

MODELOS DE LINGUAGEM DE LARGA ESCALA (LLMs): IMPULSIONANDO A REVOLUÇÃO DA INTELIGÊNCIA ARTIFICIAL NO CAMPO

Ruy de Oliveira

Instituto Federal de Mato Grosso (IFMT)
ruy.oliveira@ifmt.edu.br - <http://lattes.cnpq.br/4757935695805250>

Matheus Cândido Teixeira

Instituto Federal de Mato Grosso (IFMT)
matheus.candido@ifmt.edu.br - <http://lattes.cnpq.br/0915261538773931>

Resumo: A Inteligência Artificial (IA) avança em múltiplas áreas, e sua aplicação na agricultura tem grande margem para crescimento, dada a variedade de processos produtivos que podem ser aprimorados com essa tecnologia. No entanto, diversas soluções exigem a coleta de grandes volumes de dados específicos do domínio de interesse, além de conhecimento técnico especializado, o que tem, aparentemente, limitado o aproveitamento pleno dos benefícios da IA no setor. Uma alternativa promissora é o uso dos Modelos de Linguagem em Larga Escala (*Large Language Models* - LLMs), que são pré-treinados com extensos volumes de dados, tornando-os capazes de gerar textos, traduzir textos, responder a perguntas, entre outras tarefas importantes. Os LLMs simplificam a interação entre usuário e máquina, à medida que esses modelos podem interpretar comandos em linguagem natural e imediatamente executar as tarefas correspondentes. Este trabalho avalia preliminarmente o potencial dos LLMs em aplicações dentro da agricultura. Abordam-se sucintamente os principais modelos disponíveis, destacando suas funcionalidades mais relevantes, bem como os principais domínios de interesse dentro do setor agrícola.

Palavras-chave: Inteligência Artificial. Agricultura inteligente. LLMs. Aprendizado de máquina.

Abstract: Artificial Intelligence (AI) is advancing across multiple fields, and its application in agriculture has significant room for growth, given the variety of production processes that can be enhanced with this technology. However, many solutions require the collection of large volumes of domain-specific data, as well as specialized technical expertise, which appears to be hindering the full adoption of AI's benefits in the sector. A promising alternative is the use of Large Language Models (LLMs), which are pre-trained on vast datasets, enabling them to generate text, translate languages, answer questions, among other important tasks. LLMs simplify human-machine interaction by interpreting natural language commands and executing corresponding tasks immediately. This work provides a preliminary assessment of the potential of LLMs in agricultural applications. It briefly outlines the main available models, highlighting their

key functionalities, as well as the primary domains of interest within the agricultural sector.

Keywords: *Artificial Intelligence. Smart Agriculture. LLMs. Machine Learning.*

INTRODUÇÃO

Os altos índices de competitividade global, entre outros fatores, demandam que a agricultura moderna, incluindo as tecnologias da chamada agricultura 4.0, produza resultados cada vez mais eficientes, inovadores e sustentáveis. Por isso, nos últimos anos, uma variedade significativa de tecnologias avançadas vem sendo gradativamente adotada no campo, e a Inteligência Artificial (IA) se destaca como uma solução promissora para revolucionar o trabalho nessa área, originando a chamada agricultura inteligente. Os benefícios da IA para a agricultura são amplos, incluindo suporte para tomada de decisão assertiva, consolidação da agricultura de precisão, evolução da automação (drones, máquinas autônomas, etc.), aumento de produtividade, entre outros.

O termo inteligência artificial é amplo e subdivide-se em várias vertentes. Uma dessas vertentes é a Aprendizagem Profunda (*Deep Learning* - DL), a qual se sobressai em várias áreas, incluindo o setor da agricultura. Embora a DL consiga prover resultados satisfatórios em muitas aplicações, o seu desempenho depende de longos treinamentos com grandes bases de dados. Dessa forma, a adoção da DL implica custos elevados e a necessidade de mão de obra altamente especializada, o que certamente dificulta a disseminação dessa abordagem no setor da agricultura.

Impulsionados por essas limitações da DL, os Modelos de Linguagem de Larga Escala (*Large Language Models* - LLMs) emergem como uma alternativa interessante para o setor, visto que eles oferecem interface interativa com o usuário e aceitam comandos em linguagem natural, aproximando-os do usuário que não dispõe de conhecimentos aprofundados no assunto.

