMs na organização evidenciou uma lacuna formativa entre profissionais de Produto, que atuam em decisões estratégicas, mas frequentemente não possuem formação técnica aprofundada sobre sistemas de IA [Cooper 2025a, Cooper 2024b].

A ação de capacitação foi articulada entre a liderança da área de Produto da empresa e a autora principal deste artigo, que atua na firma com o desenvolvimento de produtos baseados em IA e, paralelamente, desenvolve pesquisas no Programa de Mestrado em Ciência da Computação da UFMS. O curso foi estruturado com foco na alfabetização em IA e na tradução de fundamentos computacionais para o contexto de desenvolvimento de produtos digitais. Realizada remotamente, a formação teve duração total de três horas, distribuídas em dois encontros síncronos, e contou com a participação voluntária de 15 profissionais. A caracterização sociodemográfica desses participantes é apresentada na Tabela 1.

A avaliação da experiência ocorreu por meio de questionários aplicados antes e após a formação, analisando a percepção dos participantes sobre compreensão conceitual e aplicação de IA e LLMs no contexto de Produto. Os dados foram tratados de forma agregada e anonimizada, com consentimento formal dos participantes para uso acadêmico das informações.

¹<https://www.cortex-intelligence.com>

Tabela 1. Perfil Sociodemográfico dos Participantes

Variável	Distribuição
Gênero	Masculino: 4 (40%); Feminino: 6 (60%)
Faixa etária	Até 24: 1 (10%); 25–34: 6 (60%); 35–44: 2 (20%); 45–54: 1 (10%)
Escolaridade	Superior: 6 (60%); Pós-graduação: 4 (40%)
Área de atuação	Produto: 6 (60%); Design: 4 (40%)
Cargo	PO: 5 (50%); Designer: 4 (40%); Head: 1 (10%)
Experiência	2–5 anos: 1 (10%); 6–10 anos: 4 (40%); Acima de 10 anos: 5 (50%)
Formação	Design: 6 (60%); Tecnologia: 2 (20%); Comunicação: 1 (10%); Arquitetura: 1 (10%)

4. Estrutura Curricular

A formação foi organizada em dois encontros síncronos estruturados de forma progressiva: (i) fundamentos técnicos de IA e LLMs e (ii) aplicação desses fundamentos à tomada de decisão arquitetural no contexto de Produto.

A primeira aula concentrou-se na construção de base conceitual. Foram apresentados fundamentos de IA, *Machine Learning* (ML) e *Deep Learning* (DL), bem como métricas clássicas de avaliação de modelos. Em seguida, discutiu-se o funcionamento interno dos LLMs, abordando tokenização, embeddings, mecanismo de atenção, janela de contexto e aspectos probabilísticos da inferência, além de limitações típicas de sistemas generativos, como alucinação.

Esse módulo foi fundamentado em literatura clássica da área, incluindo Russell e Norvig [Russell and Norvig 2009], Mitchell [Mitchell 1997] e Bishop [Bishop 2006], entre outras referências consolidadas [Flach 2012, Haykin 2008, Anthony and Bartlett 2009]. O objetivo foi apresentar princípios formais de modelagem e avaliação de forma acessível ao contexto de desenvolvimento de produtos baseados em IA.

A segunda aula foi orientada à análise arquitetural e discussão de *trade-offs*. Foram exploradas diferentes estratégias de uso de LLMs, incluindo modelos paramétricos, arquiteturas baseadas em recuperação de informação (RAG), fine-tuning e sistemas multi-agente. A discussão sobre RAG baseou-se em Lewis et al. [Lewis et al. 2020], enquanto a avaliação de sistemas generativos dialogou com propostas como o framework RAGAS [Es et al. 2024] e o paradigma *LLM-as-a-Judge* [Li et al. 2025].

Também foram discutidos aspectos práticos relacionados à integração de ferramentas externas, *function calling*, observabilidade e governança de sistemas baseados em LLMs [OpenAI 2024]. Reflexões sobre viés e riscos sociais dialogaram com discussões recentes sobre linguagem, poder e riscos de modelos de larga escala [Blodgett et al. 2020, Bender et al. 2021].

