

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

مدل‌های زبانی بزرگ در کشاورزی مبتنی بر هوش مصنوعی

مؤلف:

دکتر جواد خنیفر

۱۴۰۴

سرشناسه:	خنیفر، جواد، ۱۳۷۲
عنوان و نام پدیدآور:	مدل‌های زبانی بزرگ در کشاورزی مبتنی بر هوش مصنوعی/مؤلف جواد خنیفر
مشخصات نشر:	کرج: واژگان الف، ۱۴۰۴
مشخصات ظاهری:	۵۹ص.
شابک:	۹۷۸-۶۲۲-۹۱۵۶۳-۹-۱-۵۰۰۰۰
وضعیت فهرست نویسی:	فیپا
یادداشت:	کتابنامه.
یادداشت:	نمایه.
موضوع:	پردازش زبان طبیعی Natural language processing (Computer science) متن‌پردازی Text processing (Computer science) هوش مصنوعی Artificial intelligence هوش مصنوعی -- کاربردهای کشاورزی Artificial intelligence -- Agricultural applications
رده بندی کنگره:	QA۷۶/۹
رده بندی دیویی:	۰۰۶/۳۵
شماره کتابشناسی ملی:	۱۰۰۸۹۱۹۹
اطلاعات رکورد کتابشناسی:	فیپا

مدل‌های زبانی بزرگ در کشاورزی مبتنی بر هوش مصنوعی

مؤلف: جواد خنیفر

ناشر: واژگان الف

چاپ: اول - ۱۴۰۴

شمارگان: ۵۰ نسخه

شابک: ۹۷۸-۶۲۲-۹۱۵۶۳-۹-۱-۵۰۰۰۰

قیمت: ۵۰۰۰۰ تومان

نشانی انتشارات: البرز، کرج، باغستان غربی.

شماره تماس انتشارات: ۰۹۳۳۵۵۲۴۸۹۲

فهرست مطالب کتاب

پیش‌گفتار نویسنده.....	۶
فصل اول: مقدمه‌ای بر مدل‌های زبانی بزرگ.....	۹
فصل دوم: کاربردهای مدل‌های زبانی بزرگ.....	۱۳
فصل سوم: تکنیک‌ها و مدل‌ها.....	۲۱
فصل چهارم: ارزیابی عملکرد مدل‌های زبانی بزرگ.....	۲۹
فصل پنجم: چالش‌ها و ملاحظات.....	۳۷
فصل ششم: مسیرهای تحقیقاتی و چشم‌اندازهای آینده.....	۴۷
فصل هفتم: جمع‌بندی و نتیجه‌گیری.....	۴۹
منابع.....	۵۳
چکیده انگلیسی.....	۵۷

پیش‌گفتار

مدل‌های زبانی بزرگ (LLM‌ها)، به‌عنوان یکی از برجسته‌ترین پیشرفت‌ها در حوزه هوش مصنوعی (AI)، با قابلیت‌های قدرتمند در درک و تولید زبان طبیعی، به‌طور فزاینده‌ای در حوزه‌های گوناگون، از جمله کشاورزی، کاربرد یافته‌اند و روند گذار به کشاورزی هوشمند را تسریع بخشیده‌اند. این کتاب به بررسی جامع مفاهیم، کاربردها، تکنیک‌ها و چالش‌های مرتبط با بهره‌گیری از LLM‌ها در بخش کشاورزی می‌پردازد. مدل‌های عمومی بزرگ مقیاس شناخته‌شده‌ای همچون سری‌های GPT، Claude، Gemini و LLaMA با توانایی تحلیل داده‌های متنی، تصویری و حسگری، می‌توانند در زمینه‌های متنوعی نظیر ارائه مشاوره و راهنمایی تخصصی، مدیریت هوشمند محصول (از جمله پایش رشد گیاه، تشخیص بیماری و آفات، بهینه‌سازی آبیاری و کوددهی و پیش‌بینی عملکرد)، تحلیل داده‌های حجیم کشاورزی، خودکارسازی مستندسازی و تقویت سیستم‌های پرسش‌وپاسخ به کار گرفته شوند. بااین‌حال، نیاز به دانش دامنه‌ای تخصصی در کشاورزی، اغلب اقتضا می‌کند که این مدل‌های عمومی تطبیق داده شوند. در این راستا، مدل‌هایی نظیر AgriVLM، KALLM، AgriBERT و PLLaMa به‌طور خاص برای حوزه کشاورزی توسعه یا تنظیم شده‌اند. از جمله تکنیک‌های کلیدی برای ارتقای کارایی LLM‌ها در این حوزه

می‌توان به تنظیم دقیق یا پیش آموزش آن‌ها با مجموعه داده‌های کشاورزی، بهره‌گیری از تولید تقویت‌شده با بازیابی (RAG) جهت افزودن دانش تخصصی و ادغام با گراف‌های دانش، مدل‌های زبانی بصری برای تحلیل داده‌های چندوجهی و سیستم‌های اینترنت اشیا (IoT) اشاره کرد. افزون بر این رویکردهای فنی، ارزیابی عملکرد LLM‌ها در حوزه کشاورزی برای ایجاد اعتماد و تضمین قابلیت استفاده عملی آن‌ها از اهمیت بالایی برخوردار است. این ارزیابی مجموعه‌ای از معیارها را در بر می‌گیرد؛ از جمله صحت، دقت، امتیاز F1، معیارهای تولید متن (مانند BLEU، ROUGE و BERTScore)، بهره‌وری منابع، محک‌زنی و مقایسه با ارزیابی‌های انجام‌شده توسط متخصصان انسانی. علی‌رغم پتانسیل عظیم LLM‌ها، چالش‌هایی نظیر کمبود داده‌های کشاورزی باکیفیت بالا، خطر تولید اطلاعات نادرست، فقدان دانش تخصصی عمیق در مدل‌های عمومی، هزینه‌های بالای محاسباتی، مسائل مربوط به تفسیرپذیری و اعتمادپذیری، سوگیری‌های احتمالی، نگرانی‌های مرتبط با حریم خصوصی داده‌ها و پیامدهای بالقوه بر نیروی کار کشاورزی همچنان باقی است. باوجود این محدودیت‌ها، LLM‌ها با ارائه بینش‌های عملی برگرفته از داده‌های پیچیده، فرصت‌هایی قابل توجه برای افزایش بهره‌وری، بهبود بازده محصول، ارتقای پایداری و بهینه‌سازی تصمیم‌گیری در کشاورزی فراهم کرده و فرایند اتوماسیون را در این حوزه شتاب می‌بخشند. استمرار پژوهش در زمینه توسعه مدل‌های تخصصی‌تر، بهبود هم‌افزایی با سایر فناوری‌ها، رفع چالش‌های موجود و بررسی پیامدهای اخلاقی و اجتماعی این فناوری‌ها، ضرورتی اساسی محسوب می‌شود.

جواد خنیفر

www.drjk.ir

فصل اول

مقدمه‌ای بر مدل‌های زبانی بزرگ

مدل‌های زبانی بزرگ (LLMها)^۱ اساساً سیستم‌هایی از نوع هوش مصنوعی (AI)^۲ هستند که با آموزش بر روی مجموعه‌های عظیم داده‌های متنی — شامل کتاب‌ها، مقالات، وب‌سایت‌ها و سایر منابع — قادر به پیش‌بینی و تولید متن منسجم هستند. فناوری محوری این مدل‌ها «یادگیری عمیق» است که به آن‌ها امکان می‌دهد الگوهای پیچیده زبان انسان را فراگیرند (Feng et al., 2024; Gong & Li, 2025; Khanifar, 2025; Kuska et al., 2024).

همان‌طور که در شکل (۱) نشان داده شده است، LLMها زیرمجموعه‌ای از هوش مصنوعی مولد^۳ به شمار می‌روند. تکامل این مدل‌ها را می‌توان از مراحل اولیه پردازش زبان طبیعی (NLP)^۴ — که متکی بر N-gramها و روش‌های آماری در پیش‌بینی و تولید متن پایه بودند — ردیابی کرد. با این حال، این رویکردهای ابتدایی در درک وابستگی‌های دوربرد و لحاظ کردن اطلاعات زمینه‌ای با محدودیت‌هایی همراه

^۱ Large Language Models (LLMs)

^۲ Artificial Intelligence (AI)

^۳ Generative Artificial Intelligence

^۴ Natural Language Processing (NLP)

بودند. ظهور شبکه‌های عصبی، به‌ویژه شبکه‌های عصبی بازگشتی (RNN)^۱ و شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM)^۲، توانایی پردازش داده‌های ترتیبی را به طور چشمگیری بهبود بخشید (Antoshchuk et al., 2025; Feng et al., 2024; Khanifar, 2025; Shaikh et al., 2024; Vizniuk et al., 2025).

تحولی کلیدی با معرفی معماری ترنسفورمر توسط Vaswani و همکاران در سال ۲۰۱۷ رخ داد که امکان پردازش موازی توالی‌های ورودی را فراهم ساخت و کارایی مدل‌سازی زبانی را به شکل قابل توجهی افزایش داد. یکی از مهم‌ترین پیشرفت‌ها، توسعه خانواده GPT^۳ (ترنسفورمر مولد از پیش آموزش‌دیده) توسط OpenAI بود که با معرفی GPT-3 در سال ۲۰۲۰ — با ۱۷۵ میلیارد پارامتر — نقطه عطفی در تولید متن‌های بسیار منسجم و مرتبط ایجاد کرد. این پیشرفت، الهام‌بخش توسعه مدل‌های دیگری مانند BERT^۴ (نمایش رمزگذار دوطرفه) از سوی گوگل شد. تکامل LLM‌ها از مدل‌های زبانی آماری (SLMs)^۵ به مدل‌های زبانی عصبی (NLMs)^۶، مدل‌های زبانی از پیش آموزش‌دیده (PLMs)^۷ و در نهایت به LLM‌های مدرن با میلیاردها پارامتر نشانگر پیشرفت چشمگیر این حوزه است (Antoshchuk et al., 2025; Feng et al., 2024; Khanifar, 2025; Li et al., 2024; Shaikh et al., 2024; Yang et al., 2024).