Os LLMs ganharam notoriedade com o lançamento do ChatGPT em 2022, mas a fundação para o desenvolvimento desses modelos, materializada por meio da arquitetura denominada *Transformer*, foi criada

pela gigante Google em 2017. Atualmente, além do ChatGPT, desenvolvido pela empresa OpenAI, outros modelos de LLM populares incluem Gemini (Google), LLaMA (META), Claude (Anthropic) e DeepSeek (DeepSeek AI) (Aydin, 2025).

O extraordinário avanço alcançado pelos LLMs não tem precedente na história da IA. Esses modelos tornaram possível ao usuário comum desfrutar de um modelo computacional inteligente, pré-treinado numa massa astronômica de dados, para simplificar a realização das mais variadas tarefas, como consultar informações sobre assuntos diversos, realizar tradução de documentos, gerar códigos de linguagens de programação e resumir textos. Conforme explicado mais adiante, os LLMs estão evoluindo para processar dados multimodais, habilitando-os para lidar com dados na forma não apenas textual, mas também imagem, áudio e vídeo (Huang, 2024; Naveed, 2025).

Este artigo apresenta um breve relato de como os LLMs podem revolucionar o trabalho no campo, sobretudo os processos envolvidos na produção agrícola. Os principais modelos de LLMs da atualidade são descritos e comparados. As aplicações emergentes dos LLMs no setor agrícola são discutidas, e algumas delas são explanadas por meio de exemplos práticos implementados. Por fim, aspectos importantes da integração dos LLMs na realidade rural são abordados na perspectiva de que as vantagens e os desafios desse cenário fiquem evidentes.

1. DESENVOLVIMENTO

1.1 Modelos de Linguagem de Larga Escala - LLMs

Os modelos inteligentes pré-treinados, inerentes aos LLMs, estão revolucionando profundamente a área da inteligência artificial. Os avanços proporcionados pelos LLMs em relação aos algoritmos clássicos de DL são notáveis, não apenas pela abrangência dos LLMs em vários domínios, mas também pela forma “autônoma” com que esses grandes modelos são treinados. Enquanto os modelos tradicionais de DL dependem de dados rotulados (Sun *et al.*, 2017, p. 845), os LLMs não neces-

sitam de rótulos para serem treinados. A dispensa de rotulação é vantajosa, já que rotular dados para treinamento de IA requer tempo e conhecimento especializado. O fato de depender de dados rotulados implica dizer que os LLMs são treinados de modo não supervisionado ou auto-supervisionado.

Dependendo do tamanho da base de dados a ser rotulada, o processo torna-se inviável, e assim surgiram os LLMs, que são treinados com vasta base de dados disponível na internet, incluindo páginas da web, Wikipedia, livros, notícias, redes sociais, artigos científicos, códigos de programação, entre outros. Dessa forma, esses modelos adquirem conhecimento abrangente em diversos domínios (Raiaan *et al.*, 2024, p. 26840; Xiong *et al.*, 2024, p. 4558).

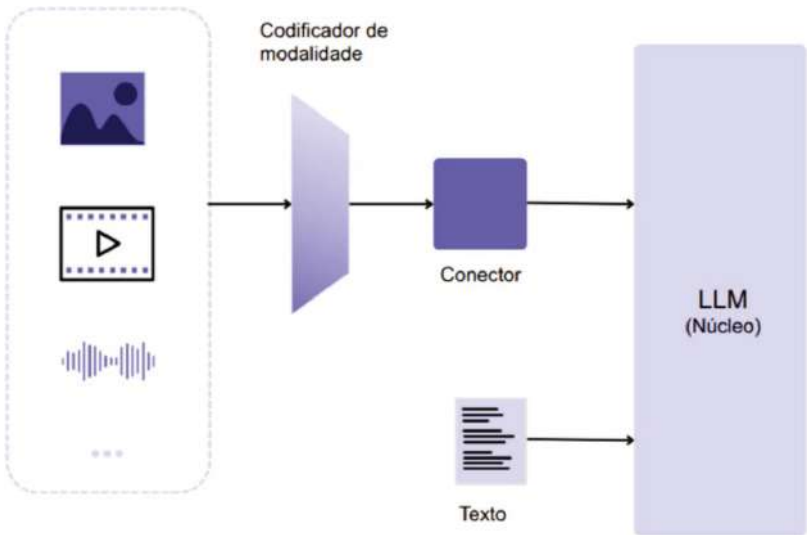
É importante ressaltar que os LLMs são algoritmos avançados de processamento de linguagem natural, desenvolvidos para aproximar a IA do modo como os seres humanos se comunicam. Os modelos de LLM tradicionais recebem dados em linguagem natural (linguagem usada pelos seres humanos), inclusive em vários idiomas, e retornam seus resultados também em linguagem natural. Portanto, além de processar textos, esses modelos também geram textos, e por isso incluem funcionalidades da chamada IA generativa, o que lhes confere a prerrogativa de gerar textos com alta qualidade linguística. A qualidade desses textos depende, naturalmente, da qualidade do treinamento dos modelos, incluindo as bases de dados utilizadas.

