



کاربرد مدل‌های هوش مصنوعی در پایش و بهینه‌سازی عملکرد محصولات کشاورزی

نگار هریوندی^۱، جلال برادران مطیع^{۲*}

۱. دانشجوی مقطع کارشناسی مهندسی مکانیک بیوسیستم، گروه مهندسی بیوسیستم، دانشگاه فردوسی مشهد (negar.harivandi@um.ac.ir)

۲. عضو هیات علمی گروه مهندسی بیوسیستم، دانشگاه فردوسی مشهد (j.baradaran@um.ac.ir)

چکیده

این مقاله مروری نظام‌مند، کاربرد فناوری‌های نوین در کشاورزی دقیق را بررسی می‌کند و نقش سامانه‌های اطلاعات جغرافیایی (GIS)، سنجش از دور، اینترنت اشیا (IoT)، یادگیری عمیق و هوش مصنوعی مولد را در پایش، تحلیل و مدیریت محصولات کشاورزی تحلیل می‌کند. مطالعه منابع نشان می‌دهد که GIS و سنجش از دور امکان تحلیل دقیق ویژگی‌های زمین، شناسایی تنش‌های محیطی و پیش‌بینی عملکرد محصولات را فراهم می‌آورند، در حالی که IoT با جمع‌آوری داده‌های بلادرنگ از شرایط خاک، گیاه و آب، پایه‌ای برای تصمیم‌گیری هوشمند و اتوماسیون عملیات مزرعه فراهم می‌کند. هوش مصنوعی، به ویژه یادگیری عمیق و مدل‌های مولد، با تحلیل داده‌های پیچیده و تولید داده‌های مصنوعی، قادر به تشخیص زودهنگام بیماری‌ها و آفات، بهبود کیفیت تصاویر ماهواره‌ای و پهنای، مدل‌سازی رشد محصول و شبیه‌سازی داده‌های کم‌یاب است. مقاله همچنین به چالش‌های کلیدی این فناوری‌ها شامل محدودیت داده‌ها، نیاز به سخت‌افزار و پردازش ابری قدرتمند، پیچیدگی یکپارچه‌سازی داده‌های مکانی با مدل‌های عمیق، و مسائل امنیت و حریم خصوصی می‌پردازد. در کنار آن، فرصت‌های آینده مانند توسعه مدل‌های مولد پیشرفته، هوش مصنوعی توزیع‌پذیر، بهره‌گیری از شبکه‌های 5G و محاسبات لبه‌ای برای پایش بلادرنگ و تصمیم‌گیری هوشمند، قابلیت افزایش دقت و بهره‌وری را فراهم می‌کنند. این مقاله نتیجه‌گیری می‌کند که ادغام این فناوری‌ها، با کاهش مصرف منابع، افزایش بهره‌وری و بهبود تصمیم‌گیری، مسیر کشاورزی هوشمند، پایدار و داده‌محور را هموار می‌سازد و افق‌های جدیدی برای تحقیقات و کاربردهای عملی در مدیریت جامع مزرعه ارائه می‌دهد.

کلمات کلیدی

اینترنت اشیا، سامانه اطلاعات جغرافیایی، سنجش از دور، کشاورزی دقیق، هوش مصنوعی مولد، یادگیری عمیق.

*نویسنده مسئول: جلال برادران مطیع (j.baradaran@um.ac.ir)



مقدمه

با توجه به رشد سریع جمعیت و محدودیت منابع طبیعی، به‌ویژه آب و خاک، استفاده از روش‌های نوین برای مدیریت مزارع به یک ضرورت اساسی در کشاورزی مدرن تبدیل شده است. در این میان، نظارت بلادرنگ بر محصولات کشاورزی نقش کلیدی ایفا می‌کند؛ زیرا امکان رصد مداوم وضعیت گیاه، خاک و شرایط محیطی را فراهم ساخته و زمینه تصمیم‌گیری سریع و دقیق را برای کشاورزان و مدیران فراهم می‌آورد. این رویکرد می‌تواند با کاهش مصرف بی‌رویه نهاده‌هایی مانند آب، کود و سم، ضمن افزایش بهره‌وری، آثار زیست‌محیطی فعالیت‌های کشاورزی را نیز به حداقل برساند. به‌کارگیری فناوری‌های پیشرفته نظیر اینترنت اشیا و سامانه‌های اطلاعات جغرافیایی (GIS^۱) در این زمینه، موجب ارتقای دقت پایش، سهولت تحلیل داده‌های مکانی و ایجاد بستری برای مدیریت هوشمندانه منابع می‌شود. در نتیجه، نظارت بلادرنگ نه تنها ابزاری برای افزایش تولید و کیفیت محصولات است، بلکه گامی اساسی در جهت تحقق کشاورزی پایدار و سازگار با تغییرات اقلیمی محسوب می‌شود.