^۱ Recurrent Neural Networks (RNN)

^۲ Long Short-Term Memory (LSTM)


^۳ GPT (Generative Pre-Trained Transformer)

^۴ BERT (Bidirectional Encoder Representation)

^۵ Statistical Language Models (SLMs)

^۶ Neural Language Models (NLMs)

^۷ Pre-trained Language Models (PLMs)



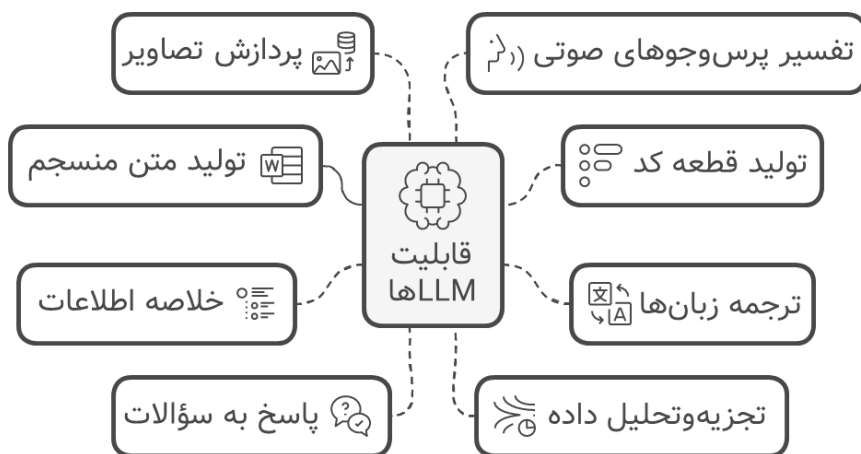
شکل ۱. رابطه میان مدل‌های زبانی بزرگ (LLMها)، هوش مصنوعی مولد و یادگیری عمیق در اکوسیستم هوش مصنوعی (AI).

LLMها سطح بالایی از توانمندی را در وظایفی همچون درک زبان طبیعی و تولید متن نشان داده‌اند. در شکل (۲)، رایج‌ترین قابلیت‌های کلیدی این مدل‌ها معرفی شده‌اند. LLMها به طور گسترده در حوزه‌های متنوعی همچون آموزش، پژوهش، پزشکی، امور مالی و حقوق به کار گرفته شده‌اند. برخی از برجسته‌ترین نمونه‌های این مدل‌ها عبارت‌اند از:

- سری GPT (توسعه‌یافته توسط OpenAI، وب‌سایت: openai.com)
- سری Claude (توسعه‌یافته توسط Anthropic، وب‌سایت: anthropic.com)
- سری Gemini (توسعه‌یافته توسط Google، وب‌سایت: ai.google)

- سری Grok (توسعه‌یافته توسط xAI، وب‌سایت: x.ai)
- سری LLaMA (توسعه‌یافته توسط Meta، وب‌سایت: ai.meta.com)

این مدل‌ها قادرند همبستگی‌های آماری میان واژگان و عبارات را شناسایی کرده و متعاقباً متن تولید کنند، مطلب را ترجمه کنند و سایر عملیات پردازش زبان طبیعی را به انجام رسانند. توانایی آن‌ها در درک معنانشناسی و ظرایف زبان طبیعی، آن‌ها را به ابزارهای مؤثری برای وظایف متنوعی نظیر پاسخ به پرسش‌ها تبدیل کرده است. LLM‌های مدرن همچنین قابلیت‌های نوظهوری از خود نشان داده‌اند که به آن‌ها امکان می‌دهد وظایفی را که فراتر از توان مدل‌های کوچک‌تر است، با موفقیت انجام دهند (Antoshchuk et al., 2025; Banerjee et al., 2024; Khanifar, 2025; Kuska et al., 2024; Yang et al., 2024).



شکل ۲. برخی از قابلیت‌های کلیدی مدل‌های زبانی بزرگ (LLM‌ها).

فصل دوم

کاربردهای مدل‌های زبانی بزرگ


پتانسیل LLMها برای ایجاد تحول در ابعاد مختلف کشاورزی به طور فزاینده‌ای در حال شناسایی است. در این بخش، به طیف گسترده‌ای از کاربردهای فعلی و بالقوه این مدل‌ها در بخش کشاورزی پرداخته می‌شود (شکل ۳). این کاربردها از توانایی LLMها در درک و تولید زبان طبیعی، پردازش انواع داده‌ها و یادگیری از مجموعه‌های داده بزرگ برای مواجهه با چالش‌های پیچیده کشاورزی مدرن بهره می‌برند.

ارائه مشاوره و راهنمایی کشاورزی

LLMها می‌توانند به عنوان کارشناسان مجازی کشاورزی عمل کرده و پشتیبانی دانشی برای زیرشاخه‌های مختلف این حوزه فراهم آورند (Gong & Li, 2025). این مدل‌ها قادرند تخصص زراعی مورد نیاز و توصیه‌های شخصی‌سازی شده، مکان‌محور و داده‌محور را به کشاورزان ارائه دهند (De Clercq et al., 2024; Tzachor et al., 2023). این خدمات شامل ارائه مشاوره درباره کشت محصول، اصلاح نژاد^۱

^۱ Breeding

ماشین‌آلات کشاورزی و آسیب‌شناسی گیاهی^۱ می‌شود. برای نمونه، LLMها می‌توانند به کشاورزان در انتخاب زمان، اقدام و ابزار مناسب جهت افزایش بهره‌وری کمک کنند (Kuska et al., 2024).



شکل ۳. برخی از کاربردهای مدل‌های زبانی بزرگ (LLMها) در کشاورزی.

مطالعات نشان می‌دهد که LLMهایی مانند GPT می‌توانند مشاوره فنی مؤثری به کشاورزان ارائه کنند. همچنین این مدل‌ها می‌توانند در نقش خدمات ترویج کشاورزی ظاهر شوند؛ به گونه‌ای که دانش علمی را ساده‌سازی کرده و مشاوره‌های شخصی‌سازی‌شده را در مقیاس گسترده در اختیار کاربران قرار دهند (Kuska et al., 2024; Tzachor et al., 2023).

^۱ Phytopathology

علاوه بر این، LLMها قابلیت ادغام در سیستم‌های هوشمند نظیر ربات‌های کشاورزی^۱ را دارند تا تعاملات پرسش و پاسخ را تسهیل کرده و کمک هدفمندتری به کارگران کشاورزی ارائه دهند (Gong & Li, 2025).

کمک به مدیریت محصول

LLMها کاربردهای قابل توجهی در مدیریت هوشمند محصولات کشاورزی دارند. آن‌ها با ادغام فناوری‌هایی همچون AI، اینترنت اشیاء (IoT)^۲ و کلان‌داده، در وظایفی مانند پایش رشد گیاه، تشخیص بیماری، پایش عملکرد و برداشت محصول ایفای نقش می‌کنند (Li et al., 2024; Shaikh et al., 2024).

- **تشخیص بیماری گیاهی و مرحله رشد:** مدل‌های زبان بصری^۳ تنظیم دقیق شده مانند *AgriVLM* عملکرد چشمگیری در تشخیص بیماری‌های گیاهی و شناسایی مراحل رشد گیاه دارند و صحت آن‌ها از ۹۰٪ فراتر می‌رود. LLMها قادرند داده‌های متنی و تصویری را برای انجام این وظایف به طور هم‌زمان تحلیل کنند (Gong & Li, 2025; Yu and Lin, 2024).
- **کنترل آفات:** LLMها می‌توانند داده‌های تحقیقاتی مرتبط با مدیریت آفات را تحلیل کرده تا توصیه‌هایی کاربردی برای محصولات و مناطق خاص ارائه دهند (Feng et al., 2024). پروژه‌هایی مانند *PestGPT* از LLMها و IoT برای ارائه توصیه‌های سفارشی و به‌موقع در مدیریت پایدار آفات بهره می‌برند (Yuan et al., 2024).

^۱ Agricultural robots

^۲ Internet of Things (IoT)

^۳ Visual language models

- **آبیاری و کوددهی:** این مدل‌ها با تجزیه و تحلیل داده‌های هواشناسی، شرایط خاک و سلامت محصول، می‌توانند توصیه‌های لحظه‌ای و هوشمندانه‌ای در خصوص زمان و میزان آبیاری و کوددهی ارائه دهند. این امر موجب بهینه‌سازی مصرف منابع و افزایش عملکرد محصولات می‌شود (Feng et al., 2024).

- **پیش‌بینی عملکرد:** درحالی‌که LLM‌های عمومی برای پیش‌بینی دقیق عملکرد محصول ممکن است به داده‌های نمونه‌ای خاص نیاز داشته باشند، ادغام آن‌ها با منابع داده مکمل می‌تولند دقت و آگاهی این پیش‌بینی‌ها را به شکل قابل توجهی افزایش دهد (Akbar et al., 2024; Feng et al., 2024).

تجزیه و تحلیل داده‌های کشاورزی

LLM‌ها ابزارهایی قدرتمند برای تجزیه و تحلیل طیف گسترده‌ای از داده‌های کشاورزی، از جمله متون، تصاویر، داده‌های حسگر و روندهای بازار به شمار می‌آیند. این مدل‌ها قادرند مقادیر زیادی از داده‌های بدون ساختار که از دستگاه‌های IoT گردآوری می‌شوند را پردازش و تفسیر کرده و از آن‌ها الگوها و بینش‌های معناداری را برای پشتیبانی از تصمیم‌گیری استخراج کنند. قابلیت‌های NLP در LLM‌ها امکان تحلیل منابع متنی همچون مقالات پژوهشی، گزارش‌های ترویجی و مکاتبات میان کشاورزان را فراهم می‌سازد. این تحلیل‌ها می‌توانند به شناسایی روندها، کشف اطلاعات مهم و ارائه توصیه‌های عملی منجر شوند. علاوه بر این، LLM‌ها می‌توانند داده‌های بازار را به منظور شناسایی الگوهای قیمتی، نوسانات تقاضا و ترجیحات مشتری تحلیل کرده و اطلاعات راهبردی در اختیار تصمیم‌گیرندگان قرار دهند. در بُعد تصویری نیز، مدل‌های زیان بصری توانایی تحلیل داده‌های

تصویری را فراهم می‌کنند و دامنهٔ عملکرد این مدل‌ها را به حوزه‌هایی مانند تشخیص بصری بیماری و ارزیابی کیفیت محصول گسترش می‌دهند (Feng et al., 2024; Shaikh et al., 2024; Shaikh et al., 2025; Yu and Lin, 2024).