Mais recentemente, alguns modelos de LLMs incorporaram a capacidade de trabalhar com imagens, inclusive com geração de imagens, caracterizando-se como LLMs multimodais (MLLM). Em outras palavras, pode-se dizer que os sistemas LLMs atuais foram expandidos para processar dados multimodais. Então, além de textos, esses modelos já podem também desempenhar tarefas que requeiram o entendimento e a geração de dados não textuais como imagem, áudio e vídeo (Huang, 2024).

Como ilustrado na Figura 1, o núcleo do LLM, que opera com texto na sua entrada, necessita de um Codificador de modalidade para integrar todas as modalidades de dados não textuais. Os dados na saída desse codificador contêm as características (*features*) representativas das infor-

mações não textuais, as quais são adequadamente convertidas para a forma de texto pelo bloco Conector.

Figura 1 - LLMs com dados de entrada Multimodal



Fonte: Adaptado de Tenyks, 2024.

A implementação mais famosa dos LLMs é certamente o ChatGPT, o qual surpreendeu o mundo em 2022 ao atingir a marca de 1 milhão de usuários em apenas cinco dias após seu lançamento, e alcançar 100 milhões em apenas dois meses. No entanto, há outros exemplos de LLM que também evoluíram e estão se tornando populares por apresentarem desempenho e funcionalidades similares, ou mesmo superiores, aos do ChatGPT. Em especial, a implementação Deepseek, lançada em janeiro de 2025, ganhou destaque no seu lançamento, por oferecer um modelo de código aberto, que alcança desempenho similar ao do seu famoso antecessor e foi construído a um custo muito menor. O Quadro 1 resume aspectos importantes de cinco das implementações de LLM mais populares da atualidade.

Quadro 1 - Comparação dos modelos de LLM

Atributo	ChatGPT4o	Gemini 2.0 Flash	Claude 3.7	LLaMA 4**	DeepSeek V3.6
Lançamento	Mai 2024	Abr. 2025	Fev. 2025	Abr. 2025	Jan. 2025
Desenvolvedor	Open AI	Google	Anthropic	Meta	DeepSeek AI
Diferencial	Interação por voz muito rápido	Integração nativa com ferramenta de busca	Inferência híbrida**	Combinação de especialistas^	Destaque com código e matemática
Tamanho do contexto*	128K	1 milhão	200K	1 milhão	128K
Qtidade de parâmetros*^	1,8 trilhão	40 Bilhões	100 bilhões	400 bilhões	671 bilhões
Entrada	Texto, imagem, áudio, vídeo	Texto, imagem, áudio, vídeo	Texto, imagem	Texto, imagem	Texto
Open source	Não	Não	Não	Sim	Sim

Fonte: Elaborado pelos autores.

Qtidade de parâmetros*^: quantidade de *tokens* (palavras) que o modelo pode receber de uma só vez e processar.

Tamanho de contexto*: refere-se a uma estiva porque alguns dos desenvolvedores não divulgam essas informações.

Inferência híbrida:** mecanismo de chaveamento entre tarefas simples e complexas visando à melhor interatividade.

Combinação de Especialistas^: arquitetura que provê resultado eficiente com menor demanda computacional.