فناوری GIS به‌عنوان یک ابزار کلیدی در کشاورزی دقیق، امکان تحلیل و مدیریت داده‌های مکانی را فراهم می‌آورد. کشاورزان می‌توانند با استفاده از GIS ویژگی‌های زمین مانند نوع خاک، شیب، رطوبت و پوشش گیاهی را شبیه‌سازی و تحلیل کنند. این تحلیل‌ها در مناطق نیمه‌خشک برای ارزیابی کیفیت منابع آب آبیاری و مدیریت بهینه آن‌ها اهمیت ویژه دارد. ترکیب GIS با مدل‌های چندمتغیره می‌تواند شاخص کیفیت آب آبیاری را به‌طور مؤثری ارزیابی کند و به کشاورزان در اتخاذ تصمیمات بهینه کمک نماید [۱]. GIS همچنین در انتخاب بهترین نوع کشت با توجه به تنوع خاک و ویژگی‌های محیطی کاربرد دارد و می‌تواند بهره‌وری محصولات را افزایش دهد. استفاده از تکنیک‌هایی مانند AHP^۲ به همراه GIS، امکان تعیین بهترین چرخش زراعی برای محصولات مختلف را فراهم می‌کند و منجر به بهبود عملکرد و کاهش هزینه‌ها می‌شود [۱].

سنجش از دور (RS^۳) با تصاویر ماهواره‌ای و پهپادی، داده‌های گسترده و به‌روز از وضعیت گیاهان، رطوبت خاک و تغییرات محیطی ارائه می‌دهد. این داده‌ها به کشاورزان امکان می‌دهد مناطق نیازمند توجه ویژه را شناسایی کرده و اقدامات به‌موقعی مانند آبیاری، کوددهی و سمپاشی انجام دهند. ترکیب سنجش از دور با GIS (شکل ۱) امکان تحلیل دقیق‌تری از وضعیت مزارع و پیش‌بینی عملکرد محصولات را فراهم می‌کند [۲].



شکل ۱) بررسی اجمالی سامانه اطلاعات جغرافیایی و سنجش از دور در کشاورزی

¹ Geographic Information System

² Analytical Hierarchy Process

³ Remote Sensing



این فناوری همچنین در پایش بیماری‌ها و آفات گیاهی نقش کلیدی دارد. Khan و Cheema (۲۰۱۹) بیان کردند که با استفاده از تصاویر ماهواره‌ای و پهنپاشی می‌توان بیماری‌ها و آفات را به‌طور مؤثر شناسایی کرد و اقدامات پیشگیرانه و درمانی را به‌موقع انجام داد که منجر به کاهش خسارت و افزایش کیفیت محصول می‌شود. این فناوری امکان پایش گسترده و تحلیل محیطی را فراهم می‌کند و اطلاعات مکانی-زمانی ارزشمندی برای مدیریت زمین، خاک و منابع آبی ارائه می‌دهند [۳،۴].

مطالعه‌ی Mansoor و همکاران (۲۰۲۵) نشان می‌دهد که ادغام حسگرهای هوشمند و اینترنت اشیا (IoT^1) در کشاورزی دقیق، نه تنها داده‌های بلادرنگ از شرایط خاک، آب و گیاه را فراهم می‌کند، بلکه امکان یکپارچه‌سازی این داده‌ها با الگوریتم‌های یادگیری ماشین و هوش مصنوعی را نیز ایجاد می‌نماید. به‌گفته‌ی نویسندگان، IoT در کشاورزی فراتر از جمع‌آوری داده است و در حقیقت بستر اصلی برای تصمیم‌گیری هوشمند و اتوماسیون عملیات مزرعه به شمار می‌رود. برای مثال، حسگرهای متصل به IoT قادرند پارامترهایی مانند رطوبت خاک، سطح مواد مغذی، دمای محیط و حتی حضور آفات را ردیابی کرده و این اطلاعات را در قالب شبکه‌های ابری به سیستم‌های مدیریتی ارسال کنند. این فرایند نه تنها مدیریت دقیق‌تر منابع آب و کود را امکان‌پذیر می‌سازد، بلکه با کاهش مصرف نهاده‌ها به پایداری محیط‌زیست نیز کمک می‌کند [۴].

به‌علاوه، Mansoor و همکاران (۲۰۲۵) تأکید می‌کنند که چالش‌های مهمی همچون امنیت داده‌ها، مقیاس‌پذیری زیرساخت‌ها، هزینه‌های اولیه و استانداردسازی پروتکل‌های ارتباطی هنوز مانع از پیاده‌سازی گسترده IoT در مزارع بزرگ‌مقیاس است. با این حال، روندهای اخیر نشان می‌دهد که توسعه‌ی شبکه‌های $5G$ و استفاده از انرژی‌های تجدیدپذیر در حسگرها، این محدودیت‌ها را کاهش خواهد داد. در نتیجه، IoT نه تنها یک ابزار کمکی، بلکه به‌عنوان یک زیرساخت حیاتی برای کشاورزی آینده معرفی می‌شود [۴].