خودکارسازی مستندسازی و گزارش‌دهی

LLMها می‌توانند با تبدیل داده‌های قابل خواندن توسط ماشین —مانند اطلاعات حاصل از سیستم‌های مدیریت مزرعه و ردیاب‌های ماشین‌آلات کشاورزی— به زبان قابل درک برای انسان، به مستندسازی خودکار کمک کنند. این مدل‌ها همچنین قادرند فرآیند تولید گزارش‌ها، خلاصه‌سازی اطلاعات و سایر محتوای متنی را به صورت خودکار انجام دهند (Kuska et al., 2024; Shaikh et al., 2024; Shaikh et al., 2025).

توضیح مقررات و سیاست‌های کشاورزی

LLMها توانایی دارند اسناد حقوقی و مقررات مرتبط با کشاورزی را، از جمله قوانین ناظر بر حفاظت گیاهان^۱ یا کاربرد مواد شیمیایی، به شکلی قابل فهم و ساده‌سازی شده تبیین نمایند. این مدل‌ها می‌توانند وظایف قانونی در فعالیتهای کشاورزی را شفاف‌سازی کرده و به تصمیم‌گیری آگاهانه کمک کنند (Kuska et al., 2024; Shaikh et al., 2024; Shaikh et al., 2025).

تقویت سیستم‌های پرسش و پاسخ کشاورزی

LLMها نقش فزاینده‌ای در تحول سامانه‌های پرسش و پاسخ در حوزه کشاورزی ایفا می‌کنند. این مدل‌ها قادرند اصطلاحات و مفاهیم تخصصی کشاورزی را درک کرده،

^۱ Plant protection

با انواع منابع داده‌ای کشاورزی—اعم از متنی، عددی و ساختاریافته—تعامل برقرار کنند و بر اساس زمینه و شرایط واقعی پاسخ‌هایی دقیق ارائه دهند. در طراحی این سامانه‌ها، رویکردهای متنوعی برای ذخیره‌سازی و بازیابی دانش به کار می‌رود که LLMها یکی از ارکان اصلی آن به شمار می‌آیند (Yang et al., 2024). علاوه بر این، ادغام LLMها با منابع دانش خارجی کشاورزی از طریق تکنیک تولید تقویت‌شده با بازیابی (RAG)^۱، می‌تواند دقت و ارتباط پاسخ‌ها را به طرز چشمگیری بهبود بخشد (Akbar et al., 2024; Jiang et al., 2025; Vizniuk et al., 2025).

تسهیل اشتراک‌گذاری داده‌ها

چارچوب‌های اشتراک‌گذاری داده مبتنی بر عامل که از LLMها بهره می‌گیرند، با هدف امکان‌پذیر ساختن تبادل داده میان دستگاه‌های ناهمگون IoT در حوزه کشاورزی پیشنهاد شده‌اند. این چارچوب‌ها به مسائل مربوط به استانداردسازی و قابلیت همکاری می‌پردازند (Akbar et al., 2024).

پشتیبانی از تصمیم‌گیری

LLMها پتانسیل آن را دارند که به ابزارهایی قدرتمند برای حمایت از کشاورزان و سایر ذی‌نفعان در اتخاذ تصمیم‌هایی آگاهانه‌تر و به‌موقع‌تر تبدیل شوند. این امر از طریق پردازش و تفسیر حجم انبوهی از داده‌ها و ارائه توصیه‌های متناسب با زمینه انجام می‌شود. این مدل‌ها می‌توانند داده‌ها را از منابع مختلف ادغام کرده و نمایی جامع از شرایط مزرعه ارائه دهند و همچنین شناسایی روندها و همبستگی‌ها را تسهیل کنند (Feng et al., 2024; Vizniuk et al., 2025; Shaikh et al., 2024).

^۱ Retrieval-Augmented Generation (RAG)

بهبود درک دانش کشاورزی

مدل‌های زبان بصری مانند *AgriVLM* به منظور بهبود یادگیری ویژگی‌های داده‌های چندوجهی در کشاورزی، تحقق ادغام این داده‌ها و در نتیجه درک بهتر سناریوهای کاربردی پیچیده طراحی شده‌اند. این رویکرد منجر به درکی جامع‌تر از دانش کشاورزی می‌شود (Yu and Lin, 2024).

کمک به تحقیقات کشاورزی

LLMها به عنوان ابزارهای مؤثر NLP در تحقیقات کشاورزی ایفای نقش می‌نمایند و به پژوهشگران در انجام وظایفی چون پردازش متون و کاهش هزینه‌های انسانی کمک می‌کنند (Gong & Li, 2025). این مدل‌ها می‌توانند در تطابق معنایی میان توضیحات مربوط به مواد غذایی و داده‌های تغذیه‌ای، طبقه‌بندی احساسات در اخبار کشاورزی و سازماندهی اطلاعات بدون ساختار مؤثر واقع شوند (Muller et al., 2025; Rezayi et al., 2024; Shaikh et al., 2024).

پتانسیل در رباتیک و اتوماسیون کشاورزی

درحالی‌که کاربردهای فعلی عمدتاً بر متن و تصویر متمرکز هستند، علاقه فزاینده‌ای به بهره‌گیری از LLMها در حوزه رباتیک کشاورزی وجود دارد؛ جایی که این مدل‌ها قادر به پردازش ورودی‌های متنوعی همچون تصویر، متن، صدا و داده‌های عمقی هستند (Li et al., 2024). LLMها همچنین می‌توانند برای پردازش ویدئو در صنعت کشاورزی به کار روند و وظایفی نظیر پایش دام و تشخیص ناهنجاری را ممکن سازند (Antoshchuk et al., 2025). افزون بر این، آن‌ها می‌توانند در اتوماسیون وظایف داده‌محور کشاورزی نقش مؤثری ایفا کنند (Muller et al., 2025).

پرداختن به پیامدهای بازار کار

مطالعاتی در حال بررسی تأثیرات بالقوه LLMها بر بازار کار کشاورزی هستند و تمرکز آنها بر نحوه تأثیر این فناوری‌ها بر مشاغل گوناگون از طریق تجزیه و تحلیل الزامات شناختی، فیزیکی و حسی مرتبط با وظایف کشاورزی است (Marinoudi et al., 2024).

سایر کاربردها

- **ارتباطات چندزبانه:** LLMها می‌توانند ارتباطات چندزبانه را تسهیل کرده، متون پیچیده زراعی را ترجمه کنند و زمینه را برای همکاری‌های بین‌المللی فراهم سازند (Antoshchuk et al., 2025; Feng et al., 2024).
- **تبدیل متن به گفتار (TTS):** فناوری TTS که توسط AI پشتیبانی می‌شود، می‌تواند پشتیبانی فنی برای رفع مشکلات کمبود اطلاعات و ارتقای تعاملات پویا در خدمات دانش کشاورزی ارائه دهد (Shaikh et al., 2025).

¹ Text-to-Speech (TTS)

فصل سوم

تکنیک‌ها و مدل‌ها

طیف متنوعی از تکنیک‌ها و مدل‌ها در زمینه به‌کارگیری LLM‌ها در کشاورزی در حال بررسی و پیاده‌سازی است. این تکنیک‌ها با هدف بهره‌گیری از توان LLM‌ها برای پاسخ‌گویی به چالش‌ها و بهره‌برداری از فرصت‌های خاص این حوزه طراحی شده‌اند.

معماری‌های بنیادی LLM و آموزش

در هسته بسیاری از کاربردهای LLM در کشاورزی، مدل‌های بنیادی مبتنی بر معماری ترنسفورمر قرار دارند. این LLM‌ها معمولاً بر روی مجموعه‌های گسترده‌ای از داده‌های متنی آموزش می‌بینند تا همبستگی‌های آماری میان واژگان و عبارات را فرا گرفته و توانایی درک زبان طبیعی و تولید متن را کسب کنند (Banerjee et al., 2024; Gong and Li, 2025; Yu and Lin, 2024). این فرآیند اغلب با استفاده از یادگیری خودنظارتی انجام می‌شود که نیاز به برچسب‌گذاری دستی داده‌ها را کاهش می‌دهد. نمونه‌هایی از این LLM‌های عمومی شامل سری مدل‌های GPT و LLaMa

هستند. این مدل‌ها به واسطه آموزش در مقیاس بزرگ، قابلیت‌های تعمیم‌پذیری بالایی از خود نشان داده‌اند (Shaikh et al., 2024; Yu and Lin, 2024).

تکنیک‌های تطبیق برای کشاورزی

با توجه به ماهیت تخصصی دانش در حوزه کشاورزی، LLM‌های عمومی اغلب نیازمند تطبیق با داده‌ها و مفاهیم خاص این حوزه هستند. از جمله تکنیک‌های اصلی برای توسعه LLM‌های تخصصی در کشاورزی می‌توان به موارد زیر اشاره کرد:

- **تنظیم دقیق^۱:** این روش شامل استفاده از یک LLM عمومی پیش‌آموزش‌دیده و آموزش بیشتر آن بر روی مجموعه داده‌ای کوچک‌تر و مختص کشاورزی است. این فرآیند پارامترهای مدل را برای درک و تولید دقیق‌تر متون کشاورزی تنظیم می‌کند. به عنوان نمونه، *AgriVLM* چارچوبی است که یک مدل زبان بصری را با بهره‌گیری از حجم زیادی از داده‌های کشاورزی برای تحلیل داده‌های این حوزه به صورت دقیق تنظیم می‌کند. همچنین، تنظیم دقیق نظارت‌شده (SFT)^۲ هماهنگ با دانش^۳ نیز برای بهبود نمایش توکن‌های اختصاصی کشاورزی پیشنهاد شده است (Gong and Li, 2025; Jiang et al., 2025; Yu and Lin, 2024).