Os dados do Quadro 1 mostram o quão dinâmicos esses modelos são. Dos cinco modelos apresentados, apenas o ChatGPT 4o ainda não tem atualização do ano de 2025. Observa-se também que a quantidade de parâmetros dos modelos, os quais são aprendidos durante o treinamento, também é astronômica. Por isso, os LLMs normalmente são treinados por grandes corporações, conforme indicado na Tabela 1, e posteriormente disponibilizados como modelos pré-treinados para o público. Pode-se ainda notar no Quadro 1 que, atualmente, apenas as implementações ChatGPT 4o e Gemini 2.0 Flash aceitam dados de entrada nas modalidades de texto, imagem, áudio e vídeo. No entanto, os demais desenvolvedores (corporações) estão trabalhando ativamente para brevemente disponibilizarem essas funcionalidades também.

Para que os benefícios dos LLMs possam ser explorados de forma plena, seus algoritmos devem ser instalados em máquinas locais. Nesse arranjo, códigos abertos (*open-sources*) podem ser utilizados, possibilitando o ajuste fino (refinamento) dos LLMs, no sentido de personalizar a implementação para as necessidades de cada usuário.

Em decorrência dessa necessidade, nos últimos anos, uma quantidade significativa de ferramentas foi criada, entre as quais se destaca a Ollama, juntamente com a LangChain. A Ollama simplifica o processo de instalação dos modelos de LLM localmente, e a LangChain possibilita a integração desses modelos com as aplicações (Liu; Kang; Han, 2024). Ainda há ferramentas como Axolotl, Unsloth e MLX que podem ser usadas para o refinamento desses modelos (Mangena, 2025). Essas plataformas impulsionam a disseminação dos LLMs, ao torná-los mais acessíveis e fáceis de usar, mesmo para usuários com pouca qualificação no tema. Assim, todo o poder da inteligência artificial dos LLMs pode ser facilmente acessado e usufruído, nas mais diversas áreas do conhecimento.

1.2 Modelos de Linguagem de Larga Escala na agricultura

Conforme mencionado anteriormente, atualmente já há muitos processos produtivos no campo que estão sendo conduzidos por algoritmos de inteligência artificial. Os grandes fabricantes mundiais de maquinário agrícola já estão progressivamente embarcando algoritmos de IA em seus equipamentos, impulsionando a era da agricultura digital (Jorge, 2024, p. 58). A Figura 2 exhibe algumas áreas em que a IA já está revolucionando o trabalho no campo.

No entanto, a fim de explorar em mais detalhes como a IA está transformando o setor da agricultura, destacam-se as seguintes aplicações emergentes: i) máquinas modernas, como as colheitadeiras e os tratores, que utilizam IA para navegação autônoma via GPS, com sensores e câmeras integrados que auxiliam na identificação de culturas e no monitoramento do solo; ii) robôs para plantio, colheita e remoção de ervas daninhas; iii) drones agrícolas para monitoramento do plantio, identificação de pragas e doenças, pulverização e análise de solo; iv) sistemas de irrigação automatizados que otimizam o uso da água com base em fatores ambientais; v) soluções avançadas de agricultura de precisão para otimizar a produção agrícola através da análise preditiva de safras e da gestão eficiente de insumos.

A literatura recente mostra que muitos desses processos podem ser aprimorados com o emprego dos LLMs, sobretudo devido ao grande número de dados, como imagens coletadas por drones, disponíveis que

podem não estar sendo plenamente usados atualmente. A subutilização desses dados pode ser atribuída, em grande parte, à elevada complexidade envolvida na identificação e extração de padrões estatísticos relevantes em seu conteúdo (Li, 2023).

Figura 2 - Algumas aplicações da IA na agricultura



Fonte: Adaptado de Intelliarts, 2025.

Devido à limitação de espaço, este trabalho se restringe a abordar alguns exemplos de aplicação de LLM no setor agrícola. Cabe ressaltar que a IA, de forma geral, representa um mecanismo valioso para a agricultura, mas seguramente ainda há vantagens na combinação de esforço entre os modelos LLMs e o ser humano. Apresentam-se a seguir três exemplos ilustrativos do potencial dos LLMs no campo: controle de pragas, gerenciamento e planejamento de culturas e saúde do solo.