طبق مرور جامع Miller و همکاران (۲۰۲۵)، ورود هوش مصنوعی (AI^2) به کشاورزی نقطه‌ی عطفی در گذار از مدیریت سنتی به کشاورزی داده‌محور و هوشمند محسوب می‌شود. آن‌ها نشان می‌دهند که با افزایش وابستگی کشاورزی به داده‌های جمع‌آوری‌شده از حسگرهای IoT ، تصاویر ماهواره‌ای و داده‌های سنجش از دور، نیاز به ابزارهایی برای پردازش سریع، تحلیل پیشرفته و تصمیم‌گیری هوشمند بیش از پیش احساس می‌شود. هوش مصنوعی قادر است با تحلیل این داده‌های پیچیده، فرایندهایی مانند پیش‌بینی عملکرد، پایش سلامت گیاه، بهینه‌سازی مصرف آب و کود و حتی مدیریت زنجیره تأمین محصولات کشاورزی را به‌صورت بلادرنگ پشتیبانی کند. به همین دلیل، نویسندگان AI را نه صرفاً یک ابزار کمکی، بلکه زیرساخت اصلی کشاورزی آینده می‌دانند [۵].

در این میان، یادگیری عمیق (DL^3) به‌عنوان یکی از شاخه‌های پیشرفته‌ی هوش مصنوعی نقش ویژه‌ای ایفا می‌کند. به‌گفته‌ی Miller و همکاران، مدل‌های یادگیری عمیق به‌ویژه شبکه‌های عصبی کانولوشنی ($CNNs^4$) و شبکه‌های بازگشتی ($RNNs^5$) توانسته‌اند در زمینه‌هایی چون تشخیص خودکار بیماری‌ها و آفات از روی تصاویر برگ و میوه، پیش‌بینی دقیق عملکرد محصول بر اساس شرایط اقلیمی و خاک، و شناسایی تنش‌های ناشی از کم‌آبی یا کمبود مواد مغذی نتایجی فراتر از مدل‌های سنتی ارائه دهند. این الگوریتم‌ها با قابلیت یادگیری از داده‌های کلان و پیچیده، امکان استخراج الگوهایی را فراهم می‌سازند که برای انسان یا حتی روش‌های کلاسیک آماری غیرقابل مشاهده است. در واقع، یادگیری عمیق پلی میان داده‌های خام و تصمیم‌گیری هوشمند کشاورزی ایجاد می‌کند [۵].

با این وجود، مطالعه‌ی Miller و همکاران (۲۰۲۵) تأکید می‌کند که چالش‌هایی مانند نیاز به داده‌های آموزشی بزرگ و متنوع، هزینه‌های بالای محاسباتی، و ضعف در تفسیرپذیری نتایج شبکه‌های عصبی همچنان موانعی جدی هستند. راهکارهایی مانند یادگیری انتقالی^۶ و یادگیری فدرال^۷ به‌عنوان مسیرهای نوظهور برای غلبه بر این محدودیت‌ها پیشنهاد شده‌اند. به‌طور کلی، نویسندگان نتیجه می‌گیرند که ترکیب IoT با هوش مصنوعی و یادگیری عمیق می‌تواند تحول بنیادینی در پایداری، بهره‌وری و هوشمندسازی کشاورزی آینده رقم بزند [۵].

¹ Internet of Things

² Artificial Intelligence

³ Deep Learning

⁴ Convolutional Neural Networks

⁵ Recurrent Neural Networks

⁶ Transfer Learning

⁷ Federated Learning



مدل‌های هوش مصنوعی مولد (Generative AI) قادر به تولید داده‌ها و الگوهای نوین بر پایه اطلاعات موجود هستند و بدین ترتیب امکان شبیه‌سازی سناریوهای مختلف کشاورزی، پیش‌بینی رشد و عملکرد محصولات، و تحلیل شرایط محیطی را فراهم می‌آورند. این فناوری به ویژه در شرایطی که داده‌های واقعی محدود یا ناقص باشند، اهمیت دارد، زیرا می‌تواند داده‌های آموزشی مصنوعی تولید کرده و دقت مدل‌های یادگیری عمیق را بهبود بخشد. علاوه بر این، مدل‌های مولد در تشخیص زودهنگام بیماری‌ها و آفات، برنامه‌ریزی هوشمند آبیاری و مدیریت تغذیه گیاهان، و پیش‌بینی کیفیت محصولات نقش مؤثری ایفا می‌کنند و به عنوان یک ابزار مکمل و تقویتی برای سامانه‌های IoT و حسگرهای هوشمند در تحقق کشاورزی دقیق و هوشمند عمل می‌نمایند [۴]. در کنار آن، یادگیری عمیق با تحلیل تصاویر و داده‌های پیچیده، امکان پیش‌بینی رشد محصول و تشخیص بیماری‌ها را بهبود می‌دهد [۵].

