

کاربرد هوش مصنوعی عمومی AGI در حوزه کشاورزی



چکیده

هوش مصنوعی عمومی (Artificial General Intelligence- AGI) آماده است تا انقلابی در بخش‌های مختلف از جمله مراقبت‌های بهداشتی، مالی، حمل و نقل و آموزش ایجاد کند. در مراقبت‌های بهداشتی، AGI برای تجزیه و تحلیل یادداشت‌های پزشکی بالینی، تشخیص الگوها در داده‌های بیمار و کمک به مدیریت بیمار استفاده می‌شود. کشاورزی یکی دیگر از بخش‌های حیاتی است که بر زندگی افراد در سراسر جهان تأثیر می‌گذارد. این به عنوان پایه‌ای برای تامین غذا، فیبر و سوخت عمل می‌کند، اما با چالش‌های متعددی مانند تغییرات آب و هوا، تخریب خاک، کمبود آب و امنیت غذایی مواجه است.

AGI این پتانسیل را دارد که با افزایش عملکرد محصول، کاهش ضایعات و ترویج شیوه‌های کشاورزی پایدار با این مسائل مقابله کند. همچنین می‌تواند به کشاورزان در تصمیم‌گیری آگاهانه با استفاده از داده‌های بلادرنگ کمک کند و منجر به مدیریت کارآمدتر و مؤثرتر مزرعه شود.

این مقاله به کاربردهای بالقوه آینده (Artificial General Intelligence (AGI) در کشاورزی، مانند پردازش تصویر کشاورزی، پردازش زبان طبیعی ((Natural language processing (NLP)، روباتیک، نمودارهای دانش (Knowledge charts)، و زیرساخت و تأثیر آنها بر دام‌های دقیق و محصولات دقیق می‌پردازد. با استفاده از قدرت AGI، این فناوری‌های نوظهور می‌توانند بینش‌های عملی را در اختیار کشاورزان قرار دهند و

امکان تصمیم‌گیری بهینه و افزایش بهره‌وری را فراهم کند. پتانسیل تحول آفرین AGI در کشاورزی بسیار زیاد است و هدف این مقاله برجسته کردن پتانسیل آن برای متحول کردن صنعت است.

۱. مقدمه

از زمانی که برنامه هوش مصنوعی AlphaGo استادان World Go را شکست داد، هوش مصنوعی دوباره به موضوع داغ تبدیل شد، به ویژه پس از انتشار ChatGPT و GPT-۴. هوش مصنوعی عمومی (AGI) این است که ماشین‌ها می‌توانند مانند انسان فکر کنند و بسیاری از وظایف عمومی را با استفاده از انتقال یادگیری و روش‌های مختلف دیگر انجام دهند. در چند سال گذشته، مدل‌های زبان بزرگ (LLMs) مانند GPT-۳,۵ مورد استفاده در ChatGPT توجه و علاقه زیادی را به خود جلب کرده است. اخیراً، GPT-۴ یک زبان و سیستم بینایی چندوجهی با قابلیت تشخیص و توصیف تصاویر است. پس از راه اندازی، با توانایی خود برای مطابقت با هوش انسانی همه را تحت تاثیر قرار می‌دهد. انتظار می‌رود با توسعه بیشتر، AGI تأثیرات عمیق‌تر و گسترده‌تری بر کشاورزی داشته باشد.

علیرغم اینکه کشاورزی به عنوان یک رکن اساسی برای توسعه اقتصادی ملی و جهانی شناخته شده است، و با توجه به اهمیت کشاورزی به عنوان یکی از اجزای حیاتی در جهان ادبیات علمی در مورد اجرای هوش مصنوعی (AI)، به ویژه هوش مصنوعی عمومی (AGI)، در کشاورزی نسبتاً اندک است.

امنیت غذایی و پتانسیل هوش مصنوعی برای افزایش بهره‌وری و پایداری کشاورزی، با توسعه سریع اخیر AGI، انتظار می‌رود که نقش مهمی در کاربردهای کشاورزی آینده داشته باشد. بنابراین در این مقاله به کاربردهای AGI در کشاورزی می‌پردازیم.

در زمینه کشاورزی، فناوری AGI همچنین می‌تواند توسعه طیف گسترده‌ای از کاربردها، مانند شناسایی آفات، تشخیص بیماری و غیره را امکان‌پذیر و ترویج کند. استفاده از حسگرها و الگوریتم‌های پیشرفته برای تجزیه و تحلیل داده‌ها و بهینه‌سازی عملکرد محصول می‌باشد.

کاربرد بینایی کامپیوتری: عمدتاً شامل تشخیص هدف، تقسیم‌بندی تصویر، محلی‌سازی و طبقه‌بندی تصویر است. همچنین فناوری بینایی کامپیوتر را در زمینه‌های عمیق‌تر و گسترده‌تر به کار گیرد.

فناوری AGI می‌تواند به کشاورزان کمک کند تا تصمیمات آگاهانه‌ای در مورد آبیاری، کود دهی و سایر روش‌های کشاورزی بگیرند که منجر به افزایش بهره‌وری و کارایی می‌شود.

AGI می‌تواند در توسعه انواع محصولات جدید از طریق اصلاح محاسباتی، روند توسعه محصولات انعطاف پذیرتر و پرمحصول، را سرعت بخشد.

یکی دیگر از کاربردهای بالقوه AGI در کشاورزی در اتوماسیون مزرعه است، جایی که ربات‌ها و هواپیماهای بدون سرنشین مجهز به بینایی کامپیوتری پیشرفته و قابلیت‌های یادگیری ماشینی می‌توانند طیف وسیعی از وظایف را از کاشت و برداشت گرفته تا نظارت بر محصولات کشاورزی و دام انجام دهند. در مقایسه

با روش‌های مبتنی بر بینایی کامپیوتر اصلی یا سایر روش‌های مبتنی بر هوش مصنوعی (به عنوان مثال، هوش باریک مصنوعی)، AGI به طور بالقوه می‌تواند جامع‌تر، هوشمندتر و بیشتر ارائه دهد.

قابل ذکر است، AGI می‌تواند در توسعه کشاورزی از روش‌های مختلف مانند تصاویر، صدا، روباتیک، نمودار دانش، NLP و غیره پشتیبانی کند و به طور بالقوه آنها را برای حمایت از تصمیم‌گیری ترکیب کند. یک تفاوت مهم بین AGI و AI در کشاورزی، توانایی آنها برای تعمیم و یادگیری از موقعیت‌های جدید است.

سیستم‌های AGI توانایی انتقال یادگیری از یک حوزه به حوزه دیگر و سازگاری با موقعیت‌های جدید را بدون دخالت انسان دارند. این بدان معنی است که AGI می‌تواند از داده‌ها و تجربیات جدید به گونه‌ای بیاموزد که هوش مصنوعی نمی‌تواند. از یک طرف، AGI می‌تواند برنامه‌های گسترده جدید را فعال کند. از سوی دیگر، AGI می‌تواند عملکرد سیستم‌های هوش مصنوعی موجود را در کارهای مشابه به میزان قابل توجهی افزایش دهد.

AGI این پتانسیل را دارد که شیوه تعامل کشاورزان با روبات‌های کشاورزی را متحول کند. با استفاده از پردازش زبان طبیعی و یادگیری ماشینی، AGI می‌تواند ربات‌ها را قادر به درک و پاسخگویی به فرمان‌های انسان، چه از طریق صدا و چه از طریق متن باشد. این امر به ساده‌سازی عملکرد روبات‌های کشاورزی، کاهش زمان یادگیری برای کاربران جدید و دسترسی بیشتر کشاورزان به آنها کمک می‌کند. یکی از کاربردهای بالقوه AGI در کشاورزی، توسعه دستیاران کشاورزی هوشمند است که می‌توانند وظایفی مانند کاشت، آبیاری و برداشت محصولات را در پاسخ به دستورات زبان طبیعی انجام دهند. این دستیاران می‌توانند از الگوریتم‌های یادگیری ماشینی برای بهینه‌سازی توصیه‌های خود بر اساس داده‌های بلادرنگ از مزرعه استفاده کنند و با ترجیحات کشاورزان تطبیق دهند.

AGI همچنین می‌تواند هماهنگی و همکاری روبات‌ها را برای بهینه‌سازی عملیات مزرعه تسهیل کند. برای مثال، ربات‌های مجهز به AGI می‌توانند برای اولویت‌بندی وظایف، بهینه‌سازی استفاده از منابع و جلوگیری از برخورد و سایر حوادث با یکدیگر ارتباط برقرار کنند. AGI با فعال کردن روبات‌ها برای همکاری مؤثرتر با یکدیگر، می‌تواند به کشاورزان کمک کند بهره‌وری خود را افزایش دهند، هزینه‌ها را کاهش دهند و از منابع خود بهتر استفاده کنند.

برای اصلاح نژاد و فنوتیپ، با تجزیه و تحلیل حجم زیادی از داده‌های فنومیک و ژنومی و سایر عوامل محیطی، AGI می‌تواند به پرورش دهندگان کمک کند تا امیدوارکننده‌ترین صفات گیاهی یا حیوانی را با دقت و کارایی بیشتر نسبت به روش‌های سنتی شناسایی و انتخاب کنند.

بر اساس نیازهای اصلاح‌کنندگان، AGI احتمالاً می‌تواند مدل‌های پیش‌بینی‌کننده‌ای ایجاد کند تا عملکرد ترکیب‌های اصلاحی مختلف را بر اساس داده‌های فنومیک و ژنومی و سایر عوامل مرتبط پیش‌بینی کند. این مدل‌ها می‌توانند از الگوریتم‌های یادگیری ماشینی برای بهینه‌سازی استراتژی‌های پرورش و پیش‌بینی نتیجه ترکیب‌های مختلف پرورش استفاده کنند.

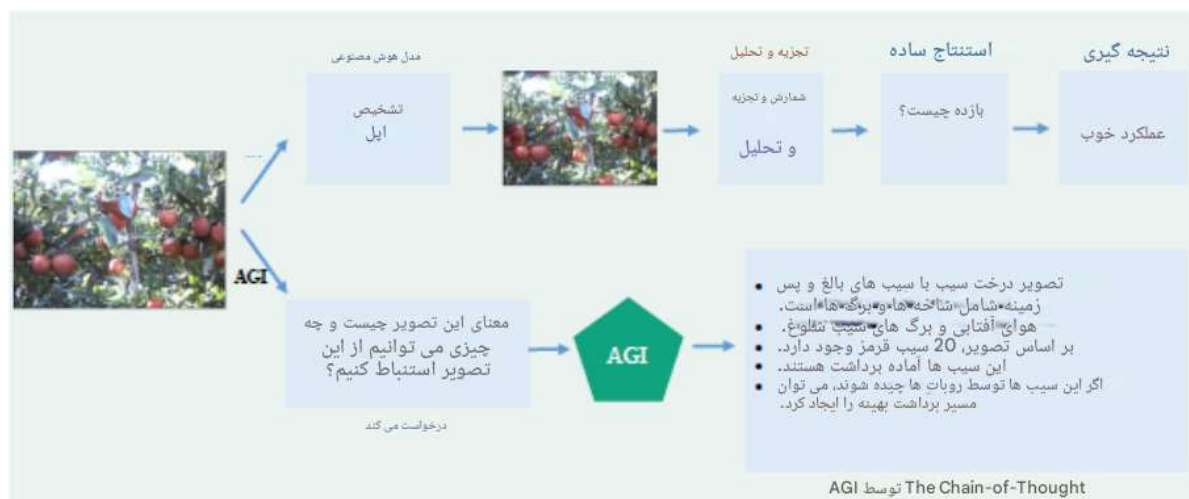
تأثیرات آشکارتر، گسترده‌تر و سریع‌تر که AGI می‌تواند برای کشاورزی به ارمغان بیاورد، توانایی آن برای افزایش اثربخشی سیستم‌های AI موجود است. به عنوان مثال می‌توان به شناسایی انواع آفات و بیماری‌های محصولات زراعی اشاره کرد. بیماری‌های زراعی و آفات حشرات یکی از بلاهای اصلی در کشاورزی است. آنها دارای ویژگی‌های انواع مختلف، تأثیر زیاد و شیوع مکرر هستند. در حال حاضر اکثر کشاورزان به منظور کنترل آفات و بیماری‌ها اقدام به سم‌پاشی کورکورانه می‌کنند که به ناچار باعث ایجاد یک سری بیماری‌ها می‌شود.