A estrutura curricular buscou conectar fundamentos técnicos a decisões típicas do contexto de Produto, como escolha de arquitetura, definição de métricas de sucesso e gestão de riscos técnicos e reputacionais. A Tabela 2 sintetiza os módulos do curso e suas relações com decisões estratégicas.

5. Abordagem Didática

A abordagem didática adotada foi orientada pela contextualização aplicada, buscando reduzir abstrações excessivas e conectar fundamentos técnicos ao processo decisório no

Tabela 2. Estrutura dos Módulos do Curso

Módulo	Conteúdo Técnico	Conexão com Produto
Parte 1 (Fundamentos)	IA, ML e DL; aprendizado supervisionado e não supervisionado; métricas (acurácia, precisão, recall, F1); tokenização, embeddings, atenção, janela de contexto; inferência probabilística (temperatura, top-k, top-p); limitações e alucinação.	Definição de critérios de qualidade; escolha de métricas adequadas; compreensão de variação de resposta; previsão de ciclos de experimentação; definição de limites e expectativas realistas.
Parte 2 (Arquitetura e Decisão)	LLM puro vs RAG vs fine-tuning vs agentes; tools e function calling; chunking e busca vetorial; métricas RAG (RAGAS); avaliação humana vs automática; observabilidade e logging; custos por token; guardrails e ética.	Escolha de arquitetura; análise de trade-offs entre custo, latência e qualidade; definição de governança e controle de autonomia; mitigação de risco técnico e reputacional; planejamento de escalabilidade.

contexto de Produto. Os conceitos foram apresentados a partir de situações concretas, como definição de métricas de sucesso, escolha entre alternativas arquiteturais (LLM puro versus RAG), análise de trade-offs entre custo, latência e qualidade e avaliação de riscos associados à alucinação em sistemas generativos.

As aulas combinaram exposição conceitual estruturada com discussão orientada, promovendo análise comparativa entre estratégias técnicas (ex.: fine-tuning versus RAG; modelo único versus arquiteturas baseadas em agentes) e suas implicações operacionais, incluindo escalabilidade, observabilidade, monitoramento e controle de autonomia. O objetivo foi explicitar as consequências sistêmicas de decisões técnicas no desempenho e na governança do produto.

Além da dimensão técnica, a formação incorporou reflexões sobre ética, vies algorítmico, responsabilidade organizacional e necessidade de *guardrails* arquiteturais. O propósito central não foi capacitar os participantes para implementar modelos, mas fortalecer sua capacidade analítica para a tomada de decisão informada ao longo do desenvolvimento de soluções baseadas em IA.

6. Procedimentos de Avaliação

A avaliação foi realizada por meio de um questionário composto por 51 itens organizados em quatro dimensões: (i) fundamentos técnicos de IA e LLMs, (ii) aplicação no contexto de Produto, (iii) arquitetura de sistemas baseados em LLMs e (iv) riscos, governança e aspectos regulatórios. As respostas foram coletadas por meio de uma escala Likert de cinco pontos, variando de 1 (total discordância/insatisfação) a 5 (total concordância/satisfação). O instrumento completo encontra-se disponível em material suplementar².

O questionário foi aplicado em dois momentos (pré e pós-curso) para capturar o conhecimento percebido dos participantes em relação aos conteúdos abordados. A participação foi voluntária e anônima. Dez participantes responderam a ambos os questionários e consentiram com o uso dos dados exclusivamente para fins acadêmicos.

²Os materiais utilizados e os dados anonimizados coletados neste trabalho estão disponíveis no repositório do estudo em <https://github.com/firminovitoria/llm-foundations-product-education/tree/main>.

Como complemento à análise quantitativa, o questionário pós-curso incluiu uma questão aberta opcional sobre a contribuição da formação para o entendimento de IA e LLMs no contexto de Produto. Duas respostas foram registradas, destacando a utilidade da formação para esclarecer conceitos fundamentais, compreender diferentes abordagens de modelos e agentes e tornar conceitos técnicos mais acessíveis a profissionais com menor familiaridade com o tema.