در این مطالعه مروری، منابع علمی مرتبط با کاربرد فناوری‌های نوین در کشاورزی دقیق، شامل مقالات منتشر شده بین سال‌های ۲۰۱۷ تا ۲۰۲۵، با تمرکز بر GIS، سنجش از دور، اینترنت اشیا (IoT)، یادگیری ماشین، یادگیری عمیق و هوش مصنوعی مولد بررسی شد. جمع‌آوری داده‌ها بر پایه یک جستجوی سیستماتیک و ساختارمند در پایگاه‌های اطلاعاتی معتبر مانند Scopus، Web of Science، Google Scholar انجام شد، به‌طوری که کلیدواژه‌ها با دقت انتخاب شدند تا پوشش جامع مفاهیم مرتبط با «Precision Agriculture»، «Generative AI»، «Remote Sensing»، «GIS» و «IoT» فراهم شود. پس از بازبایی منابع اولیه، مقالات غیرمرتبط، تکراری و فاقد کیفیت علمی حذف شده و اطلاعات استخراج شده شامل نوع فناوری، کاربرد عملی در پایش و بهینه‌سازی محصولات کشاورزی، مدل‌های یادگیری عمیق به کار رفته و نتایج گزارش شده تحلیل شد. این تحلیل به صورت کیفی و کمی امکان مقایسه دقیق بین رویکردهای سنتی و هوشمند را فراهم کرده و توانمندی‌ها، محدودیت‌ها و فرصت‌های بالقوه هر فناوری را شناسایی می‌کند. مرور ارائه شده، علاوه بر معرفی مبانی سیستم‌های سنتی نظارت بر محصولات و اصول GIS و یادگیری عمیق، مفاهیم پایه‌ای مانند CNN، RNN، و Transformers و مدل‌های هوش مصنوعی مولد (GANs، VAEs، Diffusion Models) را معرفی کرده و کاربردهای عملی این مدل‌ها در تشخیص بیماری‌ها، مدل‌سازی رشد محصول و بهبود کیفیت تصاویر ماهواره‌ای و پهبادی را بررسی می‌کند. همچنین ادغام یادگیری عمیق با GIS برای نظارت بلادرنگ و معماری‌های مبتنی بر IoT تحلیل شده و در نهایت، چالش‌ها، محدودیت‌ها و فرصت‌های آینده در مسیر توسعه کشاورزی هوشمند و داده‌محور مطرح شده است.

پیش در آمدی بر مبانی نظری

سیستم‌های سنتی نظارت بر محصول در کشاورزی، عمدتاً بر پایه روش‌های دستی و تجربی استوار بوده‌اند. این سیستم‌ها شامل بازدیدهای میدانی منظم، بررسی‌های چشمی وضعیت گیاهان، و نمونه‌برداری از خاک و برگ برای تحلیل‌های آزمایشگاهی می‌شوند. اگرچه این روش‌ها در گذشته رایج بوده‌اند، اما با چالش‌هایی نظیر زمان‌بر بودن، نیاز به نیروی انسانی زیاد، و دقت محدود مواجه هستند. علاوه بر این، این سیستم‌ها معمولاً قادر به ارائه اطلاعات بلادرنگ یا تحلیل‌های دقیق برای تصمیم‌گیری‌های به موقع نیستند. به همین دلیل، در سال‌های اخیر، کشاورزان و محققان به دنبال جایگزین‌هایی با کارایی بالاتر و دقت بیشتر بوده‌اند [۶]. با پیشرفت فناوری‌های کشاورزی دقیق، GIS به عنوان یک چارچوب تحلیلی و تصمیم‌گیری پیشرفته جایگاه ویژه‌ای یافته است. اصول کار GIS در کشاورزی هوشمند مبتنی بر مدل‌سازی مکانی، تحلیل داده‌های لایه‌ای و استخراج روابط فضایی و مکانی-زمانی است که امکان شناسایی الگوهای پیچیده و پیش‌بینی وضعیت مزرعه را فراهم می‌کند. جایگاه GIS در این حوزه فراتر از جمع‌آوری و نمایش داده‌هاست و به عنوان ابزاری برای پشتیبانی تصمیمات مدیریتی و بهینه‌سازی عملیات مزرعه عمل می‌کند. Mahanta و همکاران (۲۰۲۴) نشان داده‌اند که ادغام GIS با فناوری‌های نوین، از جمله سنجش از دور و سیستم‌های موقعیت‌یاب جهانی (GPS)، می‌تواند کارایی، دقت و پایداری کشاورزی هوشمند را به شکل قابل توجهی ارتقا دهد [۷].