مشکلاتی مانند آلودگی محیط زیست و ایمنی مواد غذایی. علاوه بر این، شناسایی بیماری‌های محصول و آفات حشرات عمدتاً به تجربه کشاورزان و کارشناسان بستگی دارد. هنگامی که با نظارت در مقیاس بزرگ بیماری‌های محصولات کشاورزی و آفات حشرات سروکار داریم، سیستم‌های هوش مصنوعی فعلی باید به داده‌هایی تکیه کنند که قبلاً به خوبی برچسب‌گذاری شده‌اند تا به طور جامع آموزش ببینند. از دست دادن اقدامات نجات و بهترین زمان برای محصولات بیمار آسان است. فناوری AGI می‌تواند آستانه شناسایی انواع بیماری‌های محصول و آفات حشرات را کاهش دهد. کشاورزان می‌توانند با تلفن همراه خود از بیماری‌های گیاهی عکس بگیرند و سپس آنها را در مدل AGI آپلود کنند. AGI قادر خواهد بود دستورالعمل‌های ورودی را درک کند و به کشاورزان بگوید که چگونه آفات و بیماری‌های شناسایی شده را مدیریت کنند، به عنوان مثال، کدام آفت کش را بخرند. علاوه بر این، کشاورزان همچنین می‌توانند صدای آفات در مزرعه را با تجهیزات ضبط، ضبط کرده و آنها را در مدل AGI بارگذاری کنند. سپس AGI می‌تواند ویژگی‌های صوتی آفات را تشخیص دهد و برای شناسایی آفات محصول، تشخیص گفتار را انجام دهد. برخلاف الگوریتم‌های معمولی هوش مصنوعی و CV، به ویژه، AGI می‌تواند به کشاورزان کمک کند تا آفات و بیماری‌های ناشناخته قبلی را با یادگیری از داده‌های جدید و شناخت الگوهایی که ممکن است برای انسان‌ها آشکار نباشد، شناسایی کنند. این توانایی برای تعمیم و یادگیری از موقعیت‌های جدید می‌تواند به طور قابل توجهی اثربخشی راه‌حل‌های کشاورزی را افزایش دهد و انعطاف‌پذیری کلی صنعت را بهبود بخشد.

در سناریوی دیگر، علف‌های هرز از نظر رنگ شبیه به محصولات هستند و رشد آنها نیز به نور خورشید و منابع آب نیاز دارد. علف‌های هرز به فضای زندگی محصولات هجوم می‌آورند و مواد مغذی را از محصولات می‌ربایند. اگر تراکم علف‌های هرز در مزرعه بیش از حد باشد، بر عملکرد و کیفیت محصولات زراعی تأثیر جدی خواهد گذاشت. بنابراین وجین هرز جزء اجتناب‌ناپذیر و مهم تولیدات کشاورزی است. فناوری AGI اکنون می‌تواند به افراد کمک کند تا از شر علف‌های هرز خلاص شوند. AGI این پتانسیل را دارد که از سیستم‌های هوش مصنوعی سنتی بهتر عمل کند. AGI را می‌توان برای شناسایی و تمایز بین گیاهان و علف‌های هرز آموزش داد و سپس به طور انتخابی علف‌های هرز را بدون آسیب رساندن به محصولات حذف کرد. این امر از طریق استفاده از بینایی رایانه‌ای پیشرفته و الگوریتم‌های یادگیری ماشینی امکان‌پذیر است که به AGI امکان می‌دهد موقعیت‌ها و داده‌های جدید را تشخیص دهد و به آنها پاسخ دهد. از یک طرف، از طریق دید همه‌منظوره و قابلیت‌های استدلال در فناوری AGI، افراد می‌توانند علف‌های هرز را دقیقاً مکان‌یابی کنند، کشاورزان را برای رسیدن سریع

به منطقه رشد علف‌های هرز راهنمایی کنند، و کشاورزان را از آفت‌کش‌های مناسب آگاه کنند، به طوری که بتوانند پاسخ‌های متفاوتی به موارد مختلف داشته باشند.

سیستم‌های سنتی AI برای وجین معمولاً بر قوانین از پیش برنامه‌ریزی شده و مجموعه داده‌های محدودی تکیه می‌کنند که ممکن است نتوانند با موقعیت‌های جدید سازگار شوند یا گونه‌های علف‌های هرز در حال ظهور را تشخیص دهند. سیستم‌های AGI می‌توانند از تجربیات خود بیاموزند و با داده‌های جدید سازگار شوند و به آنها امکان می‌دهد در طول زمان دقیق‌تر و کارآمدتر شوند. راه دیگر اتصال AGI به ربات‌های هوشمند است تا ربات‌ها بتوانند به سرعت و با دقت علف‌های هرز را شناسایی کرده و سمپاشی دقیق آفت‌کش‌ها را انجام دهند. این امر باعث کاهش استفاده از آفت‌کش‌هایی مانند علف‌کش‌ها، کاهش آلودگی محیط زیست ناشی از آفت‌کش‌ها و جلوگیری از کمبود نیروی کار و کاهش بیشتر هزینه‌ها می‌شود.



کیفیت بذور نه تنها میزان بقای نهال‌ها را تعیین می‌کند، بلکه تأثیر مهمی بر برداشت و کیفیت محصولات نیز دارد. بذره‌ای پرتوان در برابر تنش مقاومت بالایی دارند. هنگامی که در مزرعه کاشته می‌شوند، سرعت جوانه زنی بالا، سبز شدن سریع و منظم دارند و می‌توانند محصولاتی با عملکرد و کیفیت بالا تولید کنند. بذور کم‌قدرت مقاومت تنش ضعیفی دارند و مستعد پوسیده شدن دانه‌ها و نهال‌های مرده هستند که در نتیجه عملکرد محصول کاهش می‌یابد. AGI می‌تواند دانه‌های ناشناخته را با استخراج صفات بذر عالی و داده‌های مربوط به آن‌ها غربال کند و دانه‌هایی را با شکل‌های عالی حفظ کند. AGI می‌تواند بر اساس سرخ‌های متعدد مانند اندازه، چاق بودن، ویژگی‌های هندسی خارجی، ویژگی‌های رنگ و وجود کپک و غیره از انتخاب بذر پشتیبانی کند.

درجه بندی میوه‌ها عبارت است از غربالگری دقیق میوه‌ها قبل از ورود به بازار، حذف میوه‌های گندیده و طبقه بندی آنها بر اساس کیفیت میوه‌ها. از طریق شناسایی عکس‌های میوه، AGI می‌تواند درجات مختلف میوه‌ها را به صورت جداگانه بسته‌بندی، حمل و نقل و بفروشد، تلفات نخیره‌سازی را کاهش دهد و در هنگام فروش قیمت‌ها را بر اساس کیفیت بحث کند تا حداکثر سود اقتصادی را به دست آورد. AGI دارای مزیت قابل توجهی نسبت به

AI سنتی در توانایی آن در تعمیم و یادگیری از موقعیت های جدید است. بنابراین، AGI را می توان آموزش داد تا عوامل مختلف کیفیت میوه مانند رسیده، اندازه، رنگ و شکل را تشخیص دهد و میوه ها را به طور دقیق در دسته بندی های کیفی مختلف مانند "کیفیت بالا"، "متوسط" و "مناسب برای فروش" دسته بندی کند. " در مقابل، زمانی که شکل میوه، اندازه، رنگ، و به خصوص نواحی و درجات پوسیده با داده های آموزشی محدود متفاوت باشد، ممکن است اثر غربالگری کاهش یابد.

علاوه بر این، AGI این پتانسیل را دارد که طیف وسیعی از وظایف را در کشاورزی به طور مستقل انجام دهد. با توانایی درک و تفسیر زبان طبیعی و نشانه های بصری، AGI می تواند بدون دخالت انسان به طور مستقل تصمیم گیری و اقداماتی انجام دهد. این سطح از خودمختاری با سیستم های هوش مصنوعی فعلی امکان پذیر نیست و می تواند شیوه مدیریت کشاورزان محصولات کشاورزی و دام های خود را متحول کند.

با مثال هایی که در بالا ذکر شد، AGI می تواند پشتیبانی و خدمات حیاتی برای توسعه کشاورزی بر اساس اطلاعات استخراج شده از روش ها و حوزه های دانش متعدد ارائه دهد. بخش های بعدی این مقاله AGI را برای کاربردهای کشاورزی از منظرهای متعدد به تفصیل بیان می کند، از جمله پس زمینه AGI، درک تصویر کشاورزی، NLP، نمودار دانش، زیرساخت ها، رباتیک، و کاربردهای آن ها برای محصولات دقیق و دام های دقیق.

۲. پس زمینه

در این بخش، به طور خلاصه معرفی می کنیم که چگونه تکنیک های هوش مصنوعی و AGI، مانند پردازش زبان طبیعی (NLP)، می توانند برای پیشبرد طیف گسترده ای از کاربردهای کشاورزی به کار گرفته شوند. با توجه به حجم گسترده اسناد (مثلاً مقالات علمی، گزارش های فنی، نظرسنجی ها، اخبار و داده های رسانه های اجتماعی)، متون احتمالاً در دسترس ترین منابع داده در بسیاری از حوزه ها از جمله کشاورزی هستند. اگرچه برخی از تلاش های پیشگامانه از تکنیک های NLP برای کاربردهای کشاورزی استفاده می کنند، سفارشی سازی مدل های NLP برای کاربردهای کشاورزی خاص تا حد زیادی مورد بررسی قرار نگرفته است. در ادامه، انواع مختلفی از تکنیک های NLP، از جمله تکنیک های سنتی NLP و جدیدترین مدل های زبان بزرگ (LLM) را که مورد استفاده قرار گرفته اند (یا می توانستند) را مورد بحث قرار دهیم.

برای کمک به کاربردهای کشاورزی، استخراج اطلاعات به عنوان یک وظیفه اساسی در NLP، استخراج اطلاعات بر استخراج اطلاعات ساختاریافته از اسناد بدون ساختار یا نیمه ساختار یافته متمرکز است. همچنین یک گام اساسی برای بسیاری از وظایف NLP دیگر مانند ساخت نمودار دانش است. برخی از تلاش های اخیر در حوزه کشاورزی را می توان در این مقاله پیمایشی یافت. بیشتر کارها در این زمینه بر روی استفاده از تکنیک های NLP کلاسیک (مانند روش های مبتنی بر قانون و روش های مبتنی بر یادگیری) برای کارهای فرعی مانند شناسایی موجودیت نام گذاری شده ((Named entity identification) (NER) و سپس ایجاد هستی شناسی یا نمودار دانش متمرکز است. مخصوص کشاورزی اخیراً، مدل های زبان مبتنی بر ترانسفورماتور مانند BERT نیز برای استخراج موجودیت و رابطه استفاده شده است.