- **پیش‌آموزش^۴:** در این روش، یک مدل پایه یا از ابتدا آموزش داده می‌شود یا ادامه آموزش آن بر روی پیکره‌ای^۵ بسیار بزرگ از داده‌های متنی مرتبط با کشاورزی انجام می‌گیرد. این کار به مدل امکان می‌دهد تا درک عمیق‌تری از

^۱ Fine-tuning

^۲ Supervised Fine-Tuning (SFT)

^۳ knowledge-coordinated

^۴ Pre-training

^۵ Corpus

مفاهیم و اصطلاحات تخصصی این حوزه به دست آورد. برای مثال، *PLLaMa* یک LLM ویژه علوم گیاهی، از طریق پیش‌آموزش LLaMa-2 بر روی مقالات علوم گیاهی توسعه یافت. *AgriBERT* نیز نمونه‌ای دیگر از LLM است که بر روی پیکره‌های متنی مرتبط با کشاورزی آموزش دیده است (Gong and Li, 2025; Muller et al., 2025; Yu and Lin, 2024).

تولید تقویت‌شده با بازیابی (RAG)

برای رفع محدودیت‌های دانش درونی LLM‌ها و کاهش مشکلاتی نظیر توهم‌زایی (تولید اطلاعات نادرست)، تولید تقویت‌شده با بازیابی (RAG) به‌عنوان یک تکنیک کلیدی معرفی شده است (Akbar et al., 2024; Jiang et al., 2025; Vizniuk et al., 2025).

- در RAG، ورودی LLM با دانش خارجی مرتبط که از پایگاه‌های داده یا پایگاه‌های دانش کشاورزی بازیابی می‌شود، تقویت می‌گردد. این کار به مدل اجازه می‌دهد تا پاسخ‌هایی دقیق‌تر و با زمینه‌سازی مناسب برای پرس‌وجوهای کشاورزی تولید کند. این دانش خارجی می‌تواند از طریق مکانیزم‌هایی مانند ترکیب توجه^۱ یا درونیابی خروجی^۲ در مدل ادغام شود.
- در کاربردهای کشاورزی، روش‌های متنوعی برای بازیابی اطلاعات در چارچوب RAG مورد استفاده قرار می‌گیرند؛ از جمله الگوریتم BM25

^۱ Attention blending

^۲ Output interpolation

برای شباهت مبتنی بر کلمه کلیدی، (Sentence-BERT (SBERT برای شباهت معنایی و مدل‌های بازیابی متراکم^۱ برای بازیابی آگاه از زمینه^۲.

- KALLM (LLM کشاورزی هدایت‌شده با دانش^۳) یک مکانیسم RAG خودبازتابنده^۴ مبتنی بر تطابق موضوعی ارائه می‌دهد که هدف آن بهبود دقت در بازیابی شواهد از پایگاه‌های دانش کشاورزی است.

مدل‌های زبان بصری

باتوجه به اهمیت داده‌های بصری در کشاورزی، مدل‌های زبان بصری به تدریج در حال برجسته‌شدن هستند. این مدل‌ها از قابلیت‌های درک چندوجهی برخوردارند که به آن‌ها امکان تجزیه و تحلیل هم‌زمان تصاویر و متون را می‌دهد (Yu and Lin, 2024).

- AgriVLM از یک *Q-former* به عنوان پلی بین یک رمزگذار تصویر و یک مدل زبانی برای دستیابی به ادغام چندوجهی داده‌های تصویری و متنی کشاورزی استفاده می‌کند و وظایفی نظیر تشخیص بیماری‌های گیاهی و شناسایی مرحله رشد محصولات را با دقت بالا امکان‌پذیر می‌سازد.
- مدل‌های زبانی بصری عمومی مانند ViLT، Qwen-VL و VisCPM، گرچه بر اساس داده‌های گسترده تصویر-متن آموزش دیده‌اند، با تنظیم دقیق می‌توانند برای درک مفاهیم خاص در حوزه دانش کشاورزی نیز به کار گرفته شوند.

¹ Dense retrieval models

² Context aware

³ Knowledge-guided Agriculture LLM (KALLM)

⁴ Self-reflective

ادغام با گراف‌های دانش (KGها)

ادغام LLMها با KGها به‌عنوان رویکردی قدرتمند برای ترکیب نقاط قوت هر دو فناوری مطرح شده است (Gong and Li, 2025; Zhao et al., 2024).

- KGها اطلاعات ساختاریافته و تخصصی مرتبط با حوزه کشاورزی را فراهم می‌کنند، درحالی‌که LLMها از توانایی بالایی در پردازش زبان طبیعی برخوردارند.

- از LLMها می‌توان برای ارتقای کارایی در ساخت KGها کشاورزی استفاده کرد. به‌کارگیری هم‌زمان LLMها و KGها می‌تواند منجر به ارائه خدمات دانشی دقیق‌تر و قابل‌اعتمادتر شود و فرآیند تصمیم‌گیری و استدلال مشارکتی در حوزه کشاورزی را تسهیل کند.

سیستم‌های مبتنی بر عامل

چارچوب‌های اشتراک‌گذاری داده مبتنی بر عامل (ADS)^۱ که از LLMها بهره می‌برند، در حال بررسی به‌عنوان راهکاری برای تسهیل تبادل یکپارچه اطلاعات میان دستگاه‌های ناهمگون IoT در کشاورزی هستند. این چارچوب‌ها فناوری‌های وب معنایی، طراحی مبتنی بر عامل و LLMها را ترکیب می‌کنند تا اشتراک‌گذاری غیرمتمرکز داده‌ها را از طریق عامل‌های متخصص هوشمند امکان‌پذیر سازند (Akbar et al., 2024).

^۱ Agent-based data sharing (ADS)

سیستم‌های پرسش و پاسخ (QA)^۱

LLMها به طور قابل توجهی موجب تقویت سیستم‌های پرسش و پاسخ در حوزه کشاورزی شده‌اند. این سیستم‌ها با هدف درک دقیق اصطلاحات و مفاهیم تخصصی کشاورزی، پردازش منابع متنوع داده‌ای و ارائه پاسخ‌های مرتبط با شرایط واقعی طراحی شده‌اند. در این سیستم‌ها از رویکردهای مختلف ذخیره‌سازی دانش استفاده می‌شود؛ از جمله پیکره‌های متنی، KGها و خود LLMها (Yang et al., 2024).

نمونه‌های خاص LLM کشاورزی

چندین LLM وجود دارد که به طور ویژه برای کاربردهای حوزه کشاورزی طراحی یا تطبیق داده شده‌اند (جدول ۱).

کاربرد LLMهای عمومی در کشاورزی

LLMهای عمومی مانند ChatGPT، Copilot و Gemini نیز برای بررسی کاربردهای بالقوه در بخش کشاورزی مورد استفاده قرار گرفته‌اند. برای مثال، از این مدل‌ها به عنوان ارزیاب‌های خودکار جهت سنجش آسیب‌پذیری مشاغل کشاورزی در برابر فرآیند رباتیک‌سازی استفاده شده است. ChatGPT همچنین در ارائه مشاوره فنی به کشاورزان و طبقه‌بندی احساسات در اخبار مرتبط با کشاورزی مورد ارزیابی قرار گرفته است (Benos et al., 2025; Muller et al., 2025; Shaikh et al., 2024; Tzachor et al., 2023; Yu and Lin, 2024).

^۱ Question Answering

جدول ۱. مرور برخی از مدل‌های زبانی بزرگ (LLMها) تخصصی در حوزه کشاورزی.	
نام مدل	توضیحات
AgriVLM	یک مدل زبان بصری که برای تحلیل داده‌های کشاورزی تنظیم دقیق شده است و در وظایفی مانند تشخیص تصویری و درک مفاهیم کشاورزی عملکرد برتری دارد (Yu and Lin, 2024).
AgriBERT	یک مدل زبانی تزریق‌شده با دانش کشاورزی که در وظایفی مانند تطبیق داده‌های تغذیه‌ای و غذایی کاربرد دارد (Muller et al., 2025; Rezayi et al., 2024).
PestGPT	پروژه‌ای مبتنی بر ترکیب LLM و IoT که توصیه‌هایی به‌موقع و شخصی‌سازی‌شده برای مدیریت آفات ارائه می‌دهد (Yuan et al., 2024).
PLLaMa	یک LLM متن‌باز برای علوم گیاهی که با استفاده از پیکره‌ای گسترده از مقالات مرتبط با گیاهان پیش‌آموزش داده شده است (Gong and Li, 2025; Muller et al., 2025).
KALLM	مدلی طراحی‌شده برای تصمیم‌گیری چندوظیفه‌ای که دانش کشاورزی را در سطوح توکن و جمله، از طریق SFT هماهنگ با دانش و RAG تطبیق‌یافته با موضوع ^۱ ، ادغام می‌کند (Jiang et al., 2025).

^۱ Topic-matched

فصل چهارم

ارزیابی عملکرد مدل‌های زبانی بزرگ

ارزیابی LLMها در حوزه کشاورزی شامل بهره‌گیری از انواع معیارها و رویکردها به منظور سنجش عملکرد، اثربخشی و قابلیت اطمینان این مدل‌ها در وظایف و کاربردهای گوناگون است. این ارزیابی، در راستای ایجاد اعتماد و اطمینان نسبت به امکان بهره‌برداری عملی از LLMها توسط کشاورزان و متخصصان کشاورزی، نقشی حیاتی ایفا می‌کند. در ادامه، برخی از معیارها و روش‌های ارزیابی این مدل‌ها در زمینه کشاورزی معرفی و بررسی می‌شوند.

معیارهای کمی

- **صحت^۱:** یکی از معیارهای متداول است که برای اندازه‌گیری نسبت کلی پیش‌بینی‌های صحیح توسط یک مدل استفاده می‌شود (Zhao et al., 2024). این معیار در وظایفی مانند تشخیص بیماری‌های محصولات کشاورزی و تشخیص مراحل رشد به کاررفته است؛ به عنوان مثال، AgriVLM صحت تشخیصی بیش از ۹۰٪ را نشان داده است (Yu and Lin, 2024). صحت

^۱ Accuracy

همچنین در ارزیابی توانایی LLMها در پاسخ به آزمون‌های کشاورزی مورد استفاده قرار گرفته است، به‌طوری‌که GPT-4 در آزمون مشاور محصول معتبر ایالات متحده (CCA)^۱ به صحت ۹۳٪ دست‌یافته است (Gong and Li, 2025; Vizniuk et al., 2025).