شبکه‌های عصبی کانولوشنی (CNN) به عنوان یکی از پیشرفته‌ترین ابزارهای یادگیری عمیق در کشاورزی هوشمند برای تشخیص بیماری‌های گیاهی و تحلیل تصاویر مزرعه می‌باشند. این شبکه‌ها قادرند با استفاده از لایه‌های کانولوشنی و pooling، ویژگی‌های مکانی پیچیده تصاویر برگ‌ها و محصولات را استخراج کرده و بیماری‌ها را با دقت بالا شناسایی کنند. مطالعات Gülmez (۲۰۲۴) نشان می‌دهد که الگوریتم‌های مختلف CNN مانند ResNet، VGG و MobileNet برای طبقه‌بندی بیماری‌ها و کاهش خطای تشخیص



چگونه در سیب زمینی مورد ارزیابی قرار گرفته‌اند (شکل ۲). استفاده از تصاویر RGB، چندطیفی و داده‌های سنجش از دور باعث افزایش دقت و تعمیم‌پذیری مدل‌ها در شرایط محیطی متفاوت می‌شود. علاوه بر این، چالش‌هایی مانند کمبود داده‌های آموزشی، تغییرات در علائم بیماری و اختلالات موجود در محیط مطرح است که با روش‌هایی مانند افزایش داده و یادگیری فدرال می‌توان تا حدی آن‌ها را کاهش داد. این مقاله تأکید می‌کند که CNNها نه تنها برای تشخیص بیماری، بلکه برای پایش رشد محصول و مدیریت منابع مزرعه نیز کاربرد دارند و با ادغام با سایر فناوری‌ها مانند GIS و IoT، پتانسیل بالایی برای ارتقای کشاورزی دقیق دارند [۸].



شکل ۲) چارچوب کلی کاربردهای شبکه عصبی کانولوشنی (CNN)

شبکه‌های عصبی بازگشتی (RNN) برای پردازش داده‌های توالی‌دار و زمانی طراحی شده‌اند و از ساختار بازگشتی خود برای حفظ اطلاعات ورودی‌های گذشته در پردازش داده‌های بعدی استفاده می‌کنند. این ویژگی امکان مدل‌سازی وابستگی‌های زمانی بلندمدت در داده‌ها را فراهم می‌کند. در کشاورزی هوشمند، RNNها به‌طور گسترده برای پیش‌بینی سری‌های زمانی مانند رشد گیاه، تغییرات رطوبت و دما، و پیش‌بینی عملکرد محصول کاربرد دارند. نسخه‌های پیشرفته مانند LSTM¹ و GRU² مشکلات فراموشی طولانی‌مدت اطلاعات در RNNهای ساده را برطرف کرده و دقت پیش‌بینی را افزایش می‌دهند. همچنین، RNNها با ادغام داده‌های مکانی و زمانی، می‌توانند نقش مهمی در سیستم‌های نظارت بلادرنگ و تصمیم‌گیری بهینه در مزرعه ایفا کنند [۹].

ترنسفورمرها معماری‌های پیشرفته یادگیری عمیق هستند که با استفاده از مکانیزم توجه قادرند وابستگی‌های طولانی‌مدت و روابط پیچیده بین عناصر داده‌های توالی‌دار را مدل‌سازی کنند. برخلاف شبکه‌های عصبی بازگشتی (RNN) و LSTM، ترنسفورمرها می‌توانند کل توالی داده‌ها را به‌طور موازی پردازش کنند و این امر باعث افزایش چشمگیر سرعت آموزش و پیش‌بینی می‌شود. معماری ترنسفورمر شامل لایه‌های Encoder و Decoder است که هر کدام از چند بلوک توجه چندسره و شبکه‌های کاملاً متصل تشکیل شده‌اند، و با مکانیزم‌های نرمال‌سازی و موقعیت‌یابی قادر به حفظ اطلاعات مکانی و زمانی توالی‌ها هستند [۱۰].

در کشاورزی هوشمند، ترنسفورمرها به دلیل توانایی پردازش همزمان داده‌های چندحسی و چندمنبعی (تصاویر ماهواره‌ای، داده‌های هواشناسی، داده‌های IoT و پهبادی) کاربردهای متنوعی دارند. از جمله کاربردهای آن‌ها می‌توان به پیش‌بینی رشد محصول، تشخیص زودهنگام بیماری‌ها، تحلیل پراکنش آفات، شناسایی الگوهای پیچیده مکانی-زمانی و بهینه‌سازی منابع آب و کود اشاره کرد. همچنین، ترنسفورمرها پایه بسیاری از مدل‌های هوش مصنوعی مولد و مدل‌های زبانی بزرگ هستند که امکان شبیه‌سازی و تولید داده‌های مصنوعی با کیفیت بالا برای آموزش مدل‌های کشاورزی را فراهم می‌کنند. این ویژگی به خصوص زمانی اهمیت دارد که داده‌های واقعی محدود یا ناقص باشند و نیاز به افزایش تنوع داده‌ها برای آموزش مدل‌های دقیق وجود داشته باشد [۱۰].

¹ Long Short-Term Memory

² Gated Recurrent Unit



هوش مصنوعی مولد (Generative AI) شاخه‌ای از یادگیری ماشین است که قادر است داده‌های جدید و واقعی‌نما را بر اساس الگوهای موجود تولید کند. این مدل‌ها می‌توانند تصاویر، ویدئوها، متن و حتی داده‌های چندبعدی علمی را شبیه‌سازی کنند. در کشاورزی هوشمند، این قابلیت به خصوص برای افزایش حجم داده‌های آموزشی، شبیه‌سازی شرایط مختلف محیطی و تولید داده‌های چندطیفی یا ماهواره‌ای اهمیت دارد، به طوری که مدل‌های یادگیری عمیق بتوانند با دقت بالاتر آموزش ببینند و تصمیم‌گیری بهتری ارائه دهند [۱۱].