Embora limitados em número, esses relatos qualitativos complementam os resultados quantitativos apresentados nas subseções seguintes. Ressalta-se que os resultados representam medidas de autopercepção de conhecimento e não constituem mensuração objetiva de desempenho técnico dos participantes.

6.1. QP1: Compreensão Conceitual

Para avaliar o aumento percebido de compreensão conceitual, foram analisados dois itens representativos da dimensão de fundamentos técnicos. No item referente à distinção entre IA, ML, DL e IA Generativa, observou-se aumento da média de 2,80 (pré) para 4,10 (pós), representando variação positiva de 1,30 pontos na escala Likert. A proporção de respostas em níveis de concordância (parcial ou total) passou de 30% para 90%.

No que se refere à clareza sobre conceitos internos de LLMs (tokens, contexto, janela de contexto e atenção), a média evoluiu de 3,70 para 4,20, com aumento de 0,50 pontos e elevação da concordância de 50% para 90%.

Os resultados indicam aumento consistente na autopercepção de compreensão conceitual, sugerindo que a formação contribuiu para fortalecer fundamentos técnicos essenciais ao entendimento de sistemas baseados em LLMs. A Tabela 3 apresenta a variação das médias para os itens representativos da QP1.

Tabela 3. Resultados da QP1 – Compreensão Conceitual

Item Avaliado	Pré	Pós	Δ
Diferença entre IA, ML, DL e IA Generativa	2,80	4,10	+1,30
Clareza sobre tokens, janela de contexto e atenção	3,70	4,20	+0,50

6.2. QP2: Aplicação e Tomada de Decisão

A segunda questão de pesquisa investigou se a formação contribuiu para ampliar a capacidade percebida dos participantes de aplicar conceitos de LLMs na definição de arquitetura, avaliação e tomada de decisão em produtos digitais.

Observou-se crescimento consistente em itens diretamente associados ao julgamento estratégico. A média referente à tradução de fundamentos técnicos para decisões de Produto evoluiu de 3,20 para 3,80 (+0,60). A capacidade de identificar situações em que o uso de LLMs não é adequado apresentou aumento de 3,30 para 3,80 (+0,50). Já a avaliação de trade-offs entre complexidade arquitetural e valor de negócio mostrou crescimento moderado, passando de 2,60 para 3,20 (+0,60).

Entretanto, os maiores incrementos absolutos da dimensão foram observados em tópicos estruturais de arquitetura e avaliação técnica. A compreensão sobre pré-treinamento e fine-tuning apresentou variação de 2,10 para 4,20 (+2,10), enquanto a clareza sobre quando e por que utilizar RAG evoluiu de 1,30 para 3,70 (+2,40). De forma

semelhante, o entendimento sobre métricas clássicas de avaliação de modelos de Machine Learning aumentou de 1,50 para 3,60 (+2,10), e o conceito de LLM-as-a-Judge apresentou incremento de 1,80 para 3,70 (+1,90).

Os resultados indicam que a intervenção impactou de maneira particularmente expressiva conteúdos relacionados à engenharia aplicada, escolha arquitetural e avaliação de modelos generativos, competências centrais para decisões responsáveis em produtos baseados em IA. Diferentemente da dimensão puramente conceitual (QP1), nesta dimensão observou-se não apenas aumento incremental, mas mudanças estruturais em tópicos que inicialmente apresentavam elevado grau de desconhecimento.

Tabela 4. Resultados da QP2 – Aplicação Arquitetural e Tomada de Decisão

Item Avaliado	Pré	Pós	Δ
Traduzir conceitos técnicos para decisões de produto	3,20	3,80	+0,60
Identificar quando não utilizar LLM como solução	3,30	3,80	+0,50
Avaliar trade-offs arquiteturais vs valor de negócio	2,60	3,20	+0,60
Compreensão de pré-treinamento e fine-tuning	2,10	4,20	+2,10
Clareza sobre quando utilizar RAG	1,30	3,70	+2,40
Conhecimento sobre métricas clássicas de ML	1,50	3,60	+2,10
Compreensão do conceito de LLM-as-a-Judge	1,80	3,70	+1,90

6.3. QP3: Riscos Técnicos, Sociais e Regulatórios

A dimensão de riscos apresentou médias relativamente elevadas já no momento pré-curso, indicando sensibilidade inicial dos participantes ao tema. Ainda assim, observou-se aumento consistente após a formação.