تطبیق معنایی با توجه به تنوع در بازنمایی زبان، تطبیق معنایی یک تکنیک کلیدی است که تطبیق صحیح موجودیت های معنایی مشابه با طول های مختلف (مانند کلمات، عبارات، جملات، اسناد) را امکان پذیر می کند. یکی از کاربردهای اخیر تطبیق معنایی در حوزه کشاورزی، ایجاد نقشه بین توصیف های غذا و پایگاه داده تغذیه است. به طور خاص، یک مجموعه متنی مرتبط با غذا (به عنوان مثال، ادبیات غذایی و کشاورزی) برای پیش آموزش مدل های زبانی مبتنی بر ترانسفورماتور جمع آوری می شود. و تطبیق معنایی بین غذا و تغذیه سپس در فضای تعبیه، با فرمول بندی مسئله انتخاب پاسخ انجام می شود. علاوه بر این، تطبیق معنایی می تواند نقش اساسی در ترکیب داده های متن کشاورزی از منابع مختلف داشته باشد.

سیستم پاسخگویی به پرسش و گفتگو: پاسخگویی به سؤال (QA) و سیستم های گفتگو از مشکلات اساسی در NLP هستند. انتظار می رود که مدل ها به طور دقیق سؤال و زمینه را درک کنند و سپس پاسخ های اطلاعاتی ایجاد کنند. توسعه مستقیم تکنیک (QA)، سیستم های گفتگو مانند ربات های گفتگو است. تا به حال، برخی ربات های چت در حوزه کشاورزی توسعه یافته اند. (مانند پاسخ دادن به سؤالات کشاورزان). به عنوان مثال، یک ربات گفتگوی مبتنی بر شبکه عصبی مکرر (RNN) برای رسیدگی به سؤالات مربوط به آزمایش خاک، حفاظت از گیاهان و مدیریت مواد مغذی طراحی شده است. با این حال، این سیستم های (QA) یا چت بات ها به دلیل اندازه مدل کوچک و داده های آموزشی ناکافی، قابلیت بسیار محدودی دارند.

مدل های زبان از پیش آموزش دیده (PLM)

مدل سازی زبان به دلیل اثربخشی و قابلیت تعمیم قابل توجه آن به تکنیک اصلی در NLP تبدیل شده است. به طور خاص، مدل های زبان از پیش آموزش دیده مبتنی بر ترانسفورماتور می توانند به عنوان مدل های پایه برای بسیاری از برنامه های NLP عمل کنند. PLM هایی مانند BERT معمولاً با کارهایی مانند مدل سازی زبان ماسک دار (MLM) و پیش بینی جمله بعدی (NSP) از قبل آموزش داده می شوند. از آنجایی که این PLM ها در حوزه های عمومی با استفاده از داده های ویکی پدیا و BookCorpus از قبل آموزش داده شده اند، معمولاً برای دامنه های خاص نیازمند یک مرحله تنظیم دقیق می باشند. با تنظیم دقیق PLM های پایه با مجموعه متنی با کیفیت بالا از یک دامنه خاص، می توان مدل های زبان سفارشی سازی شده را توسعه داد. برخی از نمونه های نماینده عبارتند از BioBERT، Pub-MedBERT و LEGAL-BERT. مجموعه ای در مقیاس بزرگ از ادبیات کشاورزی با بیش از ۳۰۰ میلیون توکن برای تنظیم دقیق BERT عمومی به AgriBERT استفاده می شود. چنین مدل های زبانی خاص دامنه می توانند به طور بالقوه برای کمک به بسیاری از برنامه های کشاورزی، مانند بازاریابی کشاورزی، تجزیه و تحلیل رسانه های اجتماعی کشاورزی و غیره مورد استفاده قرار گیرند.

مدل های زبان بزرگ (LLM)

LLM ها معمولاً به PLM هایی با بیش از میلیارد پارامتر مدل اشاره می کنند، مانند مدل های GPT (ترانسفورماتور از پیش آموزش دیده) (GPT-۱، GPT-۲، GPT-۳، Instruct-GPT، ChatGPT و GPT-۴)، LLaMA (متا مدل زبان بزرگ) (AI و BLOOM). به عنوان مثال، GPT-۳ و BLOOM دارای ۱۷۵ میلیارد پارامتر هستند.

و LLaMA دارای ۶۵ میلیارد پارامتر است. مشابه PLM های سنتی مانند BERT، این LLM های اخیر نیز از معماری ترانسفورماتور پیروی می کنند، اما در اهداف آموزشی، منابع داده، جزئیات بهینه سازی و غیره با یکدیگر تفاوت دارند. برای مثال، BERT تنها رمزگذار Transformer را به عنوان استفاده می کند. بر روی یادگیری بازنمایی زبان تمرکز می کند، در حالی که مدل های GPT از رمزگشایی Transformer استفاده می کنند، زیرا هدف اصلی آنها تولید متن واقعی است. جدیدترین LLM ها مانند ChatGPT و GPT-۴ به دلیل اندازه مدل های عظیم و ترکیب مؤثر بازخوردهای انسانی (به عنوان مثال، درخواست ها)، نه تنها عملکرد شگفت انگیزی در وظایف سنتی NLP مانند درک زبان، تولید زبان و پاسخ به سؤال به دست آورده اند. اما همچنین قابلیت های قابل توجهی را در یادگیری و استدلال صفر نشان داد. به عنوان مثال، ChatGPT توانایی بسیار امیدوار کننده ای را در استدلال استقرایی و استدلال قیاسی نشان داده است. GPT-۴ یک مدل چند وجهی بزرگ است که می تواند هم با زبان و هم با ورودی های بصری سروکار داشته باشد. علاوه بر این، LLM ها ابزارهای موثری برای تقویت داده ها هستند که برای سناریوهای خاص دنیای واقعی با داده های محدود بسیار مفید است. این مشاهدات هیجان انگیز نشان می دهد که تکنیک های مبتنی بر LLMs ممکن است یک نقشه راه امیدوارکننده به سمت AGI را ممکن کند. برای کاربردهای کشاورزی، LLM ها می توانند پردازش، درک و تفسیر متون و اسناد کشاورزی را به طور قابل توجهی پیش ببرند. علاوه بر این، توانایی های یادگیری و استدلال بدون شات LLM نیز مشکلات مختلف تصمیم گیری در حوزه کشاورزی را تسهیل می کند.

در ادامه، نحوه استفاده از تکنیک های AGI (مانند LLM ها و مدل های چندوجهی بزرگ) برای پیشبرد طیف وسیعی از حوزه های تحقیقاتی و کاربردها در کشاورزی را مورد بحث قرار خواهیم داد. بخش ۳، بر چندین موضوع تحقیقاتی در کشاورزی، شامل انواع مختلف داده ها (به عنوان مثال، تصاویر، نمودارهای دانش) و کاربردهای مختلف (مانند دام ها و محصولات کشاورزی دقیق، روباتیک کشاورزی) تمرکز دارند. AGI را برای درک تصویر کشاورزی، مانند مدیریت ابر داده در مطالعات اصلاحی، تولید تصاویر برای افزایش داده، زمان بندی و ترکیب چند کار، یادگیری چند شات، و تطبیق دامنه، معرفی می کنیم. بخش ۴، چندین جنبه بالقوه را مورد بحث قرار می دهد که در آن تکنیک های نمودار دانش و AGI به طور مشترک برای کاربردهای کشاورزی مورد بهره برداری قرار می گیرند. بخش ۵، چندین راه ممکن برای استفاده از AGI برای روباتیک کشاورزی را توضیح می دهد. بخش ۶، سایر موارد، از جمله AGI برای کشاورزی دقیق و فنومیک، معرفی، AGI برای دام های دقیق، و AGI برای زیرساخت های کشاورزی را ارائه می دهد. بخش آخر این مقاله را به پایان می رساند.

بخش ۳. AGI for Agriculture Image Understanding هوش مصنوعی مولد برای داده های کشاورزی

اخیراً، مدل های مولد هوش مصنوعی مانند مدل Stable Diffusion، تولید قابل توجهی با کیفیت بالا از تصاویر و ویدیوهای فوتورئالیستی را نشان داده اند. پیشرفت های مشابهی در حوزه های دیگری مانند گفتار رخ داده است که همگی توسط مدل های هوش مصنوعی مولد در مقیاس بزرگ پشتیبانی می شوند. LLM های چند وجهی ذاتاً مدل های مولد هستند. می توان آنها را طوری تنظیم کرد که توزیع پیچیده داده های کشاورزی غنی را

در تصاویر ماهواره‌ای، ویدئوها، داده‌های سنجش فراطیفی، ابرهای نقطه‌ای سه‌بعدی، و همچنین اندازه‌گیری‌های سری زمانی ثبت کند. چنین مدل‌های مولد می‌توانند وظایف زیر را تقویت کنند:

تولید داده‌های آموزشی یکی از محدودیت‌های اعمال الگوریتم‌های بینایی کامپیوتری تخصصی مانند PointNet یا MaskRCNN برای داده‌های بصری کشاورزی، کمبود داده‌ها و برچسب‌های آموزشی است. به دست آوردن داده‌های با کیفیت بالا زمان‌بر است و برچسب‌گذاری مناسب آنها گران‌تر است. یک راه حل ممکن، ساختن یک محیط دیجیتالی است که داده‌های مصنوعی تولید می‌کند، اما معمولاً یک شکاف دامنه بین محیط شبیه‌سازی شده و دنیای واقعی وجود دارد. راه حل‌های پیچیده‌ای مانند تطبیق دامنه باید برای رسیدگی به این موضوع اعمال شود. از سوی دیگر، LLM‌های مولد چندوجهی، پس از تنظیم دقیق در حوزه داده‌های کشاورزی هدف، می‌توانند مقدار زیادی از داده‌های آموزشی و برچسب‌ها را برای ساخت یک مجموعه آموزشی تقویت شده تولید کنند که بسیار شبیه توزیع داده‌های اصلی است. علاوه بر این، مدل‌های تولید مبتنی بر متن می‌توانند تصاویر و ویدئوها را که با توضیحات متنی خاصی که صحنه‌ای خاص را توصیف می‌کنند، ترکیب کنند. آنها می‌توانند برای تولید داده‌های بصری کشاورزی سفارشی شده برای تنظیم دقیق الگوریتم‌های بینایی کامپیوتری پیشرفته استفاده شوند.