هوش مصنوعی مولد شامل چند نوع معماری اصلی است:

شبکه‌های مولد مقابله‌ای (GANs):

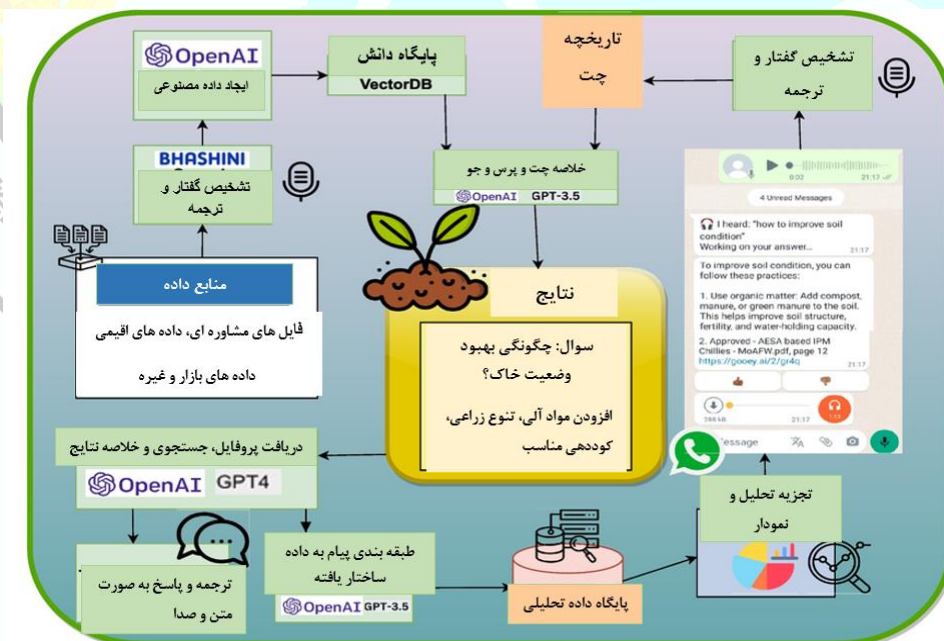
شبکه‌های مولد مقابله‌ای شامل دو شبکه عصبی هستند: یک مولد (Generator) که داده‌های مصنوعی تولید می‌کند و یک تمیزدهنده (Discriminator) که سعی می‌کند داده‌های واقعی و مصنوعی را از هم تشخیص دهد. این دو شبکه به صورت رقابتی آموزش می‌بینند تا مولد بتواند داده‌های بسیار واقعی تولید کند. در کشاورزی، GANها برای بهبود وضوح تصاویر ماهواره‌ای و پهنایی، شبیه‌سازی بیماری‌های گیاهی و افزایش تنوع داده‌های کم‌یاب استفاده می‌شوند. این مدل‌ها می‌توانند به آموزش دقیق‌تر شبکه‌های یادگیری عمیق کمک کنند، به ویژه زمانی که داده واقعی محدود باشد [۱۱].

خودرمزگذارهای واریانسی (VAEs):

VAEs با یادگیری توزیع احتمالی داده‌ها قادر به تولید نمونه‌های جدید هستند که ویژگی‌های آماری مشابه داده‌های اصلی دارند. در کشاورزی، VAEs برای شبیه‌سازی رشد محصول، تولید داده‌های چندطیفی، و تولید نمونه‌های آموزشی متنوع برای شبکه‌های عصبی کاربرد دارند. برخلاف GANها، VAEs مدل پلیدارتر و آموزش‌پذیرتری دارند و می‌توانند ویژگی‌های پیچیده مکانی و زمانی را حفظ کنند [۱۱].

مدل‌های انتشار (Diffusion Models):

مدل‌های انتشار فرآیند تولید داده را به صورت گام به گام و با استفاده از نویز کنترل‌شده انجام می‌دهند. این مدل‌ها قادرند تصاویر و داده‌های با کیفیت بسیار بالا تولید کنند و در کشاورزی برای بازسازی تصاویر ناقص ماهواره‌ای، شبیه‌سازی تغییرات محیطی و تولید داده‌های چندحسی استفاده می‌شوند. Diffusion Models در مقایسه با GANها کنترل بیشتری روی کیفیت و وضوح تصویر ارائه می‌دهند و می‌توانند داده‌های طبیعی‌تر تولید کنند [۱۱].