Controle de pragas: uma aplicação em potencial para os LLMs na área rural é a identificação de riscos eminentes de pragas na plantação. Nesses casos, normalmente as imagens são capturadas por Veículos Aéreos Não Tripulados, geralmente um drone, e dependendo da arquitetura do sistema implantado, o monitoramento pode ocorrer em tempo real, visando a tomadas de decisão no menor espaço de tempo possível.

Com o propósito de exemplificar um possível cenário nesse contexto, a Figura 3 exibe uma imagem real de um inseto, a qual geralmente é capturada por um drone como o mostrado na Figura 4. A análise dos

dados extraídos da Figura 3, referentes ao inseto mostrado, utilizando o LLM Gemini 2.0 Flash da Google, é apresentada na Figura 5. Cabe ressaltar que esse tipo de imagem pode ser capturado e processado em tempo real, ou posteriormente, fazendo-se uso de bases históricas.

Figura 3 - Exemplo de praga na plantação



Fonte: Acervo dos autores.

Figura 4 - Drones coletando imagens



Fonte: Matos (2022).

O Quadro 2 detalha uma interação com a Inteligência Artificial Gemini. Ao ser solicitada a descrever uma figura, a ferramenta identificou um inseto marrom em formato de escudo pousado em uma folha verde. Com base em sua forma e coloração, e considerando a localização em Cuiabá, Mato Grosso, Brasil, a IA sugeriu que o inseto poderia ser um *Dichelops furcatus* (percevejo barriga-verde). Em uma segunda etapa, ao ser questionada sobre o risco para a plantação, a IA confirmou a provável identificação do *Dichelops furcatus*, alertando que esta espécie é uma praga significativa, capaz de causar danos consideráveis a culturas como milho, soja e trigo na região de Cuiabá.

Quadro 2 - Interação com o LLM Gemini 2.0 Flash

Solicitação: Descreva esta figura em no máximo 5 linhas

Resposta: A imagem mostra um inseto marrom, com formato de escudo, pousado sobre uma folha verde. O corpo do inseto possui algumas manchas mais escuras e um padrão texturizado. Suas antenas são finas e alaranjadas. A identificação precisa requer uma análise mais detalhada das características morfológicas, mas com base na forma geral e coloração, *Dichelops furcatus* (percevejo barriga-verde) é uma possibilidade a ser considerada na sua localização (Cuiabá, Mato Grosso, Brasil).

Solicitação: Há risco para a plantação? Limite a resposta a 5 linhas

Resposta: Sim, o inseto na imagem provavelmente é *Dichelops furcatus*, conhecido como percevejo barriga-verde. Esta espécie é considerada uma praga importante para diversas culturas, incluindo milho, soja e trigo, causando danos significativos nas plantações na região de Cuiabá.

Fonte: Elaborado pelos autores.

Observa-se pelos resultados do Quadro 2 que o LLM não apenas classificou a praga corretamente, mas também inferiu o perigo real que isso pode representar para a plantação. Cabe lembrar que o LLM não foi refinado com dados próprios do usuário, e, portanto, está usando o seu conhecimento aprendido durante o treinamento na grande massa de dados utilizada pelo seu desenvolvedor, o Google. Se integrado com outra aplicação específica para manter o monitoramento contínuo da plantação, essa resposta do LLM Gemini pode ser devidamente tratada, possibilitando que as ações necessárias à proteção da plantação ocorram de forma manual ou automática.

Esse mesmo experimento foi feito com o GPT-4-turbo, e o resultado divergiu da resposta obtida com o Gemin 4.0 Flash. Em vez de identificar o inseto como percevejo barriga-verde (*Dichelops furcatus*), o GPT-4-turbo o classificou como percevejo marrom (*Euschistus heros*). Essa divergência é compreensível devido à grande semelhança entre as duas espécies, cujas principais diferenças referem-se ao tamanho e à cor da barriga. Se houver um refinamento do modelo divergente, com mais dados locais, possivelmente o modelo será mais assertivo. No entanto, o que dever ser ressaltado neste caso é o fato de que os dois tipos de insetos são prejudiciais para a plantação, e os dois modelos de LLM utilizados determinaram exatamente isso.