- **دقت^۲، بازخوانی^۳ و امتیاز F1^۴:** این معیارها به‌ویژه برای وظایفی مانند تشخیص بیماری و شناسایی موجودیت‌های نام‌گذاری شده (NER)^۵ مورد استفاده قرار می‌گیرند (Chebbi et al., 2024; Zhao et al., 2024). امتیاز F1 همچنین در سطح توکن، به‌منظور ارزیابی عملکرد سیستم‌های پاسخ به پرسش به کار می‌رود (He, 2024). معیار دقت، نسبت موارد مثبت صحیح شناسایی شده به کل موارد پیش‌بینی شده مثبت را اندازه‌گیری می‌کند؛ درحالی‌که بازخوانی، نسبت موارد مثبت واقعی شناسایی شده توسط مدل را محاسبه می‌کند (Zhao et al., 2024). امتیاز F1، میانگین هارمونیک^۶ معیارهای دقت و بازخوانی است و توازنی میان این دو شاخص فراهم می‌آورد. در وظایف مرتبط با NER، مدل‌هایی مانند GPT-4 و Claude v2 عملکرد قابل‌توجهی با امتیازات F1 نزدیک به مدل‌های پایه با تنظیم دقیق^۷ از خود نشان داده‌اند (Chebbi et al., 2024).

^۱ Certified Crop Adviser (CCA)

^۲ Precision

^۳ Recall

^۴ F1 Score

^۵ Named Entity Recognition (NER)

^۶ Harmonic mean

^۷ Fine-tuned

- میانگین متوسط دقت (MAP/mAP)^۱: این معیار در زمینه‌های مختلف استفاده می‌شود و می‌تواند عملکرد مدل‌ها را در وظایفی مانند انتخاب پاسخ یا ارزیابی کلی یک سیستم کشاورزی هوشمند، مانند مدل تشخیص بیماری سنجد (*Elaeagnus angustifolia*)، مورد سنجش قرار دهد (Rezayi et al., 2024; Zhao et al., 2024).
- معیارهای تولید متن: برای ارزیابی روانی و دقت متون تولید شده توسط LLMها، از معیارهای استاندارد BLEU، ROUGE و BERTScore استفاده می‌شود. BLEU و ROUGE با مقایسه همپوشانی N-gram میان متن تولیدشده و پاسخ‌های مرجع، عملکرد مدل را ارزیابی می‌کنند؛ درحالی‌که BERTScore با بهره‌گیری از تعبیه‌سازی‌های BERT و محاسبه شباهت کسینوسی بین متن تولیدی و مرجع، دقت مدل را در حوزه‌های تخصصی می‌سنجد (Jiang et al., 2025).
- معیارهای کارایی عملیاتی^۲: «فریم بر ثانیه» (FPS)^۳ به‌عنوان یکی از شاخص‌های ارزیابی کارایی عملیاتی سیستم‌ها، از جمله مدل‌های تشخیص بیماری در حوزه کشاورزی، مورد استفاده قرار می‌گیرد (Zhao et al., 2024).

^۱ Mean Average Precision (MAP) / mAP

^۲ Operational efficiency metrics

^۳ Frames Per Second (FPS)

• معیارهای تأثیر کشاورزی^۱: فراتر از ارزیابی صرف عملکرد مدل، سنجش اثربخشی باید شامل معیارهای هدفمندی باشد که مستقیماً با خروجی‌های کشاورزی مرتبط هستند (Vizniuk et al., 2025):

○ افزایش عملکرد محصول: بررسی این‌که چگونه توصیه‌های مبتنی بر LLM‌ها، مانند برنامه‌ریزی آبیاری یا مدیریت آفات، منجر به بهبود عملکرد کلی محصول می‌شود.

○ بهره‌وری منابع: اندازه‌گیری کاهش مصرف منابعی مانند آب، کود یا آفت‌کش‌ها که از طریق تصمیم‌گیری مبتنی بر AI حاصل می‌شود

○ تأثیر اقتصادی: کمی‌سازی صرفه‌جویی در هزینه یا افزایش درآمد کشاورزان به‌واسطه مداخلات مبتنی بر LLM.

ارزیابی کیفی و مقایسه‌ای

• مقایسه با متخصصان انسانی (واقعیت زمینی^۲): ارزیابی‌های انجام‌شده توسط متخصصان انسانی اغلب به‌عنوان «واقعیت زمینی» در نظر گرفته می‌شوند که عملکرد LLM‌ها در برابر آن سنجیده می‌شود، به‌ویژه هنگام ارزیابی جنبه‌های پیچیده‌ای مانند آسیب‌پذیری مشاغل کشاورزی در برابر رباتیک‌سازی. این فرآیند شامل مقایسه سیستماتیک خروجی‌های LLM با قضاوت‌های متخصصان برای تحلیل میزان همسویی و شناسایی اختلافات احتمالی است. همچنین، ارزیابی انسانی برای سنجش ویژگی‌هایی نظیر

^۱ Agricultural impact metrics

^۲ Ground truth

روانی، حرفه‌ای بودن، غنای اطلاعاتی و قابلیت اجرایی متون تولیدشده مورد استفاده قرار می‌گیرد (Benos et al., 2025; Jiang et al., 2025).

- محک‌زنی^۱: LLMها با استفاده از آزمون‌های حوزه کشاورزی و مجموعه داده‌های محک‌زنی که به طور خاص از کشورهای مختلف انتخاب شده‌اند، ارزیابی می‌شوند. این رویکرد امکان مقایسه عملکرد مدل‌های مختلف را فراهم می‌کند (Gong and Li, 2025; Shaikh et al., 2025; Vizniuk et al., 2025).
- مطالعات موردی: مطالعات موردی، بینش‌های ارزشمندی درباره عملکرد LLMها ارائه می‌دهند. به عنوان مثال، یک مطالعه نشان داد که ادغام RAG باعث بهبود شباهت پاسخ‌ها در پرسش‌های تخصصی حوزه کشاورزی شده است (Vizniuk et al., 2025).
- مقایسه سیستماتیک: مطالعات، مقایسه‌های سیستماتیک میان LLMهای مختلف (مانند Gemini, Copilot, GPT-4 و Claude v2) و روش‌های متنوع (مانند تنظیم دقیق و RAG) را در وظایف کشاورزی انجام می‌دهند تا عملکرد نسبی آن‌ها را ارزیابی کنند (Benos et al., 2025; Chebbi et al., 2024; Gong and Li, 2025; Jiang et al., 2025; Rezayi et al., 2024).

¹ Benchmarking

سایر عوامل مهم در ارزیابی

- اثربخشی و کاربرد: اثربخشی کلی سیستم‌های پرسش و پاسخ کشاورزی به شدت به کیفیت و پوشش دانش ذخیره شده بستگی دارد (Yang et al., 2024). ارزیابی‌ها باید این جنبه را مدنظر قرار دهند.
- وفاداری به حوزه تخصصی و عملی بودن: ارزیابی‌های انسانی توسط متخصصان کشاورزی، کیفیت‌های ذهنی مانند حرفه‌ای بودن، غنای اطلاعاتی و قابلیت اجرایی را برای سنجش امکان‌سنجی عملی و دقت از منظر یک متخصص حوزه بررسی می‌کنند (Jiang et al., 2025). این ارزیابی‌ها با معیارهایی مانند BERTScore که به میزان اعتمادپذیری در حوزه تخصصی می‌پردازد، مرتبط هستند (Jiang et al., 2025).
- انصاف، تعصب، بررسی واقعیت و منطق: این مؤلفه‌ها به عنوان عوامل کلیدی در ارزیابی LLMها در نظر گرفته می‌شوند، به ویژه باتوجه به گسترش روزافزون کاربردهای آن‌ها. پژوهش‌های آینده باید بر کاهش سوگیری در مجموعه داده‌های کشاورزی تمرکز داشته باشند (Benos et al., 2025; Shaikh et al., 2024; Shaikh et al., 2025).
- اعتمادپذیری و قابلیت اطمینان: اطمینان از اینکه LLMهایی که در نقش ارائه دهنده‌گان مشاوره کشاورزی یا موتورهای جستجو به کار می‌روند، نتایجی دقیق، قابل اعتماد و اتکاپذیر ارائه می‌دهند، بسیار حائز اهمیت است (Shaikh et al., 2024; Shaikh et al., 2025).

- توضیح‌پذیری: پژوهش‌ها پیشنهاد می‌کنند که تمرکز بر تکنیک‌های AI توضیح‌پذیر می‌تواند به تبیین دلایل پیش‌بینی‌های خاص LLMها کمک کند که این امر به افزایش اعتماد و درک کاربران منجر می‌شود (Benos et al., 2025).

- ارزیابی اجزای سیستم: ارزیابی می‌تواند به مؤلفه‌های داخلی یک سیستم LLM نیز گسترش یابد؛ برای مثال، ارزیابی دستی کیفیت اطلاعات بازایی شده در یک تنظیم RAG (Jiang et al., 2025).

در زمینه LLMها در کشاورزی، ارزیابی به دلیل ویژگی‌های خاص این حوزه و نیاز به اطلاعات بسیار قابل اعتماد، فرآیندی پیچیده است. مرور پژوهش‌ها بر لزوم استفاده از معیارهایی تأکید دارد که فراتر از وظایف زبانی عمومی رفته و شامل شاخص‌هایی مرتبط با خروجی‌های کشاورزی باشند. همچنین، بر بهره‌گیری از مجموعه داده‌های اختصاصی کشاورزی و دانش تخصصی دامنه برای انجام ارزیابی‌های دقیق و مؤثر تأکید می‌شود. ماهیت دائماً در حال تغییر کاربردهای LLMها نیز چالش‌هایی را در ارزیابی ایجاد کرده و بر ضرورت تحقیقات مستمر در زمینه توسعه روش‌ها و معیارهای مناسب صحنه می‌گذارد.