ویرایش و دستکاری داده‌های چندوجهی، داده‌های کشاورزی، طیف وسیعی از تغییرات را به دلیل تغییرات فصل و آب و هوا نشان می‌دهد. جمع‌آوری داده‌هایی که همه تغییرات را در بر می‌گیرد بسیار دشوار است. در همین حال، مدل‌های هوش مصنوعی مولد توانایی‌های فوق‌العاده‌ای برای ویرایش و دستکاری داده‌ها با ویژگی‌های مختلف نشان می‌دهند. می‌توان از آنها برای ایجاد تغییراتی از داده‌های اصلی برای ویژگی‌های خاص استفاده کرد. از نظر ترجمه حوزه آب و هوای تصویر، شبکه‌های متخاصم مولد (GAN) پتانسیل زیادی در انتقال، تصاویر سطح زمین به تصاویر مصنوعی فوتورئالیستی تحت شرایط آب و هوایی مختلف و اقلیم شدید متفاوت نشان داده‌اند. رویدادها اخیراً، مدل‌های سنتز تصویر مبتنی بر انتشار مانند SDEdit نیز قابلیت‌های قدرتمند ویرایش تصویر خود را بدون نیاز به آموزش ویژه کار نشان می‌دهند. مطابق با LLM‌ها، مدل‌های دید بزرگ نیز توسعه یافته‌اند، (مانند SAM برای تقسیم بندی تصویر). برای مثال، در زمینه تصاویر کشاورزی، مدل‌های هوش مصنوعی مولد می‌توانند زمان را از روز به شب و آب و هوا را از آفتابی به بارانی تغییر دهند. این تغییرات می‌تواند به آموزش مدل‌های قوی‌تر برای وظایف حیاتی کشاورزی کمک کند.

LLM برای برنامه ریزی چند کار و ترکیب کردن

درک بصری داده‌های کشاورزی معمولاً از وظایف فرعی متعددی تشکیل شده است. به عنوان مثال، برای کار اصلی شمارش تعداد جوجه‌های سالم در یک مرغداری با استفاده از دوربین‌ها، وظایف فرعی مانند تشخیص اشیا، تقسیم بندی نمونه، ردیابی اشیا و تصویر طبقه بندی مورد نیاز است. برای طراحی و اجرای چنین گردش کاری به دانش حوزه کشاورزی و همچنین بینایی کامپیوتر و یادگیری ماشین نیاز دارد. با در نظر گرفتن مثالی دیگر، فوتیپ کردن ریشه گیاه شامل مدل‌سازی ساختار ریشه، شمارش شاخه‌های ریشه، تخمین طول و زاویه، اندازه‌گیری زیست توده، الگوی توزیع و غیره می‌شود، که هر کدام مستلزم تلاش‌های گسترده است.


با درک معنایی و توانایی استدلال LLMها و انواع چندوجهی آنها، اکنون می‌توان دیدگاه‌های تخصصی و مدل‌های زبانی پیشرفته‌تر را برای زیرساخت‌های مهم کشاورزی مانند مزارع قابل دسترس‌تر کرد. یک مطالعه اخیر نشان می‌دهد که ChatGPT قادر به درک یک درخواست به زبان طبیعی، استخراج اطلاعات بصری و متنی مفید، انتخاب بینایی و وظایف زبانی مرتبط و تفسیر نتایج به انسان است. LLMها می‌توانند جریان‌های کاری کارآمد و مؤثر را از وظایف بینایی و زبانی متعدد برای انجام وظایف حیاتی کشاورزی، همه از طریق آموزش ساده و شهودی زبان طبیعی و بدون دخالت انسان در طول مسیر، ترکیب کنند. با توسعه LLMها، انتظار می‌رود که با ورودی زبان، اطلاعات فنوتیپ می‌تواند مستقیماً در اختیار محققان و پرورش دهندگان کشاورزی قرار گیرد.

آموزش چند شات

برخلاف هوش انسانی که می‌تواند دانش جدیدی را بر اساس تجربیات محدود یا صفر استنباط کند، بیشتر رویکردهای یادگیری ماشین، مانند تکنیک‌های سنتی یادگیری تحت نظارت، اغلب به هزاران مثال برچسب‌گذاری شده اند، برای یادگیری الگوهای ساده نیاز دارند. برای پر کردن این شکاف بین هوش انسانی و AGI، یادگیری چند شات (FSL) پیشنهاد شده است. به طور خاص، رویکردهای FSL بر «فراآموزی» تمرکز می‌کنند، یعنی یادگیری مدلی که می‌تواند به کارهای جدید مشخص شده در زمان استنتاج تعمیم دهد. به عبارت دیگر، FSL با تطبیق سریع با وظایف جدید که حاوی نمونه‌های ناکافی است، قصد دارد از توانایی تعمیم قابل توجه هوش انسانی تقلید کند. این برای سناریوهایی که جمع‌آوری و برچسب‌گذاری داده‌ها دشوار و پرهزینه است. مانند (برنامه‌های کشاورزی) که بسیار مفید است.

بسته به در دسترس بودن نمونه، FSL را می‌توان به سه دسته تقسیم کرد: Few-Shot (دو تا پنج نمونه در هر کلاس)، One-Shot (یک نمونه در هر کلاس)، و Zero-Shot (طبقه بندی کلاس‌های دیده نشده بدون هر نمونه آموزشی). FSL نتایج امیدوارکننده‌ای را در حوزه‌ها و کاربردهای مختلف، از جمله بینایی کامپیوتر و پردازش زبان طبیعی نشان داده است. بر اساس نحوه استفاده از دانش قبلی، کارهای موجود FSL را می‌توان به سه دسته طبقه بندی کرد:

۱) افزایش داده‌ها. برخی از روش‌ها سعی می‌کنند با تولید نمونه‌های جدید از نمونه‌های موجود، تبدیل نمونه‌ها از یک مجموعه داده با برچسب ضعیف یا بدون برچسب، یا تبدیل نمونه‌ها از یک مجموعه داده مشابه، مجموعه داده آموزشی را مستقیماً افزایش دهند. این فرآیندهای افزایش معمولاً توسط قوانین دست ساز هدایت می‌شوند، مانند عملیات ترجمه، چرخش، بازتاب و چرخش برای داده‌های تصویر، یا یادگیری مجموعه‌ای از تبدیل‌ها یا مدل‌ها برای انجام افزایش داده‌ها.



شکل ۲: فوتوپ ریشه گیاه بر اساس روش های AI-CV (بینایی کامپیوتری) در مقابل AGI. AI-CV برای پردازش هر کار به دانش CV اختصاصی گسترده ای نیاز دارد، در حالی که AGI این پتانسیل را دارد که مستقیماً اطلاعات فوتوپ مورد نیاز را با درخواست انسان ارائه دهد.

۲) محدودیت فرضیه: برای تقریب توزیع حقیقت پایه، مدل ها ممکن است نیاز به تعیین فضای فرضیه ای داشته باشند که فاصله بین پیش بینی بهینه و توزیع حقیقت زمینی را به حداقل برساند. از آنجایی که یک فضای فرضیه بزرگتر به نمونه های داده بیشتری برای کاوش نیاز دارد، برخی از روش های FSL سعی می کنند فضای جستجوی فرضیه را از طریق یادگیری مشترک چندین کار مرتبط با پارامترهای مدل مشترک یا محدود کردن شکل توزیع از دانش قبلی محدود کنند.

۳) دانش قبلی زمانی که مجموعه داده آموزشی به اندازه کافی بزرگ نباشد، روش های FSL ممکن است از دانش قبلی برای مداخله در استراتژی جستجوی پارامترها استفاده کنند، چه با ارائه یک مقدار اولیه خوب از پارامترها یا به طور مستقیم یک بهینه ساز را یاد بگیرند. مراحل جستجوی خروجی، مانند تغییر جهت جستجو یا اندازه گام

اگرچه رویکردهای یادگیری چند شات در دهه گذشته توجه زیادی را به خود جلب کرده است، بیشتر چنین رویکردهایی تعمیم پذیری محدودی دارند و فقط برای یک نوع کار مانند طبقه بندی تصویر، تشخیص شی یا ردیابی چند شی اعمال می شوند. رویکردی که مثلاً برای طبقه بندی اشیاء طراحی شده است، نمی تواند به طور پیش پا افتاده به تشخیص شی منتقل شود، حتی اگر این دو مشکل به هم مرتبط باشند.

یکی از ویژگی های شگفت انگیزتر از LLM ها این است که استعداد طبیعی برای یادگیری چند مرحله ای از خود نشان می دهند. با توجه به پیشرفت سریع LLM ها به سمت حل مسائل کلی تر، بی دلیل نیست که فرض کنیم

در حال ورود به آینده ای هستیم که در آن الگوی یادگیری نظارت شده فعلی و Thirsty for data منسوخ شده است. در حال حاضر، یک چالش مهم برای یادگیری عمیق کشاورزی، فقدان داده های مشروح شده است که منجر به تلاش های مختلفی برای کاهش نیاز به آن می شود. داده های مناسب برای یک محصول خاص ممکن است اصلاً وجود نداشته باشد، ممکن است به درستی حاشیه نویسی نشود، یا ممکن است در دسترس عموم نباشد.

LLM های پیشرفته و چندوجهی این پتانسیل را دارند که این مشکلات را یکبار برای همیشه حل کنند، اما سؤالات مهمی باقی می ماند. نسل بعدی LLM ها تازه شروع به ادغام ورودی های بصری کرده اند. به نوبه خود، OpenAI نسبتاً در مورد آنچه که GPT-4 دقیقاً در این حوزه توانایی دارد صحبت می کند، و ما احتمالاً تا زمانی که به طور دقیق و مستقل آزمایش نشود، مطمئن نخواهیم شد. یکی از خطرات واضح این است که LLM هایی که بر روی داده های مقیاس اینترنت آموزش دیده اند، نمی توانند به خوبی به حوزه دید کشاورزی تعمیم دهند، زیرا تصاویر کشاورزی با اکثر تصاویر موجود در اینترنت بسیار متفاوت هستند. در این شرایط، ما مجبور خواهیم بود به قابلیت های ذاتی یادگیری چند شات مدل تکیه کنیم، که ممکن است در حد کار باشد یا نباشد. علاوه بر این، بسیاری از وظایف مورد علاقه جامعه رباتیک کشاورزی وجود دارد که نیازمند استفاده از روش های مبهم تر (مانند ابرهای نقطه ای یا مکعب های ابرطیفی) به عنوان ورودی هستند، و یا خروجی هایی دارند که نمی توانند به صورت متن بیان شوند. (مدل هایی مانند GPT-4) به احتمال زیاد نیاز به گسترش در سطح معماری به منظور پشتیبانی از چنین موارد استفاده است. با توجه به این واقعیت که LLM های پیشرفته عمدتاً اختصاصی هستند، محرمانه هستند و آموزش آنها بدون میلیون ها دلار سرمایه گذاری در ظرفیت محاسباتی غیرممکن است، جامعه تحقیقاتی ممکن است مدت زیادی منتظر این ویژگی ها باشند.

اگر ما این دیدگاه خوشبینانه را در نظر بگیریم که LLM های آینده نزدیک حداقل قادر به انجام برخی وظایف چشم انداز کشاورزی خواهند بود، چه چیزی را ممکن می کند؟ در حال حاضر، به لطف گسترش ابزارهایی مانند YOLOv-5، کارهای ساده بینایی کامپیوتری مانند تشخیص اشیا را می توان توسط افراد غیر متخصص با آموزش تخصصی کمی انجام داد. پروژه هایی که قبلاً به دلیل نیاز به جمع آوری و حاشیه نویسی داده ها دشوار یا کند بودند، می توانند به طور قابل توجهی سریعتر اجرا شوند. علاوه بر این، به دلیل قابلیت های پردازش زبان، LLM های دارای قابلیت بینایی برای مدیریت ابرداده های مرتبط با تصویر ایده آل هستند، شاید توانایی استخراج خودکار فراداده متنی بر اساس ورودی تصویر را به دست آورند. به طور کلی، LLM ها چرخه نوآوری را در بینایی کامپیوتر کشاورزی به طور قابل توجهی تسریع می کنند و (امیدواریم) این فناوری ها را در استفاده گسترده در بین کشاورزان راه اندازی کنند.