Para ilustrar ainda mais o potencial das inteligências artificiais no agronegócio, um novo experimento foi conduzido com a IA GPT-4-turbo. Foi solicitado à ferramenta o desenvolvimento de um plano abran-

gente e sustentável de rotação de culturas para uma fazenda hipotética de 300 hectares, considerando-se as particularidades do clima de Cuiabá e a natureza do solo Latossolo, além das demandas de mercado e a sugestão de métodos de controle de pragas ambientalmente amigáveis. A resposta da IA, que delinea a análise do local e o planejamento da rotação de culturas para o primeiro ano, é detalhada no Quadro 3.

Quadro 3 - Interação com o LLM GPT-4-turbo

Solicitação: Desenvolva um plano abrangente de rotação de culturas para uma fazenda de 300 hectares com foco em práticas sustentáveis. Inclua culturas adequadas ao clima local, ao tipo de solo Latossolo e às demandas de mercado. Sugira também métodos de controle de pragas ambientalmente amigáveis.

Resposta:

Aqui está o plano para uma fazenda de 300 hectares, com foco em práticas sustentáveis:

1. Análise do Local

- **Clima Local:** O clima predominante será levado em consideração para escolher culturas adaptadas a essas condições. Pode-se considerar temperaturas médias anuais, índices de precipitação e estações de seca.
- **Tipo de Solo:** O Latossolo é um solo de alta fertilidade, bem drenado e com boa capacidade de retenção de água. Ele é adequado para uma grande variedade de culturas, mas o manejo correto da matéria orgânica será importante para manter sua qualidade.

2. Rotação de Culturas

A rotação de culturas deve ser planejada para melhorar a saúde do solo, otimizar o uso de nutrientes e reduzir a incidência de pragas e doenças. O ciclo de rotação sugerido pode ser o seguinte:

Ano 1

Culturas principais: Soja (leguminosa), milho e feijão.

Fonte: Elaborado pelos autores.

Gerenciamento e planejamento de culturas: nessa aplicação também os LLMs podem impulsionar significativamente os avanços na produção agrícola. O conhecimento amplo e constantemente atualizado dos LLMs potencializa soluções eficientes, inovadoras e rápidas nesse domínio. Um exemplo de uso dos LLMs nesse contexto é mostrado no Quadro 3, em que o usuário solicita ao ChatGPT um plano de rotação de culturas para uma fazenda com as especificações mostradas na referida figura (Weam, 2023). A resposta do LLM é extensa, mas, por concisão, apenas parte dela é mostrada na referida figura.

Quadro 4 - Interação com o LLM Gemini 2.0 Flash para solicitar um plano de melhoria do solo

Solicitação

“Gemini, atue como um especialista em saúde do solo. Analise os dados de composição do solo de uma fazenda de 500 hectares, com pH (solo): 6,0, Nitrogênio (N total): 25 mg/Kg, Fósforo (P-Mehlich-1): 10mg/Kg, Potássio (K- Mehlich-1): 120 mg/Kg, Matéria Orgânica: 2.2%. Forneça um plano detalhado de melhoria do solo com recomendações específicas de fertilizantes, emendas orgânicas e uma estratégia de rotação de culturas que melhore a fertilidade do solo”.

Resposta:

Análise do Solo e Plano de Melhoria para Fazenda de 500 Hectares

Localização: Cuiabá, Estado de Mato Grosso

Área: 500 hectares

Data da Análise: 12 de maio de 2025

- **pH (solo):** 6.0 (Ligeiramente ácido)
- **Nitrogênio (N total):** 25 mg/Kg (Baixo)
- **Fósforo (P-Mehlich-1):** 10 mg/Kg (Baixo)
- **Potássio (K-Mehlich-1):** 120 mg/Kg (Médio a Adequado, dependendo da cultura e teor da argila)
- **Matéria Orgânica (MO):** 2.2% (Baixo)

Interpretação Geral:

O solo da fazenda apresenta um pH ligeiramente ácido, o que geralmente é adequado para a maioria das culturas, mas pode influenciar a disponibilidade de alguns nutrientes. Os níveis de nitrogênio, fósforo e matéria orgânica estão baixos, indicando a necessidade de intervenção para melhorar a fertilidade e a saúde geral do solo. O potássio apresenta um nível razoável, mas é importante monitorar e ajustar conforme a demanda das culturas.