A identificação de riscos sociais e reputacionais evoluiu de 3,60 para 4,30 (+0,70). No que se refere à clareza sobre implicações de LGPD e regulações emergentes para produtos baseados em IA, a média passou de 3,70 para 4,20 (+0,50).

Destaca-se ainda o item referente à compreensão da variabilidade de respostas em LLMs, aspecto central para avaliação de risco técnico. A média evoluiu de 3,40 para 4,60 (+1,20), representando um dos maiores incrementos observados no instrumento.

Os resultados sugerem fortalecimento não apenas da consciência regulatória e social, mas também da compreensão dos riscos operacionais inerentes ao caráter probabilístico de sistemas baseados em LLMs.

Tabela 5. Resultados da QP3 – Riscos Técnicos, Sociais e Regulatórios

Item Avaliado	Pré	Pós	Δ
Identificação de riscos sociais e reputacionais	3,60	4,30	+0,70
Clareza sobre LGPD e regulações emergentes	3,70	4,20	+0,50
Compreensão da variabilidade de respostas em LLMs	3,40	4,60	+1,20

7. Reflexão Crítica

Os resultados indicam que intervenções formativas curtas podem produzir impactos relevantes na autopercepção de conhecimento técnico quando direcionadas a lacunas claramente identificadas no contexto organizacional. Observou-se que os maiores incrementos

ocorreram em conteúdos estruturais de arquitetura e avaliação de modelos generativos, como pré-treinamento, fine-tuning e o uso de arquiteturas baseadas em recuperação de informação (RAG). Esses tópicos apresentavam baixo domínio inicial e registraram as maiores variações pós-intervenção, sugerindo que a formação atuou diretamente sobre lacunas técnicas relevantes para o contexto decisório.

Outro aprendizado relevante foi a diferença de magnitude entre dimensões. Enquanto a compreensão conceitual (QP1) apresentou crescimento consistente, a dimensão de aplicação estratégica (QP2) revelou incrementos particularmente expressivos em tópicos relacionados à engenharia de sistemas baseados em LLMs. Conceitos como RAG, fine-tuning e métricas clássicas de avaliação de modelos apresentaram os maiores ganhos absolutos, indicando que esses conteúdos eram pouco familiares aos participantes antes da formação. Por outro lado, aspectos relacionados ao julgamento arquitetural e à análise de trade-offs entre valor de negócio e complexidade técnica apresentaram crescimento mais moderado, sugerindo que competências decisórias tendem a demandar maior exposição prática e tempo de maturação.

Na dimensão de riscos (QP3), verificou-se fortalecimento não apenas da consciência regulatória, mas também da compreensão do caráter probabilístico dos modelos, elemento central para gestão de risco em sistemas baseados em LLMs. O aumento na clareza sobre a variabilidade de respostas em modelos generativos indica avanço na compreensão de limitações operacionais desses sistemas. Esse resultado reforça a importância de integrar fundamentos técnicos e reflexão crítica em formações voltadas a profissionais de Produto.

7.1. Dificuldades

Uma das principais limitações da experiência refere-se ao tamanho reduzido da amostra, o que restringe a possibilidade de generalizações estatísticas. Além disso, a avaliação baseou-se em medidas de autopercepção de conhecimento, não havendo mensuração objetiva de desempenho técnico ou aplicação prática dos conceitos aprendidos. Outra dificuldade identificada foi o desafio de equilibrar profundidade técnica e aplicabilidade prática em um formato de curta duração (três horas distribuídas em dois encontros). A natureza probabilística e arquitetural dos LLMs exige a introdução de conceitos que não fazem parte do repertório tradicional de profissionais com formações predominantemente não técnicas, demandando esforço adicional de tradução didática para tornar esses conteúdos compreensíveis e relevantes para o contexto de tomada de decisão em Produto.

7.2. Trabalhos Futuros

Como desdobramento da experiência, sugere-se ampliar a carga horária da formação e incorporar atividades práticas estruturadas, como análise de casos reais, simulações de decisão arquitetural e exercícios comparativos entre diferentes estratégias de uso de LLMs. Também se propõe a adoção de uma avaliação híbrida, combinando instrumentos de autopercepção com atividades aplicadas que permitam observar mudanças comportamentais ou decisórias ao longo do tempo.