تطبیق دامنه

اگرچه AGI به دلیل عملکرد چشمگیر خود در پیش بینی و تعمیم، پیشرفت هایی در زمینه های کاربردی مختلف داشته است، اما به طور اجتناب ناپذیر به مقادیر زیادی از داده های برجسب گذاری شده نیاز دارد که ممکن است در سناریوهای دنیای واقعی به دلیل زمان قابل توجه و نیروی کار گران قیمت واقع بینانه نباشد.

تطبیق دامنه بدون نظارت (Unsupervised domain matching - UDA) یک راه امیدوارکننده برای پرداختن به این موضوع ارائه می‌کند. هدف آن تطبیق مدل‌های آموزش‌دیده در یک دامنه (دامنه منبع) با دامنه دیگر (دامنه هدف) با ویژگی‌های توزیعی متفاوت، بدون نیاز به داده‌های برچسب‌دار در دامنه هدف. مرحله کلیدی UDA یافتن ویژگی‌های متمایز و نامتغیر دامنه است که می‌توانند دامنه منبع برچسب‌گذاری شده و دامنه هدف بدون برچسب را در یک فضای پنهان به هم پیوند دهند. در دهه‌های گذشته، بسیاری از روش‌های UDA توسعه و ارزیابی شده‌اند. علاوه بر UDA، برخی دیگر از مشکلات انطباق دامنه عملی نیز به طور گسترده در ادبیات مطالعه شده است، مانند تطبیق دامنه جهانی، تطبیق دامنه نامتعادل طبقاتی، انطباق دامنه چند شات، باز تطبیق دامنه مجموعه و تعمیم دامنه.

در سال‌های اخیر، سازگاری دامنه برای برخی کاربردهای کشاورزی، مانند طبقه‌بندی گیاهان، شمارش برگ، پیش‌بینی عملکرد ذرت، استخراج زمین کشاورزی و تقسیم‌بندی پوشش زمین به کار گرفته شده است. به عنوان مثال، یک رویکرد تطبیق دامنه بدون نظارت (UDA) برای انتقال سیستم‌های طبقه‌بندی گیاهان به محیط‌های مزرعه‌ای جدید، محصولات زراعی و روبات‌ها پیشنهاد شده است. روش دیگر تطبیق دامنه خصمانه (HDM Hostile domain matching) برای کشاورزی پیشنهاد شده است. (استخراج زمین با استفاده از تصاویر سنجش از دور).

به طور کلی، بیشتر کارهای قبلی عمدتاً بر شبکه‌های عصبی کانولوشنال (CNN) برای یادگیری بازنمایی‌های نامتغیر دامنه در میان حوزه‌های مختلف متکی است. با افزایش Vision Transformers (ViT) برای وظایف بینایی، چند مطالعه مبتنی بر ViT توسعه یافته‌اند و قابلیت انتقال قابل توجهی برتری را نسبت به هم‌تایان مبتنی بر CNN خود نشان داده‌اند. علاوه بر این، آخرین پیشرفت در مدل‌های چندوجهی بزرگ مانند GPT-4 منجر به فرمول‌بندی و مدل‌سازی جدید انطباق دامنه، به‌ویژه برای حوزه‌های کاربردی خاص مانند کشاورزی می‌شود. در تنظیمات تطبیق دامنه سنتی (Traditional domain matching)، دامنه منبع معمولاً دانش کمکی را ارائه می‌دهد که به یک سناریوی محدود و خاص محدود می‌شود. با این حال، مدل‌های چندوجهی بزرگ قبلاً دانش عام غنی را رمزگذاری کرده‌اند، و همچنین دارای قابلیت‌های استدلال قابل توجهی هستند. بنابراین، مشکل انتقال دانش از مدل‌های چندوجهی بزرگ به حوزه‌های هدف باید به دقت فرموله شود. در همین حال، روش‌های جدید در زمینه یادگیری انتقالی، یادگیری بازنمایی متقابل، و انتقال دانش مبتنی بر بصری/متن باید بیشتر توسعه یابد.

۴.۴ AGI برای نمودارهای دانش کشاورزی

نمودارهای دانش (Knowledge graphs KG) که به‌عنوان چند گراف‌های هدایت‌شده برچسب‌گذاری‌شده، نشان داده می‌شوند، یک الگوی جدید برای نمایش، بازیابی و یکپارچه‌سازی داده‌ها از منابع داده‌های مختلف در سراسر حوزه‌ها هستند. KGها به عنوان یک راه حل امیدوارکننده برای چالش‌های مختلف دانشگاهی و صنعتی ظاهر شده‌اند. در ادامه، چندین جنبه بالقوه را مورد بحث قرار می‌دهیم که فناوری‌های نمودارهای دانش (KG) و AGI می‌توانند با هم کار کنند و به یک سیستم کشاورزی هوشمندتر دست یابند.

AGI دقیق و قابل تفسیر برای وظایف کشاورزی

اگرچه مدل‌های پایه اخیر عملکردهای امیدوارکننده‌ای را در کارهای مختلف زبان، بینایی و روباتیک نشان می‌دهند، اما به دلیل ایجاد نتایج نادرست و گمراه‌کننده نیز مورد انتقاد قرار می‌گیرند.

نمودارهای دانش (KG) به ویژه برای هدایت پیش‌بینی‌های مدل‌های زبان در کارهای مختلف مفید هستند و برای پایه‌گذاری پاسخ‌های تولید شده بر روی یک زیرگراف خاص، کمک می‌کنند تا از دقت پاسخ‌های تولید شده اطمینان حاصل شود و تفاسیر مدل بهبود یابد. این قابلیت به ویژه برای بسیاری از کارهای دنیای واقعی که در آنها پیش‌بینی‌های دقیق و قابل تفسیر حیاتی هستند. (در حوزه‌های پزشکی و کشاورزی مفید است). با اطلاعات زمینه‌ای ارائه شده توسط نمودارهای دانش (KG)، AGI می‌تواند برای کارهای کشاورزی مانند نظارت بر محصول، پیش‌بینی عملکرد محصول، کوددهی و غیره بهتر استفاده شود.

تلفیق متن و دانش برای وظایف کشاورزی: با توسعه اخیر مدل‌های زبان بزرگ (LLM) که عموماً به عنوان نیروی محرکه اصلی AGI هستند. نمودارهای دانش (KG) معمولاً به عنوان یک منبع داده اضافی در نظر گرفته می‌شوند و می‌تواند داده‌های متنی را برای پیش‌آموزش یا تنظیم دقیق مدل زبان تکمیل کند تا به طور قابل‌توجهی آن‌ها را تقویت کند. عملکرد در وظایف مختلف پایین دستی، به ویژه وظایف دشوار و پاسخگویی به سؤالات نیاز به استدلال پیچیده دارند.

در حوزه کشاورزی، AgriBERT نشان داده است، که افزودن داده‌های متنی (یعنی جفت‌های پاسخ‌دهی به سؤال) با دانش اضافی از یک نمودار دانش کشاورزی (KG) (به عنوان مثال، نمودار دانش FoodOn) می‌تواند عملکرد مدل را در وظایف مختلف NLP در حوزه غذا و کشاورزی به طور قابل‌توجهی افزایش دهد.

AGI برای ساخت نمودار دانش کشاورزی: (AGI for Agriculture Knowledge Graph Construction).

پیشرفت‌های اخیر مدل‌های پایه، استفاده از AGI را در ساخت نمودار دانش تقویت می‌کند. مای و همکاران به جای انجام استخراج سه گانه دانش به شیوه‌ای نظارت شده یا با استفاده از نمونه‌های بذر، نشان می‌دهد که با استفاده از اعلان‌های ساده، GPT-3 می‌تواند نام مکان‌ها را از متن بدون ساختار به دقت تشخیص دهد و از مدل‌های تشخیص نام، نام‌ها با نظارت کامل پیشرفته، بهتر عمل کند. این نشان دهنده، پتانسیل‌های AGI برای شناسایی موجودیت و پیوند نهاد است که دو وظیفه مهم مرتبط با نمودارهای دانش (KG) هستند. اخیراً، GraphGPT-3 به عنوان یک ابزار تولید گراف دانش مبتنی بر GPT-3 توسعه یافته است که می‌تواند یک نمودار دانش معین را به روز کند یا یک نمودار دانش جدید را با توجه به ورودی‌های زبان طبیعی ایجاد کند. نمودارهای دانش پرکاربرد، یا KGهای عمومی مانند DBpedia و Wikidata، یا KGهای خاص دامنه مانند FoodOn، GeoNames Linked-GeoData، GNIS-LD و KnowWhereGraph، به صورت دستی یا نیمه اتوماتیک، برای ساخت گراف دانش خودکار مبتنی بر AGI به ویژه حوزه‌هایی که در آن مهندسان دانش کمتری مانند حوزه کشاورزی در دسترس هستند. نمودار دانش کشاورزی که به طور خودکار ساخته می‌شود می‌تواند اطلاعات زمینه‌ای اضافی را ارائه دهد و فرآیندهای مختلف تصمیم‌گیری کشاورزی را تسهیل کند.

استدلال دانش پیچیده برای وظایف کشاورزی.

بسیاری از وظایف کشاورزی نیاز به استدلال پیچیده دارند. برای مثال، با توجه به یک تصویر پهپاد از یک زمین زراعی سویا، یک دانشمند کشاورزی یا یک کشاورز مراحل زیر را طی کند. ابتدا نام این مشکل (به عنوان مثال، سوختگی باکتریایی) را تعیین کند. سپس تعیین علل این بیماری (به عنوان مثال، *Pseudomonas syringae*)؛ و در نهایت، تعیین نحوه درمان این بیماری (به عنوان مثال، اسپری باکتری کش). در حال حاضر، یکی از راه‌های رایج برای فعال کردن یک مدل زبان بزرگ (LLM) برای انجام استدلال پیچیده، استفاده از *Stimulating a chain of thought* است که در آن چند زنجیره *Intellectual demonstration* به عنوان نمونه‌هایی ارائه می‌شوند تا به صراحت LLM را وادار کنند. به LLM اجازه دهیم یک مسئله استدلال چند مرحله‌ای را به گام‌های میانی که به صورت جداگانه حل می‌شوند، تجزیه کند، به جای اینکه کل یک مسئله استدلال چند هاپ را در یک پاس رو به جلو حل کند. با این حال، چنین ایده ای استدلال به شیوه ای ضمنی است که مستعد خطا است و اشکال زدایی آن سخت است. با رمزگذاری صریح روابط بین علائم محصول، بیماری ها، باکتری ها و درمان ها در یک نمودار دانش کشاورزی، می توانیم از LLM بخواهیم مسیر را دنبال کند. این نمودار و استدلال صریح چند هاپ درست مانند روشی که ماشین نمادین عصبی اتخاذ می کند ، انجام می دهد.

کاربرد نمودارهای دانش در AGI کشاورزی

نمودارهای دانش خصوصیات و روابط موجودات دنیای واقعی را توصیف می‌کنند و مزایایی را برای انواع برنامه‌های کشاورزی فراهم می‌کنند، مانند تقویت موتورهای جستجو، سیستم‌های پرسش و پاسخ، سیستم‌های توصیه و تولید محتوا با هوش بیشتر.