فصل پنجم

چالش‌ها و ملاحظات

برای توسعه و پیاده‌سازی موفق LLMها در حوزه کشاورزی، مجموعه‌ای از چالش‌ها و ملاحظات اساسی وجود دارد که توجه به آن‌ها ضروری است. این چالش‌ها شامل محدودیت‌های فنی، مسائل مربوط به داده‌ها، نگرانی‌های اخلاقی و ملاحظات عملی مرتبط با پذیرش این فناوری می‌شوند.

چالش‌ها و محدودیت‌های فنی

- **توهم^۱ مدل و مسئله دقت:** یکی از چالش‌های اصلی، تمایل LLMهای عمومی به تولید محتوای بی‌اساس و غیرواقعی است که به آن «توهم» گفته می‌شود. این مشکل به‌ویژه زمانی آشکار می‌شود که مدل‌ها با شکاف‌های دانشی در حوزه کشاورزی مواجه می‌شوند و در نتیجه ممکن است اطلاعات نادرست یا گمراه‌کننده‌ای تولید کنند. به‌عنوان مثال، ارائه توصیه درباره ارقام زراعی نیازمند آگاهی از شرایط محلی کشت و شیوع آفات است؛ دانشی که اغلب در LLMهای عمومی وجود ندارد (Gong and Li, 2025; Jiang et al., 2025).

¹ Hallucination

(al., 2025; Yu and Lin, 2024). تضمین دقت و پایایی نتایج تولیدشده توسط LLMها برای جلوگیری از نتایج نادرست یا مضر در تصمیم‌گیری‌های کشاورزی، امری حیاتی است. این مهم نیازمند اعتبارسنجی خروجی‌ها توسط متخصصان و توسعه سیستم‌های پشتیبان تصمیم‌گیری هیبریدی است که در آن‌ها LLMها با مدل‌های سنتی مبتنی بر قواعد^۱ تلفیق می‌شوند (De Clercq et al., 2024; Gong and Li, 2025; Vizniuk et al., 2025).

- **فقدان دانش تخصصی حوزه:** اگرچه LLMهای عمومی در زمینه دانش عمومی عملکرد مناسبی دارند، اما هنگام مواجهه با دانش تخصصی کشاورزی—مانند شناسایی بیماری‌های گیاهی یا ارزیابی مراحل رشد—با محدودیت‌ها و خطاهایی مواجه هستند. عملکرد این مدل‌ها در درک مفاهیم تخصصی کشاورزی، به دلیل فقدان درک عمیق از اصطلاحات و دانش فنی این حوزه، غالباً رضایت‌بخش نیست (Yu and Lin, 2024; Yang et al., 2024). برای ارتقای سطح تخصص و انطباق بهتر این مدل‌ها با نیازهای حوزه کشاورزی، ضروری است که LLMها یا به طور دقیق بر روی مجموعه داده‌های منتخب کشاورزی تنظیم شوند، یا از ابتدا بر حجم گسترده‌ای از داده‌های کشاورزی پیش‌آموزش یابند (Gong and Li, 2025; Vizniuk et al., 2025).

- **هزینه محاسباتی:** آموزش بنیادین LLMها مستلزم منابع محاسباتی بسیار بالایی است که اغلب فراتر از توان مالی افراد یا شرکت‌های دارای بودجه محدود قرار دارد. حتی تنظیم دقیق این مدل‌ها یا بهره‌گیری از مولدهای

^۱ Traditional rule-based models

سبک‌وزن بصری^۱ در ترکیب با LLM‌های دیداری-زبانی نیز همچنان نیازمند توان محاسباتی قابل توجهی است (Li et al., 2024; Shaikh et al., 2024).

- **تفسیرپذیری و توضیح‌پذیری:** فقدان شفافیت در نحوه عملکرد LLM‌ها و وابستگی بالای نتایج آن‌ها به آرایه‌های داده‌های آموزشی، از جمله موانع اساسی محسوب می‌شود (Antoshchuk et al., 2025). شفافیت و توضیح‌پذیری از ویژگی‌های اساسی سیستم‌های پشتیبانی تصمیم‌گیری^۲ هستند که به توانایی تبیین استدلال‌های پشت تصمیمات اتخاذشده توسط LLM‌ها اشاره دارند (Vizniuk et al., 2025). درک و پیش‌بینی رفتار این مدل‌ها در محیط‌های واقعی تولید، حوزه‌ای است که همچنان نیازمند تحقیقات گسترده‌تر است (Chebbi et al., 2024).

- **چندزبانگی و کاربرد منطقه‌ای:** قابلیت انتقال توصیه‌ها و خروجی‌های LLM‌ها به مناطق جغرافیایی مختلف با شرایط اقلیمی، قانونی و کشاورزی متنوع، چالشی پیچیده محسوب می‌شود. عملکرد ضعیف افزونه‌های چندزبان و ضرورت در نظر گرفتن گویش‌ها و اصطلاحات فنی منطقه‌ای، بر پیچیدگی این مسئله می‌افزاید (Gong and Li, 2025; Kuska et al., 2024).

- **ادغام با سایر فناوری‌ها:** ادغام مؤثر LLM‌ها با فناوری‌های کلیدی کشاورزی، از جمله دستگاه‌های IoT برای تحلیل داده‌های زمان واقعی و KG‌ها برای بهره‌برداری از دانش ساختاریافته حوزه، مستلزم بررسی دقیق

^۱ Visual prompt generators

^۲ Decision Support Systems

خطوط لوله^۱ جمع‌آوری، پردازش و تحلیل داده‌ها است (Feng et al., 2024; Gong and Li, 2025).

چالش‌های مربوط به داده‌ها

- **کمیابی و کیفیت داده‌ها:** کمبود داده‌ها و پایگاه‌های دانش باکیفیت بالا در زمینه گفتگوهای مرتبط با کشاورزی همچنان یکی از چالش‌های اصلی محسوب می‌شود (Jiang et al., 2025). همچنین، پیچیدگی و ماهیت آشفته بسیاری از داده‌های وب، مانعی در دستیابی به نتایج مطلوب در وظایف مرتبط با کشاورزی ایجاد می‌کند (He, 2024). راه‌حل‌های مبتنی بر AI نیز اغلب تحت‌تأثیر محدودیت در کیفیت و جامعیت داده‌های آموزشی قرار دارند (Zhao et al., 2024). پرداختن به این مسائل برای توسعه مدل‌های قوی و مؤثر ضروری است (Li et al., 2024).
- **ناهمگونی و استانداردسازی داده‌ها:** حجم قابل‌توجهی از داده‌های ناهمگون که توسط دستگاه‌های IoT در کشاورزی جمع‌آوری می‌شود، چالش‌هایی در زمینه استانداردسازی و قابلیت همکاری ایجاد می‌کند و مانع از تبادل مؤثر داده‌ها می‌گردد (Akbar et al., 2024). استفاده از زبان‌های قابل‌درک برای انسان برای استانداردسازی داده‌های حسگر و تصاویر به‌عنوان راه‌حلی بالقوه مطرح شده است (Shaikh et al., 2025).
- **دسترسی به داده‌ها و مالکیت:** داده‌های کشاورزی اغلب تحت حفاظت هستند و امکان اشتراک‌گذاری آن‌ها بین سیستم‌ها یا خارج از شرکت‌های خاص وجود ندارد؛ موضوعی که مانعی در مسیر توسعه مدل‌ها به شمار

^۱ Pipelines

می‌آید. تدوین دستورالعمل‌ها و توسعه رویکردهایی برای یکپارچه‌سازی داده‌های قابل‌اعتماد، بدون تضعیف ادعای مالکیت، از اهمیت بالایی برخوردار است (Gong and Li, 2025; Kuska et al., 2024).

ملاحظات اخلاقی و اجتماعی

پیاده‌سازی LLM‌ها در بخش کشاورزی نیازمند توجه دقیق به مجموعه‌ای از ملاحظات اخلاقی، اجتماعی و عملی است. جدول (۲) خلاصه‌ای از این ملاحظات کلیدی را ارائه می‌دهد که باید در فرآیند توسعه و به‌کارگیری این فناوری‌ها مورد توجه قرار گیرند.

- **سوگیری^۱:** LLM‌ها ممکن است سوگیری‌های موجود در داده‌های آموزشی خود را بازتولید کرده و گسترش دهند. پایش و کاهش این سوگیری‌ها در کاربردهای کشاورزی برای تضمین نتایج منصفانه و بی‌طرفانه ضروری است. این مدل‌ها گاهی پتانسیل اتوماسیون در کشاورزی را بیش از حد تخمین می‌زنند که می‌تواند پیامدهایی بر بازار کار کشاورزی داشته باشد (Benos et al., 2025; De Clercq et al., 2024; Shaikh et al., 2024;) (Vizniuk et al., 2025).

- **گسترش اطلاعات نادرست:** با وجود توانایی LLM‌ها در ارائه بینش‌های ارزشمند، راهنمایی‌های آن‌ها در شرایطی که داده‌های آموزشی ناکافی یا متناقض هستند، می‌تواند گمراه‌کننده یا حتی مضر باشد. ایجاد سازوکارهای

¹ Bias

ایمنی برای جلوگیری از انتشار اطلاعات نادرست زراعی، اقدامی ضروری است (De Clercq et al., 2024).

- **حریم خصوصی و امنیت داده‌ها:** گردآوری حجم انبوهی از داده‌های مربوط به کشاورزان، نگرانی‌های مهمی درباره حریم خصوصی ایجاد می‌کند که باید از طریق چارچوب‌ها و دستورالعمل‌های مناسب مدیریت شوند. همچنین، امنیت داده‌ها یکی از چالش‌های اصلی در مسیر پذیرش گسترده LLM‌های کشاورزی است (De Clercq et al., 2024; Gong and Li, 2025).

- **تأثیر بر پویایی نیروی کار:** افزایش توانمندی‌های LLM‌ها و ادغام آن‌ها با فناوری‌های اتوماسیون، پرسش‌هایی را درباره تأثیرات احتمالی بر بازار کار کشاورزی مطرح می‌کند. گرچه این فناوری‌ها می‌توانند بهره‌وری را ارتقا دهند، اما باید تهدیدهای بالقوه برای مشاغل سنتی نیز مدنظر قرار گیرد (De Clercq et al., 2024; Marinoudi et al., 2024).