Plano Detalhado de Melhoria do Solo:

O plano de melhoria do solo será abordado em três pilares principais: correção do pH (se necessário), aumento da disponibilidade de nutrientes e melhoria da estrutura e da atividade biológica do solo.

Fonte: Elaborado pelos autores.

Esse exemplo demonstra o nível de abrangência dos LLMs. O plano completo pode ser consultado usando-se a mesma descrição que consta no Quadro 4, a qual inclui informações extremamente pertinentes para o tipo de solo Latossolo, típico da região de Mato Grosso. O nível de detalhamento das recomendações do plano inclui: divisão da fazenda em ciclos, culturas selecionadas, justificativa das culturas, práticas sustentáveis adotadas, controle de pragas ambientalmente amigável, comercialização e demanda de mercado e resumo do benefício da rotação sustentável.

Saúde do solo: o terceiro exemplo mostrando o potencial dos LLMs na agricultura aborda a análise da saúde do solo, conforme exibido no Quadro 4. Nesse cenário, o LLM Gemini 4.0 Flash é solicitado a atuar como um especialista em saúde do solo, para analisar características importantes do solo em questão, e recomendar correções que melhorem a sua fertilidade. O Quadro 4 foi adequada para mostrar mais detalhes da resposta do LLM. Nota-se, novamente, que o nível de conhecimento dos

LLMs é fantástico, pois a avaliação é bem profunda e as recomendações são aparentemente pertinentes. Nesse cenário também a resposta completa pode ser obtida inserindo-se a solicitação detalhada que consta no Quadro 4.

CONSIDERAÇÕES FINAIS

Este trabalho apresenta uma visão geral dos Modelos de Linguagem de Larga Escala (LLMs) aplicados à agricultura moderna, conhecida também como Agricultura 4.0. Devido à complexidade e à amplitude do tema, a abordagem aqui adotada é introdutória, oferecendo uma perspectiva inicial sobre as possíveis aplicações e benefícios dos LLMs nesse contexto. Uma análise mais detalhada exigiria uma extensão considerável do conteúdo, o que excederia o escopo desta publicação.

Apesar dos avanços significativos da inteligência artificial no setor da agricultura aqui apresentados, em particular dos LLMs, ainda há muito a ser aprimorado. Nesse contexto, estima-se que gradativamente as diversas formas de dados da produção rural serão acrescentadas à base de treinamento dos LLMs, tornando-os cada vez mais eficientes e ágeis, o que certamente levará ao aumento da popularidade desses modelos no setor agrícola. Para que isso ocorra de forma consistente, não se pode esquecer de que as Tecnologias de Informação e Comunicação (TICs) também deverão ser disseminadas amplamente na área rural.

Vislumbra-se, portanto, um futuro dominado por tecnologias inteligentes avançadas no campo, impulsionando lavouras altamente eficientes, produtivas e sustentáveis. Acrescido a isso, espera-se também maior qualidade de vida para os trabalhadores rurais, bem como uma mão de obra mais treinada e motivada.

REFERÊNCIAS

AYDIN, Ömer; KARAARSLAN, Enis; ERENAY, Fatih Safa; BACANIN, Nebojsa. **Generative AI in Academic Writing: A Comparison of DeepSeek, Qwen, ChatGPT, Gemini, Llama, Mistral, and Gemma**. Elsevier BV, 2025.

CARBON BRIEF. **Rise in insect pests under climate change to hit crop yields, study says**. 2018. Disponível em: <https://www.carbonbrief.org/rise-in-insect-pests-under-climate-change-to-hit-crop-yields-study-says/>. Acesso em: 9 maio 2025.

ECOFRIENDLY COFFEE. **Butterfly Pollination inside Ecofriendly Indian Shade Coffee**. 2021. Disponível em: <https://ecofriendlycoffee.org/butterfly-pollination-inside-ecofriendly-indian-shade-coffee/>. Acesso em: 9 maio 2025.