- موتورهای جستجو: موتورهای جستجوی کشاورزی بهتر می‌توانند کشاورزان و متخصصان را به اطلاعات مورد نیازشان متصل کنند. موتورهای جستجوی سنتی با خزیدن و نمایه‌سازی محتوای وب، پذیرش پرسش‌ها و رتبه‌بندی نتایج بر اساس ارتباط کار می‌کنند.

با توجه به هوش عمومی در حال ظهور، مدل‌های زبان بزرگ اخیر (LLM) مانند ChatGPT و GPT-4 می‌توانند برای ایجاد نتایج جستجوها مورد استفاده قرار گیرند و به طور بالقوه صنعت موتورهای جستجو را مختل کنند. مفهوم نمودارهای دانش از زمان راه‌اندازی آن توسط موتور جستجوی Google که با چارچوب دانشی Vault برای ساختن نمودارهای دانش در مقیاس بزرگ مرتبط است، محبوبیت زیادی به دست آورد. نمودارهای دانش می‌توانند LLM ها را با ارائه اطلاعات ساختاریافته و قابل اعتماد تکمیل کنند.

- سیستم های پرسش و پاسخ: پاسخ به سؤال (Q&A) با هدف ارائه پاسخ های دقیق و مختصر به زبان طبیعی در پاسخ به سؤالات مطرح شده توسط کاربران است. مدل‌های زبان اخیر به سبک چت‌بات Chatbot، اگر با مقادیر زیادی از داده‌های کشاورزی از منابع مختلف (مانند الگوهای آب و هوا و کنترل آفات) آموزش داده شوند، پتانسیل پاسخگویی به سؤالات مرتبط با حوزه‌های کشاورزی مختلف را دارند. با این وجود، LLMS ممکن است محتوایی تولید کند که دقت واقعی نداشته باشد یا دانش مهم را حذف کند، جایی که KGS می‌تواند

برای کاهش مشکل به کار رود. یک استراتژی تقویت یادگیری بازنمایی زبان با نهادهای دانش است. راه دیگر یادگیری مستقیم جاسازی های گراف دانش و سپس ادغام نهادهای آموخته شده و جاسازی های رابطه در خط لوله QA است.

- سیستم های توصیه کننده: سیستم های توصیه گر کشاورزی می توانند انتشار اطلاعات معتبر را تسهیل کنند و به کشاورزان کمک کنند تا تصمیمات آگاهانه تری در مورد چگونگی بهینه سازی تولید خود بگیرند، به عنوان مثال، پیشنهاد می کنند از کدام محصولات کشاورزی مانند دانه ها، کودها و آفت کش ها استفاده کنند. هوش مصنوعی می تواند با کاربران تعامل داشته باشد تا به آنها در یافتن محصولات، خدمات کمک کند. با استفاده از اطلاعات جانبی در KG ها، می توان ترجیحات کاربر را با دقت بیشتری دریافت کرد. استراتژی های معمول ترکیب KG ها شامل یادگیری جاسازی های نمودار دانش آموزنده و هدایت استدلال مبتنی بر مسیر بر روی KG ها است.
- تولید محتوا: قابلیت های پیشرفته پردازش زبان LLM ها می تواند ساده و سرعت بخشد.
- وظایف ذهنی تکراری متخصصان کشاورزی: مانند ضبط، تولید گزارش، و تولید مواد آموزشی. ادغام KG ها می تواند فرآیند تولید محتوا را قابل کنترل تر کند. علاوه بر جاسازی گراف دانش و استدلال مبتنی بر مسیر، همچنین می توان از شبکه های عصبی گراف برای رمزگذاری اطلاعات با مرتبه بالا برای تولید متن استفاده کرد.

۵. AGI برای رباتیک کشاورزی

با تقویت فرآیند تصمیم گیری ربات ها، AGI می تواند کارایی اجرای وظایف خاص را بهبود بخشد، به ویژه در بخش کشاورزی که برخی از وظایف هنوز به شدت به کار دستی متکی هستند. کاربرد AGI در رباتیک کشاورزی می تواند ربات ها را قادر به انجام طیف وسیعی از وظایفی کند که در حال حاضر برای انجام بسیاری از مدل های هوش مصنوعی تک وظیفه ای نیاز دارند. همچنین این پتانسیل را دارد که با استفاده از کتابخانه های عملکردی سطح بالا و مهندسی سریع، طراحی ربات های کشاورزی را متحول کند. با AGI، ربات های کشاورزی می توانند وظایف مختلف را بهینه کنند و ضایعات را به حداقل برسانند، و آنها را به یک فناوری امیدوارکننده برای کشاورزی دقیق تبدیل کنند.

توانایی AGI در درک زبان های طبیعی و استدلال می تواند تعامل بین انسان و ربات ها را تا حد زیادی بهبود بخشد و در نتیجه موانع فنی کشاورزان را برای استفاده از ربات های کشاورزی کاهش دهد. علاوه بر این، توانایی AGI برای درک تصاویر می تواند ربات ها را قادر سازد تا محیط اطراف خود را از طریق دید کامپیوتری، که شامل شناسایی خطرات احتمالی ایمنی می شود، بهتر درک کنند.

- تعامل انسان و ربات: AGI به طور قابل توجهی می تواند تعامل بین انسان و ربات را با اجازه دادن به کاربران برای کنترل ربات ها با استفاده از زبان طبیعی، به جای تایپ کردن دستورات، ساده کنید. این امر موانع استفاده را برای کسانی که پیشینه فن آوری ندارند کاهش می دهد و در هزینه آموزش اپراتورهای دارای گواهی صرفه جویی می کند.

- ایمنی ربات: توانایی AGI برای تشخیص خطرات ایمنی در زمان واقعی می تواند ایمنی ربات های کشاورزی را به طور قابل توجهی بهبود بخشد. به عنوان مثال، اگر یک ربات یک خطر ایمنی را تشخیص دهد، می تواند فوراً کار خود را متوقف کند یا به کشاورز هشدار دهد و از حوادث یا صدمات احتمالی جلوگیری کند. ربات ها همچنین می توانند پیشرفت کارهای کشاورزی را زیر نظر داشته باشند و در صورت عدم اجرای فرمان، آسیب احتمالی به گیاهان را شناسایی کنند. علاوه بر این، AGI می تواند به ربات ها کمک کند تا از تجربیات خود بیاموزند و عملکرد خود را در طول زمان بهبود بخشند و احتمال خطرات ایمنی آینده را کاهش دهند.
- همکاری انسان و ربات: AGI می تواند ربات ها را قادر سازد تا به طور مؤثرتری با انسان ها هماهنگ شوند. کارهای پیچیده مانند برداشت به عنوان مثال، یک ربات کمک برداشت، می تواند کمک مؤثرتر و پاسخگوتری به کارگر انسانی ارائه دهد که بتواند مقاصد کارگر را با تشخیص حرکات و زبان آنها درک کند و کارایی کلی برداشت را بهبود بخشد. علاوه بر این، ربات می تواند خطرات احتمالی را شناسایی کرده و از آسیب رساندن به کارگران انسانی جلوگیری کند.

مزایای AGI

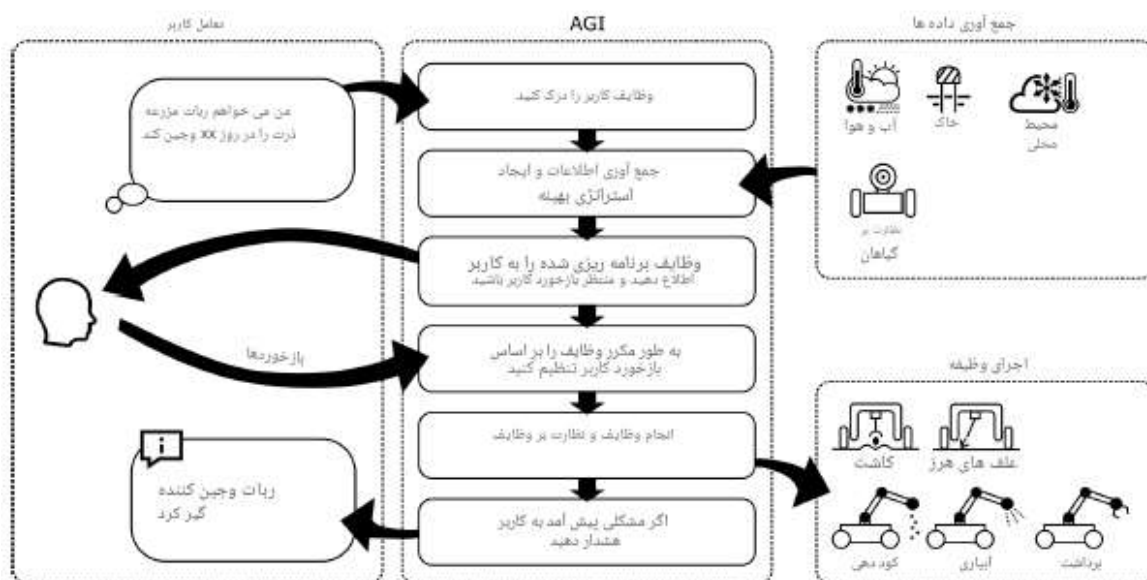
AGI چندین مزیت دارد، از جمله توانایی ادغام داده های تاریخی و بلادرنگ از منابع مختلف مانند داده های آب و هوا، محیط زیست، خاک و گیاهان. این می تواند به ربات ها کمک کند تا استراتژی های بهینه برای کارهای کشاورزی خاص را در زمان واقعی ایجاد کنند. کاربردهای AGI در کشاورزی بسیار زیاد است، از جمله افزایش کارایی وظایف زیر:

- کاشت: AGI می تواند برای کمک به ربات ها در کاشت محصولات استفاده شود. با ارائه داده های بلادرنگ در مورد کیفیت خاک، سطوح رطوبت و سایر عواملی که بر رشد بذر تأثیر می گذارند کارآمدتر باشد. با استفاده از این داده ها، ربات ها می توانند بذرها را در عمق و فاصله بهینه بکارند و عملکرد محصول را بهبود بخشند و ضایعات را کاهش دهند.
- علف های هرز: AGI می تواند به ربات ها کمک کند تا بین آنها تفاوت قائل شوند. علف های هرز و محصولات زراعی را از بین ببرید و علف های هرز را با استفاده از سمپاشی هدفمند، لیزر یا حذف مکانیکی بدون آسیب رساندن به محصولات از بین ببرید، که می تواند تا حد زیادی استفاده از علف کش ها و اثرات آنها را بر محیط زیست کاهش دهد.
- کود دهی: AGI می تواند برای تشخیص رشد گیاه استفاده شود. وضعیت و شناسایی گیاهانی که از سوء تغذیه رنج می برند. همراه با داده های مربوط به کیفیت خاک، ربات ها می توانند مقدار و زمان کودها را برای بهینه سازی محصول و کاهش ضایعات تنظیم کنند.
- برداشت: محصولات و تعیین زمان بهینه برداشت، ربات ها را قادر می سازد تا به طور انتخابی محصولات رسیده را برای اطمینان از کیفیت خوب برداشت کنند. AGI به ویژه برای فعال کردن ربات ها برای چیدن میوه برای محصولات خاصی مفید است که در حال حاضر فقط به صورت دستی قابل برداشت هستند. با استفاده

از AGI، روبات ها می توانند یاد بگیرند که ویژگی های خاص هر محصول را تشخیص دهند و استراتژی چیدن خود را بر این اساس برای بهبود کارایی برداشت تنظیم کنند.