Adicionalmente, vislumbra-se ampliar o tamanho e a diversidade da amostra, bem como replicar o estudo em múltiplas turmas do curso, o que possibilitaria análises mais robustas sobre os efeitos da formação. A inclusão de profissionais de outros papéis relacionados também pode permitir comparações entre diferentes perfis profissionais.

Por fim, considerando a parceria com uma organização do setor privado, um caminho promissor consiste em investigar o impacto da formação no contexto organizacional ao longo do tempo, analisando possíveis efeitos nas decisões relacionadas ao uso de LLMs em produtos digitais.

8. Conclusão

Este trabalho apresentou o desenvolvimento, aplicação e avaliação de um curso de fundamentos computacionais de IA voltado a profissionais de Produto atuantes em uma organização do setor de tecnologia. A iniciativa partiu da identificação de lacunas formativas relacionadas à compreensão técnica de modelos baseados em LLMs, especialmente diante da crescente incorporação dessas tecnologias em funcionalidades centrais de produtos digitais.

Os resultados indicaram aumento consistente na autopercepção de compreensão conceitual sobre fundamentos de IA e LLMs. Observou-se impacto particularmente expressivo em tópicos estruturais relacionados à arquitetura e avaliação de sistemas generativos, como pré-treinamento, fine-tuning, uso de RAG e métricas clássicas de avaliação de modelos. Também foram identificados avanços na capacidade percebida de analisar implicações arquiteturais e reconhecer limitações e riscos associados ao uso de LLMs em produtos digitais.

Na dimensão de riscos, verificou-se fortalecimento da consciência regulatória e social, bem como maior compreensão do caráter probabilístico desses modelos, aspecto central para a gestão de risco em sistemas baseados em IA generativa. Esses resultados sugerem que intervenções formativas direcionadas podem contribuir para qualificar decisões técnicas e estratégicas no desenvolvimento de produtos que incorporam essas tecnologias.

Como contribuição, o estudo evidencia o potencial de iniciativas de integração entre academia e indústria na qualificação técnica de profissionais que ocupam papéis decisórios no ciclo de desenvolvimento de produtos digitais. Ao articular fundamentos computacionais de IA com responsabilidades estratégicas do contexto de Produto, a experiência reforça a importância de iniciativas educacionais que aproximem conhecimentos técnicos de IA das decisões envolvidas no desenvolvimento de sistemas computacionais, promovendo práticas mais conscientes, tecnicamente fundamentadas e alinhadas a princípios de responsabilidade e governança.

Agradecimentos

O presente trabalho foi realizado com o apoio da Universidade Federal de Mato Grosso do Sul e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Uso de IA generativa

O uso de ferramentas de IA generativa na escrita deste trabalho restringiu-se exclusivamente ao aprimoramento linguístico do texto, incluindo reescrita, parafraseamento e lapidação da redação produzida pelos autores. Nenhuma dessas ferramentas foi empregada para sugerir, gerar ou desenvolver novo conteúdo intelectual, limitando-se a funções análogas às de corretores gramaticais, ortográficos ou dicionários.