شکل ۳) سیستم مشاوره هوشمند کشاورزی با هوش مصنوعی مولد برای کشاورزی مدرن



برخی از کاربردهای هوش مصنوعی مولد در کشاورزی

تشخیص بیماری‌ها و آفات گیاهی با هوش مصنوعی مولد

در کشاورزی دقیق، تشخیص زودهنگام بیماری‌ها و آفات از اهمیت بالایی برخوردار است. یکی از چالش‌های اصلی در این حوزه، کمبود مجموعه داده‌های برچسب‌خورده و متنوع برای آموزش مدل‌های یادگیری عمیق است. هوش مصنوعی مولد، به‌ویژه شبکه‌های مولد مقابله‌ای (GANs)، این مشکل را با تولید تصاویر مصنوعی و واقع‌نما از گیاهان بیمار برطرف ساخته است [۱۳].

مطالعه‌ای توسط Lokesh و همکاران (۲۰۲۲)، یک سیستم مبتنی بر Cycle GAN برای شبیه‌سازی تصاویر برگ کاساوا معرفی کرده است. در این پژوهش، بیش از ۱۲۸۸۰ تصویر مصنوعی از برگ‌های مبتلا به پنج نوع بیماری تولید شد و در کنار تصاویر واقعی برای آموزش مدل‌هایی مانند VGG16 و ResNet34 به کار رفت. این رویکرد موجب ارتقای دقت تشخیص بیماری به ۹۹/۵۱٪ گردید که نسبت به روش‌های سنتی بهبود چشمگیری نشان می‌دهد [۱۳].

در این مجموعه داده که در شکل ۴ نیز بخش کوچکی نشان داده شده، پنج نوع بیماری و آفت گیاه کاساوا شناسایی شده است که هرکدام علائم مشخصی روی برگ‌ها دارند. این بیماری‌ها شامل: یک بیماری باکتریایی که باعث لکه‌های سیاه روی برگ می‌شود (CBB)، یک ویروس منتقل‌شده توسط سفیدبالک که موجب کلروز و لکه‌های کلروتیک می‌گردد (CBSD)، کنه‌ای که باعث ایجاد لکه‌های سفید و کاهش کلروفیل می‌شود (CGM)، و همچنین بیماری CMD که با لکه‌های سبز و تغییر رنگ زرد و سفید روی برگ‌ها همراه است. این دسته‌بندی به‌عنوان مبنایی برای آموزش و ارزیابی مدل‌های تشخیص بیماری گیاهی استفاده می‌شود [۱۳].



(a) CBB



(b) CBSD



(c) CGM



(d) CMD

شکل ۴) دسته‌های مختلف بیماری‌ها در برگ کاساوا

مدل‌سازی رشد محصول و شبیه‌سازی داده‌های کم‌یاب

هوش مصنوعی مولد، به‌ویژه مدل‌های انتشار (Diffusion Models)، در کشاورزی دقیق به‌عنوان ابزاری مؤثر برای مدل‌سازی رشد محصول و شبیه‌سازی داده‌های کم‌یاب شناخته می‌شوند. این مدل‌ها با تولید داده‌های مصنوعی واقع‌گرایانه تحت شرایط محیطی مختلف، به‌ویژه در مراحل که داده‌های واقعی محدود یا پرهزینه هستند، امکان آموزش مدل‌های یادگیری ماشین را فراهم می‌کنند. برای مثال، مدل‌های انتشار می‌توانند داده‌های رشد محصول را تحت شرایط محیطی متغیر شبیه‌سازی کنند که این امر به پیش‌بینی سلامت و عملکرد محصول در مراحل مختلف رشد کمک می‌کند. در زمینه شبیه‌سازی داده‌های کم‌یاب، مدل‌های مولد مانند DODA¹ با استفاده از مدل‌های انتشار و رمزگذارهای بصری، قادر به تولید داده‌های با کیفیت بالا برای شناسایی اشیاء در دامنه‌های جدید کشاورزی هستند. این روش‌ها با بهبود کیفیت برچسب‌ها و کنترل‌پذیری بیشتر در تولید داده‌ها، به‌ویژه در شناسایی بیماری‌ها و آفات،

¹ Data Synthesizer for Object Detection in Agriculture




مؤثر واقع می‌شوند. استفاده از این فناوری‌ها در کشاورزی دقیق موجب بهبود دقت مدل‌ها، کاهش هزینه‌های جمع‌آوری داده و تسریع فرآیند توسعه سیستم‌های هوشمند کشاورزی می‌شود [۱۴].

بهبود کیفیت تصویر ماهواره ای و پهنادی با GAN

در کشاورزی دقیق، بهبود کیفیت تصاویر ماهواره‌ای و پهنادی با استفاده از شبکه‌های مولد رقابتی (GAN)، به‌ویژه مدل‌های پیشرفته‌ای مانند Res-PGGAN، نقش اساسی در ارتقاء دقت تحلیل‌ها ایفا می‌کنند. این مدل‌ها با توانایی در بازسازی تصاویر با وضوح بالا، امکان شبیه‌سازی دقیق‌تری از وضعیت محصولات کشاورزی را فراهم می‌آورند. برای مثال، مدل Res-PGGAN با ترکیب شبکه‌های مولد و شبکه‌های باقیمانده، قادر است تصاویر ماهواره‌ای با وضوح ۱۰ متر را به تصاویری با وضوح ۰/۶۲۵ متر تبدیل کند، که این امر به شناسایی دقیق‌تر ویژگی‌های زمین مانند نوع پوشش گیاهی و وضعیت سلامت محصول کمک می‌کند. در شکل ۵، ۴ عکس متفاوت از یک زمین زراعی گرفته شده است. همچنین در جدول ۱ مقایسه‌ای بین این روش‌ها صورت گرفته است [۱۵].