- آبیاری: AGI می تواند از داده های آب و هوای آنلاین استفاده کند. منابع، داده های محیطی محلی و رطوبت خاک از دستگاه های اینترنت اشیا، و رشد گیاه از پایش محصول برای بهینه سازی برنامه های آبیاری. AGI می تواند به ربات ها کمک کند تا میزان آبیاری هر گیاه را دقیقاً کنترل کنند، هدر رفت آب را کاهش داده و عملکرد محصول را بهبود بخشد.

- جستجوی محصول: AGI می تواند به ربات ها برای نظارت بر آن کمک کند. رشد محصول و شناسایی مسائل بالقوه در مراحل اولیه. با تجزیه و تحلیل داده های محصول جمع آوری شده با استفاده از حسگرها و دوربین ها، AGI می تواند فعالیت های فیزیولوژیکی گیاهان منفرد را که اطلاعات مهمی برای تصمیم گیری برای سایر وظایف کشاورزی است، نظارت کند. AGI همچنین می تواند به ربات ها کمک کند تا مشکلاتی از این قبیل را شناسایی کنند



شکل ۳: سناریوهای آینده تعامل انسان با روبات های کشاورزی با کمک AGI برای انجام عملیات کشاورزی کارآمدتر.

به عنوان تنش آبی، کمبود مواد مغذی، هجوم آفات، و شیوع بیماری، کشاورزان را قادر می سازد تا اقدامات اصلاحی را قبل از تحت تأثیر قرار دادن محصول انجام دهند.

- Phenotype فنوتیپ کردن: AGI می تواند یک ابزار عالی برای نژاد گیاهان باشد. به سرعت صفات فنوتیپی را از حجم زیادی از داده های جمع آوری شده توسط روبات ها استخراج می کند. AGI می تواند برای سازماندهی خودکار داده ها، انجام تجزیه و تحلیل های آماری پایه، تجسم داده ها، و تولید گزارش ها استفاده شود و در زمان تولیدکنندگان در تهیه و تجزیه و تحلیل داده ها صرفه جویی شود.

۶. سایر موارد

AGI برای کشاورزی دقیق و فنومیک: داده های تولید شده از کشاورزی دقیق معمولاً به شکل داده های خام جمع آوری شده از حسگرهای مختلف مانند تصاویر، ابرهای نقطه ای، طیف ها و اندازه گیری های سری زمانی است. در مقابل، مدل های زبان بزرگ (LLM) به طور سنتی در حوزه متن عمل می کنند. بنابراین، استفاده از LLM ها به طور مستقیم در کشاورزی ممکن است به نظر می رسد، جفت ساده دو کلمه کلیدی باشد. که ممکن است منجر به شک و تردید اولیه در مورد سودمندی بالقوه LLM در حوزه کشاورزی شود.

با این حال، در عمل، بسیاری از پیشرفت ها در کشاورزی ناشی از آزمایش هایی است که مقادیر زیادی متا داده را تولید می کنند که اغلب به زبان طبیعی بیان می شوند. به عنوان مثال پاپوتسوگلو و همکاران تلاش می کند تا ساختار داده های فنومیک گیاهی را رسمی کند، اما پیچیدگی محض رویکرد آنها موانع را برای کاربران بالقوه و همچنین خطر اشتباهات را افزایش می دهد.

LLM ها پتانسیل خودکارسازی جزئی یا کامل: وظایفی مانند ساختاردهی ابر داده های بدون ساختار (شکل ۴) را دارند. به عبارتی تبدیل ابر داده ها از یک فرمت به دیگری، و علامت گذاری اشتباهات احتمالی در طول جمع آوری داده ها. وقتی LLM با فناوری تشخیص صدا مانند Whisper API همراه شود، حتی می تواند به پرورش دهندگان گیاهی که در این زمینه کار می کنند در جمع آوری اندازه گیری ها بدون انجام ورود داده های خسته کننده و مستعد خطا کمک کند. علاوه بر این، Bubeck و همکاران نشان می دهد که نسل بعدی LLM ها ابزارهای بسیار توانمندی برای تجسم داده ها خواهند بود و به طور بالقوه به دست آوردن بینش مفید از این داده های متنی را بسیار آسان تر می کنند. LLM ها همچنین این توانایی را دارند که جستجوی مقادیر زیادی از داده های متنی را بسیار مؤثرتر کنند. به طور کلی، LLM ها این پتانسیل را دارند که تا حد زیادی به محققان در جمع آوری بینش های مفید از مقادیر زیادی داده های فنوتیپی کمک کنند.

AGI برای دام دقیق: تولید طیور و تخم مرغ منابع پروتئینی ارزشمند و مقرون به صرفه ای را برای افزایش جمعیت جهان فراهم می کند. در دهه های گذشته، بازده تولید جوجه های گوشتی در ایالات متحده به دلیل نوآوری های مستمر در پرورش حیوانات، مدیریت تغذیه، کنترل محیط زیست و پیشگیری از بیماری ها دو برابر شده است. با این حال، بهبود کارایی تولید حیوانی و کیفیت محصول تحت منابع طبیعی محدود (مانند آب شیرین و زمین) چالش برانگیز است، بنابراین تولید دقیق برای پرداختن به این موضوع بسیار مهم است. یکی از وظایف کلیدی تولید دقیق طیور، نظارت بر رفتار حیوانات برای ارزیابی رفاه و سلامت است. استفاده از AGI مانند GPT-۴ برای تجزیه و تحلیل ویدئوها و تصاویر طیور نیاز به نوآوری در توسعه بینایی کامپیوتر یا سیستم بینایی ماشین دارد. ترانسفورماتور بینایی (ViT) به یکی از روش های نوظهور برای نظارت بر اطلاعات حیوانات و به عنوان یک ابزار پشتیبانی تصمیم در پرورش حیوانات دقیق تبدیل شده است.



شکل ۴: نسخه کنونی ChatGPT در تبدیل داده های متنی بدون ساختار به داده های ساخت یافته بسیار توانایی دارد.

کارهای قبلی در طیور تجزیه و تحلیل رفاه عمدتاً بر روی استفاده از تکنیک‌های بینایی کامپیوتری مانند شبکه‌های عصبی کانولوشن (CNN) و الگوریتم‌های طبقه‌بندی تصویر برای تشخیص رفتارهای تغذیه، آشامیدن یا پیش‌پروری پرندگان متمرکز بود.

در سال‌های اخیر، روش‌های پیشرفته‌ای در ردیابی رفتارهای مشکل‌ساز جوجه‌ها مانند نوک زدن، تلفات، توزیع کف در جوجه‌های گوشتی و توزیع فضایی در مرغداری‌های بدون قفس گزارش شده است. با این حال، نظارت بر رفاه و تولید طیور با دید کامپیوتری به دلیل کمیاب بودن فیلم‌های آموزشی طیور، برچسب‌گذاری مسائل رفاهی مشکل‌ساز خاص مانند لنگش در جوجه‌های گوشتی و آسیب‌های نوک زدن در لایه‌ها، و تفسیر نتایج تجزیه و تحلیل به زبان قابل فهم برای مرغداران چالش برانگیز است. روش‌های قبلی برای پرورش طیور قابل اجرا نیستند زیرا تولیدکنندگان معمولاً دانشی از تجزیه و تحلیل داده‌ها با مدل‌های ML یا DL ندارند. ظهور ChatGPT یا GPT-۴ ظرفیت جدیدی را برای کشاورزان فراهم می‌کند زیرا آپلود یک ویدیو یا تصاویر مرغ در ChatGPT یا GPT-۴ به عنوان ورودی و انتظار خروجی‌ها (به عنوان مثال، رفتار یا رفاه خاص طیور) از ChatGPT پیچیده نیست. یا GPT-۴ به طور خودکار (شکل ۵ را ببینید).

AGI برای زیرساخت های کشاورزی: مدیریت زیرساخت و آموزش تاسیسات برای موفقیت و انعطاف پذیری در بخش کشاورزی امروزی اهمیت حیاتی دارد. پشتیبانی زیرساختی کافی، مانند پل‌ها، جاده‌ها، آبیاری، ذخیره‌سازی، فناوری اطلاعات و غیره می‌تواند بهره‌وری، قابلیت پردازش و ارزش‌های بازار را تا حد زیادی بهبود بخشد. به

دلیل نوسازی زیرساخت، پیچیدگی مدیریت و آموزش این زیرساخت به طور تصاعدی افزایش می‌یابد که رویکردهای سنتی را غیرممکن می‌سازد. در سال‌های اخیر، ما شاهد پتانسیل ابزارهای هوش مصنوعی و AGI برای پردازش و مدیریت کارآمد سیستم‌های پیچیده بوده‌ایم که می‌تواند به حوزه کشاورزی گسترش یابد. در این بخش، نقش AGI در مدیریت و آموزش زیرساخت‌های کشاورزی را خلاصه و پیش‌بینی می‌کنیم.

AGI برای مدیریت زیرساخت کارآمد: زیرساخت‌های قابل اعتماد یکی از عوامل کلیدی برای دامداران و کشاورزان برای گسترش عملیات و ارائه محصولات بهتر است. بدیهی است که چنین زیرساختی پتانسیل تبدیل و نوسازی کشاورزی و کشاورزی سنتی را به سیستم کشاورزی کارآمدتر، پایدارتر و پویاتر دارد.



شکل ۵: سیستم AI مولد برای ارزیابی خودکار وزن و رفاه طیور (نمره راه رفتن نشانگر توانایی راه رفتن است (۰-۱۰) پاهای سالم. ۱، لنگش متوسط و ۲- لنگش شدید مشابه پرندگان مرده).

بخش مهمی از نظر رشد اقتصادی و توسعه و تولید پایدار مواد غذایی به طور خاص، مدیریت زیرساخت شامل جاده‌های کشاورزی، توسعه زمین و سایر زیرساخت‌های حمل و نقل می‌شود. آب و آبیاری، سیستم‌های اطلاعاتی، تجهیزات کشاورزی، ماشین‌آلات، زیرساخت‌های ساختمانی (برخی نمونه‌ها شامل گلخانه‌ها، انبارها، صنایع کوچک مرتبط با تولیدات کشاورزی، سیلوها، مخازن و غیره)، تولید انرژی برای کشاورزی، زیرساخت‌های سازمانی (تحقیقات کشاورزی، فناوری ترویج و آموزش، خدمات اطلاعات و ارتباطات، خدمات مالی، بازاریابی و غیره)، و سیستم‌های مدیریت پسماند کشاورزی و غیره.

با این حال، مدیریت این زیرساخت‌ها یک کار چالش برانگیز است. این امر مستلزم هماهنگی، تخصیص مناسب و از همه مهمتر بهره‌برداری کارآمد است. رویکردهای موجود بیشتر بر مداخله و زمان‌بندی انسانی تکیه می‌کنند

که نمی‌تواند با مقیاس پیچیدگی همگام شود. بنابراین، مدیریت زیرساخت آینده برای رفع این مشکل بر ابزارهای پیشرفته ML مانند AGI تکیه خواهد کرد. AGI می‌تواند وظایف مدیریت زیرساخت ابتکاری زیر را ارائه دهد.