- **اعتماد و پذیرش:** تقویت اعتماد کشاورزان نسبت به LLM‌ها نیازمند شفاف‌سازی منشأ خروجی‌ها و فراهم‌سازی اطلاعات قابل اعتبارسنجی است. همچنین، اطمینان از حفظ مالکیت داده‌ها توسط کشاورزان برای افزایش پذیرش این فناوری‌ها اهمیت زیادی دارد (Gong and Li, 2025; Kuska et al., 2024; Shaikh et al., 2024).

ملاحظات عملی برای پیاده‌سازی

- نیاز به رابط‌های کاربرپسند: کشاورزان غالباً به مشاوره‌هایی دقیق و قابل فهم نیاز دارند. LLMها باید در رابط‌های مکالمه‌ای کاربرپسند ادغام شوند که بتوانند دانش علمی پیچیده را به زبانی ساده و قابل درک ترجمه کنند (De Clercq et al., 2024; Tzachor et al., 2023).
- ادغام با جریان‌های کاری موجود: پذیرش مؤثر LLMها در کشاورزی مستلزم ادغام یکپارچه آن‌ها در شیوه‌های جاری کشاورزی و فرآیندهای تصمیم‌گیری موجود است (Marinoudi et al., 2024).
- پرداختن به سواد دیجیتال و دسترسی: سطح پایین سواد دیجیتال و دسترسی محدود به اینترنت در میان خرده‌مالکان در برخی مناطق، موانعی برای پذیرش گسترده خدمات ترویج دیجیتال مبتنی بر LLMها ایجاد می‌کند. در این زمینه، استفاده از جایگزین‌های کم‌فناوری^۱ مانند پیامک و سامانه‌های پاسخ صوتی تعاملی باید مورد توجه قرار گیرد (Tzachor et al., 2023).
- چارچوب‌های نظارتی: رشد سریع LLMها نیازمند توجه سیاست‌گذاران کشاورزی به طراحی دقیق چارچوب‌ها و دستورالعمل‌هایی است که استفاده مسئولانه از این فناوری‌ها را در بخش تولید مواد غذایی، پیش از گسترش فراگیر آن‌ها، تضمین کند (De Clercq et al., 2024).

^۱ Low-tech

جدول ۲. مرور برخی از ملاحظات کلیدی در توسعه و به‌کارگیری مدل‌های زبانی بزرگ (LLMها) تخصصی در حوزه کشاورزی	
ملاحظه	توضیح
سوگیری	تداوم سوگیری‌های موجود در داده‌های آموزشی و ارزیابی بیش از حد ظرفیت اتوماسیون، با پیامدهایی برای بازار کار کشاورزی.
گسترش اطلاعات نادرست	احتمال ارائه راهنمایی نادرست به‌ویژه در مناطقی با داده‌های محدود یا متناقض.
حریم خصوصی و امنیت	ضرورت محافظت از داده‌های کشاورزان و تضمین امنیت اطلاعات آن‌ها.
تأثیر بر نیروی کار	امکان تغییر در ساختار اشتغال کشاورزی در نتیجه گسترش فناوری‌های خودکار.
اعتماد و پذیرش	نیاز به شفاف‌سازی منشأ اطلاعات و حفظ کنترل کشاورزان بر داده‌های خود.
رابط کاربری	نیاز به طراحی رابط‌های ساده و کاربرپسند برای تسهیل درک اطلاعات پیچیده.
ادغام با فرآیندهای موجود	لزوم یکپارچه‌سازی LLMها با جریان‌های کاری رایج در بخش کشاورزی.
دسترسی و سواد دیجیتال	توجه به محدودیت‌های مربوط به سواد دیجیتال و دسترسی به اینترنت، به‌ویژه در میان خرده‌مالکان.
چارچوب‌های نظارتی	ضرورت تدوین مقررات مناسب برای تضمین استفاده مسئولانه از LLMها.

پرداختن به این چالش‌های چندبعدی و توجه جدی به این عوامل، برای تحقق ظرفیت تحول‌آفرین LLMها در ایجاد بخش کشاورزی کارآمدتر، پایدارتر و مقاوم‌تر در برابر بحران‌ها، ضروری است. همکاری میان پژوهشگران، سیاست‌گذاران و فعالان بخش کشاورزی، در این مسیر حیاتی خواهد بود.

فصل ششم

مسیرهای تحقیقاتی و چشم‌اندازهای آینده

حوزه LLMها در کشاورزی همچنان در مراحل اولیه توسعه قرار دارد و مسیرهای متعددی برای پژوهش‌های آتی وجود دارد که نویدبخش پیشرفت‌های چشمگیر هستند:

- توسعه بیشتر مدل‌های زبانی تخصصی برای کشاورزی، از جمله مدل‌های زبانی بصری با قابلیت‌های پیشرفته‌تر.
- بهبود ادغام LLMها با دستگاه‌های IoT، KGها و سایر فناوری‌های AI.
- پرداختن به چالش‌هایی همچون کمبود داده، توهم‌زایی مدل، سوگیری و فقدان اعتماد.
- طراحی و توسعه معیارهای ارزیابی دقیق و سیستم‌های محک‌زنی برای ارزیابی عملکرد LLMهای کشاورزی.
- بررسی عمیق پیامدهای اخلاقی و اجتماعی ناشی از پذیرش گسترده این فناوری‌ها در بخش کشاورزی.

- گسترش حوزه کاربرد LLM‌ها به منظور پوشش طیف وسیع‌تری از فعالیت‌های کشاورزی، نظیر آموزش شخصی‌سازی‌شده، بهینه‌سازی تناوب زراعی و تحلیل هوشمند بازار.
- تمرکز بر تولید منابع اطلاعاتی قابل اعتماد و قابل تأیید برای آموزش و به‌روزرسانی LLM‌ها.
- توسعه ابزارها و رابط‌های کاربرپسند به منظور توانمندسازی کشاورزان و تسهیل تعامل آن‌ها با LLM‌ها.

در مجموع، LLM‌ها ظرفیت قابل توجهی برای ارتقای کشاورزی هوشمند از طریق بهبود تجزیه و تحلیل داده، تصمیم‌گیری و دسترسی به دانش دارند. ادامه تحقیق و توسعه، همراه با تمرکز بر غلبه بر محدودیت‌های کنونی و بهره‌برداری از توانایی‌های این فناوری، برای تحقق کامل پتانسیل LLM‌ها در ایجاد بخش کشاورزی کارآمدتر، پایدارتر و انعطاف‌پذیرتر، ضروری خواهد بود.

فصل هفتم

جمع‌بندی و نتیجه‌گیری

LLMها آماده‌اند تا با ارائه قابلیت‌های پیشرفته در پردازش داده، تسهیل انتقال دانش و پشتیبانی از تصمیم‌گیری، تحولی معنادار در بخش کشاورزی ایجاد کنند. کاربردهای آنها متنوع است و از تجزیه و تحلیل داده‌های چندوجهی مانند تصاویر و متون، برای وظایف حیاتی نظیر شناسایی بیماری‌های محصولات کشاورزی و پایش مراحل رشد، تا ایفای نقش به‌عنوان سیستم‌های هوشمند پرسش و پاسخ دانش کشاورزی و ابزارهای مشاوره‌ای گسترش می‌یابد. LLMها می‌توانند دانش علمی را ساده‌سازی کرده و مشاوره‌های کشاورزی شخصی‌سازی شده ارائه دهند، مقررات پیچیده و اسناد حقوقی مرتبط با کشاورزی را تفسیر کنند، به مستندسازی و گزارش‌دهی خودکار کمک کنند، روندهای بازار را تحلیل کرده و تغییرات در عرضه و تقاضا را پیش‌بینی کنند و یکپارچه‌سازی با سیستم‌های پشتیبانی تصمیم‌گیری را برای بهینه‌سازی وظایفی مانند پیش‌بینی عملکرد محصول و مدیریت آفات تسهیل نمایند. این مدل‌ها همچنین قابلیت یکپارچه‌سازی با دستگاه‌های IoT را دارند تا داده‌های محیطی و زراعی بلادرنگ را تحلیل کرده و بینش‌هایی برای مدیریت منابع

ارائه دهند و در وظایفی همچون خدمات مشتری خودکار و ترجمه متون زراعی نیز مؤثر واقع شوند.

تکنیک‌ها و مدل‌های مختلفی برای بهره‌برداری از LLMها در بخش کشاورزی در حال بررسی هستند. این‌ها مدل‌ها شامل نمونه‌های عمومی مانند GPT، LLaMA و Gemini می‌شوند که معمولاً با داده‌های کشاورزی تنظیم دقیق می‌شوند تا دانش تخصصی این حوزه را تقویت کنند. مدل‌های چندوجهی، مانند AgriVLM و LLMهای بصری، برای تجزیه و تحلیل داده‌های ترکیبی تصویر و متن که در کشاورزی رایج است، نقش حیاتی ایفا می‌کنند. تکنیک‌هایی مانند SFT، از جمله SFT هماهنگ با دانش و همچنین RAG برای گنجاندن دانش دامنه‌ای کشاورزی و بهبود دقت پاسخ‌دهی به کار گرفته می‌شوند که اغلب با استفاده از پایگاه‌های دانش خارجی انجام می‌شود. افزون بر این، یکپارچه‌سازی با فناوری‌هایی نظیر IoT برای جمع‌آوری داده، KGها برای ارائه اطلاعات ساختاریافته و بازیابی و بینایی ماشین^۱ برای تجزیه و تحلیل داده‌های بصری، قابلیت‌های کاربردی این مدل‌ها را بیش‌ازپیش افزایش می‌دهد.

علی‌رغم پتانسیل امیدوارکننده، چالش‌ها و ملاحظات متعددی برای پذیرش گسترده LLMها در کشاورزی وجود دارد. LLMهای عمومی اغلب در پوشش دانش تخصصی این حوزه محدودیت دارند که می‌تواند منجر به عملکرد نامطلوب در وظایف تخصصی و تولید اطلاعات نادرست یا غیرواقعی (توهم‌زایی) شود. کمبود داده‌های باکیفیت نیز یکی از موانع اساسی است، زیرا مجموعه داده‌های مناسب برای بهینه‌سازی و آموزش دقیق LLMها در حوزه کشاورزی همچنان محدود هستند.