Referências

- Anthony, M. and Bartlett, P. L. (2009). *Neural Network Learning: Theoretical Foundations*. Cambridge University Press.
- Bender, E. M., Gebru, T., McMillan-Major, A., and Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAcCT)*, pages 610–623.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Blodgett, S. L., Barocas, S., III, H. D., and Wallach, H. (2020). Language (technology) is power: A critical survey of “bias” in nlp. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics (ACL)*, pages 5454–5476.
- Bordin, A., Rodrigues, L., and Casagrande, T. (2023). Ensino, pesquisa e extensão no ensino de engenharia de software: Um relato de experiência. In *Anais do XXXI Workshop sobre Educação em Computação*, pages 30–40, Porto Alegre, RS, Brasil. SBC.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I., and Amodei, D. (2020). Language models are few-shot learners.
- Camada, M. and Durães, G. (2020). Ensino da inteligência artificial na educação básica: um novo horizonte para as pesquisas brasileiras. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1553–1562, Porto Alegre, RS, Brasil. SBC.
- Cooper, R. G. (2024a). The coming ai wave: The impact on product development in engineering management. *IEEE Engineering Management Review*, 52(3):17–26.
- Cooper, R. G. (2024b). Why ai projects fail: Lessons from new product development. *IEEE Engineering Management Review*, 52(4):15–21.
- Cooper, R. G. (2025a). The adoption and impact of ai by smes for new product development. *IEEE Engineering Management Review*, 53(4):48–54.
- Cooper, R. G. (2025b). The npd game is won or lost in the first five plays: How ai can help in product innovation. *IEEE Engineering Management Review*, 53(6):9–17.
- Cooper, R. G. (2026). Driving business value: A strategic framework for ai adoption and deployment success. *IEEE Engineering Management Review*, pages 1–19.
- Es, S., James, J., Anke, L. E., and Schockaert, S. (2024). Ragas: Automated evaluation of retrieval augmented generation. In *Proceedings of the 18th Conference of the European Chapter of the Association for Computational Linguistics: System Demonstrations*, pages 150–158. Association for Computational Linguistics.
- Flach, P. (2012). *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press.
- Gartner (2025a). Gartner predicts over 40 percent of agentic ai projects will be canceled by end of 2027.

- Gartner (2025b). Software engineering 2030: The impact of ai. <https://www.gartner.com/en/software-engineering/insights/software-engineering-2030-impact-of-ai>. Gartner Business and Technology Insights eBook, Accessed: 10 Mar. 2026.
- Goelzer, N., Possamai, P., and Marczak, S. (2025). Do's and don'ts of partnering with industry to educate software engineering students: Recommendations based on a teaching experience. In *Anais do XXXIX Simpósio Brasileiro de Engenharia de Software*, pages 577–587, Porto Alegre, RS, Brasil. SBC.
- Haykin, S. (2008). *Neural Networks and Learning Machines*. Prentice Hall, 3 edition.
- Jr., A. K. and Souza, A. (2023). Democratização do uso de big data: um relato de experiência em empresa de grande porte do ramo varejista. In *Anais da VII Escola Regional de Engenharia de Software*, pages 318–327, Porto Alegre, RS, Brasil. SBC.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., tau Yih, W., Rocktäschel, T., Riedel, S., and Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. In *Proceedings of the 34th International Conference on Neural Information Processing Systems (NeurIPS)*. Curran Associates Inc.
- Li, D., Jiang, B., Huang, L., Beigi, A., Zhao, C., Tan, Z., Bhattacharjee, A., Jiang, Y., Chen, C., Wu, T., Shu, K., Cheng, L., and Liu, H. (2025). From generation to judgment: Opportunities and challenges of llm-as-a-judge. In *Proceedings of the 2025 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Association for Computational Linguistics.
- Ministério da Ciência, Tecnologia e Inovações (2021). Estratégia Brasileira de Inteligência Artificial. <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/inteligencia-artificial>. Acesso em: 19 fev. 2026.
- Ministério da Educação (2018). Base Nacional Comum Curricular. <https://basenacionalcomum.mec.gov.br/>. Acesso em: 19 fev. 2026.
- Ministério da Educação (2022). Base Nacional Comum Curricular – Computação. <https://www.gov.br/mec/pt-br/escolas-conectadas/BNCCComputaoCompletoDiagramado.pdf>. Acesso em: 19 fev. 2026.
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- OpenAI (2024). Openai api documentation. <https://platform.openai.com/docs>. Accessed: 28-Feb-2026.
- Romao, L., Kalinowski, M., Barbosa, C., Araújo, A., Barbosa, S., and Lopes, H. (2024). Agile minds, innovative solutions, and industry-academia collaboration: Lean rd meets problem-based learning in software engineering education. In *Anais do XXXVIII Simpósio Brasileiro de Engenharia de Software*, pages 346–356, Porto Alegre, RS, Brasil. SBC.
- Russell, S. and Norvig, P. (2009). *Artificial Intelligence: A Modern Approach*. Pearson, 3 edition.