تعمیر و نگهداری پیش‌بینی کننده: AGI می‌تواند برای تجزیه و تحلیل استفاده شود. داده‌های حسگرها و منابع دیگر برای پیش‌بینی اینکه چه زمانی اجزای زیرساختی مانند سیستم‌های آبیاری، ماشین‌آلات کشاورزی و تأسیسات ذخیره‌سازی احتمالاً به تعمیر و نگهداری یا تعمیر نیاز دارند. این می‌تواند به کشاورزان و مدیران زیرساخت کمک کند تا اقدامات پیشگیرانه را انجام دهند و خطر خرابی تجهیزات و خرابی را کاهش دهند.

بهینه‌سازی منابع: AGI می‌تواند به کشاورزان کمک کند دامداران استفاده از منابعی مانند آبیاری، کود و آفت کش‌ها با تجزیه و تحلیل داده‌ها از حسگرها و سایر منابع را بهینه می‌کنند. ابزارهای یادگیری ماشینی می‌توانند به کشاورزان کمک کنند تا زمان و میزان بهینه استفاده از منابع را تعیین کنند، ضایعات را کاهش دهند و کارایی را افزایش دهند. علاوه بر این، این ابزارها همچنین می‌توانند به طور موثر برای استفاده بهتر از نظر هزینه سرمایه یا ارزش‌های اشتراک زمانی هماهنگ شوند.

طراحی و برنامه‌ریزی زیرساخت: AGI می‌تواند برای تجزیه و تحلیل داده‌های حسگرهای آب و هوا، حسگرهای خاک و سایر منابع برای اطلاع‌رسانی در برنامه‌ریزی و طراحی زیرساخت‌های کشاورزی مانند سیستم‌های آبیاری، سیستم‌های زهکشی، تأسیسات ذخیره‌سازی و سایر حسگرها استفاده می‌شود. AGI می‌تواند به مدیران زیرساخت کمک کند تا طراحی زیرساخت را بهینه کنند و کارایی تسهیلات را بهبود بخشند. به عنوان یک مثال، زیرساخت مرغداری نشان داده شده در شکل ۵ می‌تواند توسط AGI به سمت مدیریت کارآمدتر تسریع شود. مرغداری مدرن مجهز به حسگرهای بینایی پیشرفته (مانند دوربین‌های RGB و مادون قرمز)، فن‌ها، دستگاه‌های نظارت بر کیفیت هوا و غیره است. با تجزیه و تحلیل داده‌ها و استخراج AGI، تعمیر و نگهداری دستگاه با دقت بیشتری انجام می‌شود، به طوری که زمان از کار افتادگی به حداقل می‌رسد. از سوی دیگر، AGI می‌تواند به بهینه‌سازی زمان و مکان جمع‌آوری داده از چه کسی، برای بهینه‌سازی بهتر منابع دستگاه کمک کند.

AGI برای آموزش و آموزش زیرساخت: AGI همچنین می‌تواند به توسعه ابزارهایی کمک کند که می‌توانند آموزش کشاورزی را تسهیل کنند. انواع مختلف تجهیزات دستگاه‌ها آموزش را بسیار چالش‌برانگیز، زمان‌بر و تعمیر آن سخت می‌سازد. اخیراً، توسعه AGI می‌تواند چنین چالش‌هایی را برطرف کند. به عنوان مثال، تکثیر ابزارهای یادگیری در آموزش و ارزیابی بازخورد آن بسیار مؤثر بوده است. در این خط از تحقیقات، انتظار داریم که ابزارهای نوآورانه‌ای را بر اساس اصل AGI ببینیم که می‌توانند در حلقه آموزش و آموزش زیرساخت‌ها مورد استفاده قرار گیرند.

AGI می‌تواند به آموزش و آموزش زیرساختی در جنبه‌های زیر کمک کند.

- آموزش و آموزش شخصی: AGI می‌تواند برای تجزیه و تحلیل داده‌های کارآموز و ارائه توصیه‌های آموزشی شخصی‌سازی شده استفاده می‌شود و به کارآموزان اجازه می‌دهد تا روی مناطقی که بیشترین نیاز به بهبود

را دارند تمرکز کنند. علاوه بر این، بسته به پیشینه کارآموز، می توان یک مسیر یادگیری سفارشی طراحی کرد که هدف آن کارایی یادگیری بهتر است.

- تجزیه و تحلیل پیش بینی و بازخورد: الگوریتم های AGI می توانند برای تجزیه و تحلیل داده های جلسات آموزشی برای شناسایی روندها و پیش بینی نتایج آموزشی استفاده شوند. این امر بسیار مهم است زیرا جلسات آموزشی بیشتر به سمت آنلاین حرکت می کند و بازخورد از دیدگاه مربی به راحتی قابل درک نیست. با ابزار تحلیلی پیشرفته ارائه شده توسط ML، می تواند به مربیان در بهینه سازی برنامه های آموزشی و بهبود اثربخشی آموزش کمک کند.
- یادگیری مستمر: از AGI می توان برای برنامه های یادگیری مستمر، ارائه آموزش و حمایت مداوم به کشاورزان و دامداران حتی پس از پایان برنامه آموزشی اولیه استفاده کرد. که بسیار مفید است. زیرا کشاورزان و دامداران می توانند بر اساس پیشرفت خود، توسعه تجهیزات جدید یا نوع کشاورزی خود، یادگیری مادام العمر دریافت کنند. در مقایسه با رویکردهای فعلی، این روش جدید بسیار مؤثر خواهد بود، به ویژه ترکیب یادگیری شخصی و بازخورد پیش بینی کننده.

۷. نتیجه گیری

AGI پتانسیل زیادی برای متحول کردن سیستم های کشاورزی و غذایی، از جمله کشاورزی دقیق برای محصولات کشاورزی و دام، پردازش تصویر کشاورزی، NLP برای درک و پاسخگویی به مشکلات کشاورزی، رباتیک کشاورزی، نمودار دانش کشاورزی و مواد غذایی، و زیرساخت های کشاورزی دارد. AGI می تواند به کشاورزان و متخصصان کشاورزی بینش ها و توصیه های ارزشمندی در مورد چگونگی بهبود بهره وری و پایداری آنها ارائه دهد و در عین حال به چالش های پیش روی صنعت مانند تغییرات آب و هوا، امنیت غذایی و توسعه روستایی نیز رسیدگی کند. AGI می تواند تأثیر قابل توجهی بر اتوماسیون مزرعه داشته باشد، جایی که ربات ها و پهپادهای مجهز به بینایی کامپیوتری پیشرفته و قابلیت های یادگیری ماشینی می توانند طیف وسیعی از وظایف، از کاشت و برداشت تا نظارت بر محصولات و دام ها را انجام دهند. AGI با توانایی خود در درک زبان طبیعی، تصاویر و تولید پاسخ های شبیه انسان و افزایش قابلیت های رباتیک، ابزاری نوآورانه برای پیشرفت کشاورزی و بهبود معیشت افراد درگیر در این بخش حیاتی است.

تهیه و تنظیم: مریم سماواتیان

مراجع

- [۱] عباسی، ر.، مارتینز، پ.، احمد، ر.، ۲۰۲۲. دیجیتالی شدن صنعت کشاورزی - مروری بر ادبیات سیستماتیک در مورد کشاورزی ۴.۰، فناوری هوشمند کشاورزی، ۱۰۰۰۴۲.

[۲] Adke, S., Li, C., Rasheed, K.M., Maier, F.W., ۲۰۲۲. تحت نظارت و نظارت ضعیف یادگیری عمیق برای تقسیم بندی و شمارش غوزه های پنبه با استفاده از تصاویر نزدیک. حسگرها ۲۲.

[۳] Agarwal, O., Ge, H., Shakeri, S., Al-Rfou, R., ۲۰۲۱. تولید پیکره ترکیبی مبتنی بر نمودار دانش برای پیش آموزش مدل زبانی پیشرفته، در: مجموعه مقالات کنفرانس ۲۰۲۱ از بخش آمریکای شمالی انجمن زبان شناسی محاسباتی: فناوری های زبان انسانی، ص. ۳۵۵۴-۳۵۶۵.

[۴] Ahlers, D., ۲۰۱۳. Assessment of accuracy of geonames gazetteer data, in: مجموعه مقالات هفتمین کارگاه بازیابی اطلاعات جغرافیایی، صص ۷۴-۸۱.

[۵] Akiva, P., Dana, K., Oudemans, P., Mars, M., ۲۰۲۰. یافتن انواع توت ها: تقسیم بندی و شمارش کرن بری ها با استفاده از نظارت نقطه ای و پیشین های شکل. پیش چاپ: arXiv arXiv: ۲۰۰۴.۰۸۵۰۱.

[۶] Alam, A., ۲۰۲۱. آیا روبات ها باید جایگزین معلمان شوند؟ بسیج هوش مصنوعی و تجزیه و تحلیل یادگیری در آموزش، در: کنفرانس بین المللی پیشرفت در محاسبات، ارتباطات و کنترل (ICAC)، ص ۱-۱۲.

[۷] الرشیدی، ای.، ۲۰۱۹. راه حل هوشمند کشاورزی پایدار (ssa) که زیربنای اینترنت اشیا (IoT) و هوش مصنوعی (ai) است. arXiv preprint arXiv: ۱۹۰۶.۰۳۱۰۶.

[۸] Andrychowicz, M., Denil, M., Gomez, S., Hoffman, M.W., Píau, D., Schaul, T., Shillingford, N., De Freitas, N., ۲۰۱۶. یادگیری برای یادگیری با گرادیان نزول با نزول شیب. پیشرفت در سیستم های پردازش اطلاعات عصبی ۲۹.

[۹] Arumugam, K., Swathi, Y., Sanchez, D.T., Mustafa, M., Phoemchalard, C., Phasinam, K., Okoronkwo, E., ۲۰۲۲. به سوی کاربرد تکنیک های یادگیری ماشین در بخش کشاورزی و انرژی مواد امروزی: مجموعه مقالات ۵۱، ۲۲۶۰-۲۲۶۳.

[۱۰] Dbpedia: A Nucleus for a web of open data, in: The semantic Auer, S., Bizer, C., Kobilarov, G., Lehmann, J., Cyganiak, R., Ives, Z., ۲۰۰۷. صص ۷۲۲-۷۳۵.

[۱۱] Linkedgeodata: افزودن بعد فضایی به وب داده ها، در: هشتمین کنفرانس بین المللی وب معنایی در وب معنایی-ISWC، صص ۷۳۱-۷۴۶.

[۱۲] عیونی، س.، حجج، ف.، مده، م.، العتیبی، س.، ۲۰۲۱. یک رویکرد جدید مبتنی بر ml برای افزایش مشارکت دانش آموزان در محیط آنلاین. Plos one، e۱۶، ۲۰۸۷۸۸.

[۱۳] Azadi, S., Fisher, M., Kim, V.G., Wang, Z., Shechtman, E., Darrell, T., ۲۰۱۸. ابزار چند محتوایی برای انتقال سبک فونت چند شات، در: مجموعه مقالات کنفرانس IEHE در بینایی کامپیوتر و تشخیص الگو، صفحات ۷۵۷۳-۷۵۶۴.

[۱۴] Bansal, T., Jha, R., McCallum, A., ۲۰۱۹. یادگیری یادگیری چند مرحله ای در بین وظایف مختلف طبقه بندی زبان طبیعی. پیش چاپ arXiv