^۱ Computer vision

تضمین قابلیت اعتماد، توضیح‌پذیری و کاهش سوگیری در خروجی مدل‌ها برای جلب اعتماد کشاورزان و پیشگیری از مشاوره‌های زیان‌بار، ضروری است. از دیگر چالش‌های اساسی می‌توان به اعتبارسنجی عملیاتی بودن این مدل‌ها در شرایط واقعی و پیچیده کشاورزی، اطمینان از تطبیق‌پذیری توصیه‌ها با شرایط محلی، مدیریت هزینه‌های محاسباتی، حفظ قابلیت اتکای داده‌ها، توجه به نگرانی‌های مربوط به حریم خصوصی و غلبه بر پیچیدگی‌های فنی در یکپارچه‌سازی با سامانه‌های موجود اشاره کرد.

References

- Antoshchuk, S. G., Kunup, T. V., Lytvynenko, V. I., & Danchuk, O. V. (2025). Using large language models for video processing in the agricultural industry. *Applied Aspects of Information Technology*, 8(1), 88–101. <https://doi.org/10.15276/aait.08.2025.7>
- Akbar, N. A., Lenzitti, B., & Tegolo, D. (2024, November). A Novel Approach for Leveraging Agent-Based Experts on Large Language Models to Enable Data Sharing Among Heterogeneous IoT Devices in Agriculture. In *International Conference of the Italian Association for Artificial Intelligence* (pp. 12-22). Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-80607-0_2
- Banerjee, S., Das, S., & Mondal, A. C. (2024). A Study of the Application Domain of a Large Language Models in the Agricultural Sector. *International Journal of Innovative Research in Computer Science and Technology*, 12(5). <https://doi.org/10.55524/ijirest.2024.12.5.10>
- Benos, L., Marinoudi, V., Busato, P., Kateris, D., Pearson, S., & Bochtis, D. (2025). Benchmarking Large Language Models in Evaluating Workforce Risk of Robotization: Insights from Agriculture. *AgriEngineering*, 7(4), 102. <https://doi.org/10.3390/agriengineering7040102>

- Chebbi, A., Kniesel, G., Abdennadher, N., & Dimarzo, G. (2024, April). Enhancing named entity recognition for agricultural commodity monitoring with large language models. In *Proceedings of the 4th Workshop on Machine Learning and Systems* (pp. 208-213). <https://doi.org/10.1145/3642970.3655846>
- De Clercq, D., Nehring, E., Mayne, H., & Mahdi, A. (2024). Large language models can help boost food production, but be mindful of their risks. *Frontiers in Artificial Intelligence*, 7, 1326153. <https://doi.org/10.3389/frai.2024.1326153>
- Feng, T., Shen, H., Yang, X., Nianga, J. M., & Wang, Z. (2024). Integration of large language models with IoT in smart agriculture to improve efficiency, yield, and quality. *Industry Science and Engineering*, 1, 15-35.
- Gong, R., & Li, X. (2025). The application progress and research trends of knowledge graphs and large language models in agriculture. *Computers and Electronics in Agriculture*, 235, 110396. <https://doi.org/10.1016/j.compag.2025.110396>
- He, X. (2024). *Enhancing agriculture QA models using large language models*. BIO Web of Conferences, 142, 01005. <https://doi.org/10.1051/bioconf/202414201005>
- Jiang, J., Yan, L., Liu, H., Xia, Z., Wang, H., Yang, Y., & Guan, Y. (2025). Knowledge assimilation: Implementing knowledge-guided agricultural large language model. *Knowledge-based systems*, 314, 113197. <https://doi.org/10.1016/j.knosys.2025.113197>
- Khanifar, J. (2025). Evaluating AI-Generated Responses from Different Chatbots to Soil Science-Related Questions. *Soil Advances*, 100034. <https://doi.org/10.1016/j.soilad.2025.100034>
- Kuska, M. T., Wahabzada, M., & Paulus, S. (2024). AI for crop production—Where can large language models (LLMs) provide

- substantial value?. *Computers and electronics in agriculture*, 221, 108924. <https://doi.org/10.1016/j.compag.2024.108924>
- Li, J., Xu, M., Xiang, L., Chen, D., Zhuang, W., Yin, X., & Li, Z. (2024). Foundation models in smart agriculture: Basics, opportunities, and challenges. *Computers and Electronics in Agriculture*, 222, 109032. <https://doi.org/10.1016/j.compag.2024.109032>
- Marinoudi, V., Benos, L., Villa, C. C., Kateris, D., Berruto, R., Pearson, S., ... & Bochtis, D. (2024). Large language models impact on agricultural workforce dynamics: Opportunity or risk?. *Smart Agricultural Technology*, 9, 100677. <https://doi.org/10.1016/j.atech.2024.100677>
- Muller, J., Petti, D., Li, C., Gorucu, S., Pilz, M., & Weichelt, B. P. (2025). Large Language Models for Agricultural Injury Surveillance. *Safety*, 11(1), 15. <https://doi.org/10.3390/safety11010015>
- Rezayi, S., Liu, Z., Wu, Z., Dhakal, C., Ge, B., Dai, H., ... & Li, S. (2024). Exploring new frontiers in agricultural nlp: Investigating the potential of large language models for food applications. *IEEE Transactions on Big Data*. <https://doi.org/10.1109/TBDDATA.2024.3442542>
- Shaikh, T. A., Rasool, T., Veningston, K., & Yaseen, S. M. (2024). The role of large language models in agriculture: harvesting the future with LLM intelligence. *Progress in Artificial Intelligence*, 1-48. <https://doi.org/10.1007/s13748-024-00359-4>
- Shaikh, T. A., Rasool, T., & Mir, W. A. (2025). Fields of the Future: Digital Transformation in Smart Agriculture with Large Language Models and Generative AI. *Computer Standards & Interfaces*, 104005. <https://doi.org/10.1016/j.csi.2025.104005>
- Tzachor, A., Devare, M., Richards, C., Pypers, P., Ghosh, A., Koo, J., ... & King, B. (2023). Large language models and agricultural extension

- services. *Nature food*, 4(11), 941-948. <https://doi.org/10.1038/s43016-023-00867-x>
- Vizniuk, A., Diachenko, G., Laktionov, I., Siwocha, A., Xiao, M., & Smolag, J. (2025). A Comprehensive Survey of Retrieval-Augmented Large Language Models for Decision Making in Agriculture: Unsolved Problems and Research Opportunities. *Journal of Artificial Intelligence and Soft Computing Research*, 15(2), 115-146. <http://doi.org/10.2478/jaiscr-2025-0007>
- Yang, T., Mei, Y., Xu, L., Yu, H., & Chen, Y. (2024). Application of question answering systems for intelligent agriculture production and sustainable management: A review. *Resources, Conservation and Recycling*, 204, 107497. <https://doi.org/10.1016/j.resconrec.2024.107497>
- Yu, P., & Lin, B. (2024). A Framework for Agricultural Intelligent Analysis Based on a Visual Language Large Model. *Applied Sciences*, 14(18), 8350. <https://doi.org/10.3390/app14188350>
- Yuan, Z., Liu, K., Peng, R., Li, S., Leybourne, D., Musa, N., ... & Yang, P. (2024). PestGPT: Leveraging Large Language Models and IoT for Timely and Customized Recommendation Generation in Sustainable Pest Management. *IEEE Internet of Things Magazine*, 8(1), 26-33. <http://doi.org/10.1109/IOTM.001.2400036>
- Zhao, X., Chen, B., Ji, M., Wang, X., Yan, Y., Zhang, J., ... & Lv, C. (2024). Implementation of Large Language Models and Agricultural Knowledge Graphs for Efficient Plant Disease Detection. *Agriculture*, 14(8), 1359. <https://doi.org/10.3390/agriculture14081359>

Abstract

Large Language Models (LLMs) are among the most significant advancements in artificial intelligence (AI), offering powerful capabilities in natural language understanding and generation. Their applications have expanded into various domains, including agriculture, where they are accelerating the transition to smart agriculture. This book presents a comprehensive review of the concepts, applications, techniques, and challenges related to the use of LLMs in the agricultural sector. General-purpose large-scale models—such as GPT, Claude, Gemini, and LLaMA—can process text, images, and sensor data, and can be applied to tasks such as expert advisory, intelligent crop management (including plant growth monitoring, disease and pest detection, irrigation and fertilization optimization, and yield prediction), agricultural big data analysis, documentation automation, and question-answering systems. However, the need for domain-specific expertise often necessitates the adaptation of these models. In response, specialized models—such as AgriVLM, AgriBERT, KALLM, and PLLaMa—have been developed or fine-tuned for agricultural use. Key techniques to improve LLM performance in this domain include fine-tuning or pre-training with agricultural datasets, using retrieval-augmented generation (RAG) to incorporate specialized knowledge, integrating knowledge graphs, employing vision-language models for multimodal data analysis, and leveraging Internet of Things (IoT) systems. Beyond technical approaches, robust evaluation of LLM performance in agriculture is critical for

establishing trust and ensuring practical viability. This includes metrics such as accuracy, precision, F1 score, text generation quality (e.g., BLEU, ROUGE, and BERTScore), resource efficiency, benchmarking, and comparisons with expert evaluations. Despite their promise, LLMs face challenges such as limited high-quality agricultural data, the risk of misinformation, lack of deep domain expertise in general models, high computational costs, concerns about interpretability and reliability, potential biases, data privacy issues, and labor implications. Nonetheless, LLMs offer transformative potential—enhancing productivity, improving crop yields, promoting sustainability, and enabling data-driven decision-making in agriculture. Continued research into domain-specific model development, integration with complementary technologies, addressing existing limitations, and exploring ethical and social impacts remains essential.

Keywords: Artificial Intelligence (AI), Machine Learning, Generative AI, Large Language Models (LLMs), Smart Agriculture.

Large Language Models in AI-Driven Agriculture

Javad Khanifar (Ph.D.)

2025