HUANG, Dawei; YAN, Chuan; LI, Qing; PENG, Xiaojiang. From Large Language Models to Large Multimodal Models: A Literature Review. **Applied Sciences, Basel**, v. 14, n. 12, p. 5068, jun. 2024. Disponível em: <http://dx.doi.org/10.3390/app14125068>.

INTELLIARTS. **How AI is Changing Agriculture: 10 Real-World Use Cases**. 2025. Disponível em: <https://intelliarts.com/blog/ai-in-agriculture-use-cases/>. Acesso em: 12 maio 2025.

JORGE, Lucio André de Castro *et al.* Inteligência artificial aplicada na agricultura de precisão e digital. In: **AGRICULTURA DE PRECISÃO**. São Carlos: Editora Cubo, 2024.

LI, Jijia; XU, Mingle; XIANG, Lirong; CHEN, Dong; ZHUANG, Weichao; YIN, Xunyuan; LI, Zhaojian. **Large Language Models and Foundation Models in Smart Agriculture: Basics, Opportunities, and Challenges**. arXiv preprint arXiv:2308.06668, 2023. Disponível em: <https://arxiv.org/abs/2308.06668>. Acesso em: 11 maio 2025.

LIU, Fei; KANG, Zejun; HAN, Xing. **Optimizing RAG Techniques for Automotive Industry PDF Chatbots: A Case Study with Locally Deployed Ollama Models**. arXiv preprint arXiv:2408.05933, 2024. Disponível em: <https://arxiv.org/abs/2408.05933>. Acesso em: 11 maio 2025.

MANGENA, Harsha. **Tools for LLM Tuning**. 2025. Disponível em: <https://harshamangena.hashnode.dev/tools-for-llm-tuning>. Acesso em: 11 maio 2025.

MATOS, David. **Aplicações e Técnicas de Machine Learning na Agricultura**. 2022. Disponível em: <https://www.cienciaedados.com/aplicacoes-e-tecnicas-de-machine-learning-na-agricultura/>. Acesso em: 12 maio 2025.

NAVEED, Humza; KHAN, Asad Ullah; QIU, Shi; SAQIB, Muhammad; ANWAR, Saeed; USMAN, Muhammad; AKHTAR, Naveed; BARNES, Nick; MIAN, Ajmal. **A Comprehensive Overview of Large Language Models**. arXiv, 2023. Disponível em: <https://arxiv.org/abs/2307.06435>. Acesso em: 10 maio 2025.

RAIAAN, Mohaimenul Azam Khan; MUKTA, Md. Saddam Hossain; FATEMA, Kaniz; FAHAD, Nur Mohammad; SAKIB, Sadman; MIM, Most Marufatul Jannat; AHMAD, Jubaer; ALI, Mohammed Eunos; AZAM, Sami. A Review on Large Language Models: Architectures, Applications, Taxonomies, Open Issues and Challenges. **IEEE Access**, v. 12, p. 26839-26874, 2024. DOI: 10.1109/ACCESS.2024.3365742.

SUN, Chen; SHRIVASTAVA, Abhinav; SINGH, Saurabh; GUPTA, Abhinav. Revisiting Unreasonable Effectiveness of Data in Deep Learning Era. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2017, Veneza, Itália. **Anais [...]**. Veneza: IEEE, 2017. p. 843-852. DOI: 10.1109/ICCV.2017.97.

TENYKS. Multimodal Large Language Models (MLLMs): Transforming computer vision. **Medium**, 5 fev. 2024. Disponível em: https://medium.com/@tenyks_blogger/multimodal-large-language-models-mlms-transforming-computer-vision-76d3c5dd267f. Acesso em: 12 maio 2025.

WEAM AI. **40 Best ChatGPT Prompts for Farming (Agriculture Prompting)**. 2023. Disponível em: <https://weam.ai/blog/prompts/chatgpt-prompts-for-farming/>. Acesso em: 12 maio 2025.

XIONG, Haoyi; BIAN, Jiang; LI, Yuchen; LI, Xuhong; DU, Mengnan; WANG, Shuaiqiang; YIN, Dawei; HELAL, Sumi. When search engine services meet large language models: visions and challenges. **IEEE Transactions on Services Computing**, v. 17, n. 6, p. 4558-4577, 2024. DOI: 10.1109/TSC.2024.3451185.