علاوه بر این، ترکیب GAN با یادگیری عمیق و اینترنت اشیا (IoT) در کشاورزی دقیق، امکان جمع‌آوری و تحلیل داده‌های متنوع از منابع مختلف مانند حسگرهای زمینی، پهپادها و ماهواره‌ها را فراهم می‌کند. این یکپارچگی داده‌ها، به کشاورزان این امکان را می‌دهد که تصمیمات بهتری در زمینه مدیریت منابع، پیش‌بینی عملکرد محصول و شناسایی زود هنگام بیماری‌ها اتخاذ کنند. برای نمونه، استفاده از مدل‌های GAN در ترکیب با داده‌های IoT می‌تواند به شبیه‌سازی شرایط محیطی و پیش‌بینی تغییرات در وضعیت محصولات کمک کند، که این امر به بهبود بهره‌وری و کاهش هزینه‌ها منجر می‌شود [۱۵].



شکل ۵) تصویر ماهواره ای (a)، تصویر بازسازی شده با PGGAN (b)، تصویر بازسازی شده با Res-PGGAN (c)، تصویر اصلی پهپاد (d)

جدول ۱) مقایسه ویژگی‌های تصاویر گرفته شده

ویژگی / تصویر	ماهواره Sentinel-2	PGGAN بازسازی شده	Res-PGGAN بازسازی شده	پهپاد
پوشش منطقه	وسیع	مشابه ماهواره Sentinel-2	مشابه ماهواره Sentinel-2	محدود به محدوده پرواز پهپاد
دقت در بازسازی ویژگی‌ها	فقط داده اصلی	بهبود نسبی	بهبود قابل توجه و نزدیک به واقعیت	واقعی و دقیق
مزایا	دسترسی آسان و پوشش وسیع	وضوح بهتر، تولید جزئیات	وضوح بالا و جزئیات دقیق	جزئیات کامل و دقت بالا
محدودیت‌ها	جزئیات کم، وضوح پایین	برخی جزئیات دقیق ممکن نیست	هنوز امکان دارد جزئیات خیلی پیچیده پوشش کوچک، نیازمند پرواز و منابع کم باشد	



هوش مصنوعی مولد در پیش‌بینی شرایط اقلیمی و شبیه‌سازی سناریوهای تغییرات آب‌وهوا

هوش مصنوعی مولد در کشاورزی دقیق به‌عنوان ابزاری مؤثر برای پیش‌بینی شرایط اقلیمی و شبیه‌سازی سناریوهای تغییرات آب‌وهوا شناخته می‌شود. این فناوری با تولید داده‌های مصنوعی واقع‌گرایانه، امکان شبیه‌سازی دقیق‌تر و سریع‌تر شرایط اقلیمی را فراهم می‌کند. برای مثال، مدل «Spherical DYffusion» که توسط محققان دانشگاه کالیفرنیا سن‌دیگو و مؤسسه آلن برای هوش مصنوعی توسعه یافته، قادر است پیش‌بینی‌های اقلیمی ۱۰۰ ساله را در مدت ۲۵ ساعت انجام دهد؛ در حالی که مدل‌های سنتی به هفته‌ها زمان نیاز دارند. این مدل با ترکیب داده‌های فیزیکی و هوش مصنوعی، پیش‌بینی‌هایی با دقت بالا و هزینه محاسباتی کمتر ارائه می‌دهد [۱۶].

مدل (cBottle¹) یک مدل هوش مصنوعی مولد پیشرفته است که توسط NVIDIA توسعه یافته و به‌عنوان بخشی از پلتفرم Earth-2 عمل می‌کند. این مدل با استفاده از معماری انتشار (Diffusion Architecture) قادر است شرایط اقلیمی جهانی را با وضوح کیلومتری شبیه‌سازی کند. cBottle با ترکیب داده‌های شبیه‌سازی و مشاهداتی، پیش‌بینی‌های کوتاه‌مدت و بلندمدت اقلیمی را با دقت بالا ارائه می‌دهد. استفاده از این مدل‌ها می‌تواند به افزایش دقت پیش‌بینی‌های اقلیمی و پشتیبانی از تصمیم‌گیری‌های مؤثر سیاست‌گذاران و محققان در مواجهه با تغییرات اقلیمی کمک کند [۱۷].

ترکیب یادگیری عمیق و GIS برای نظارت بلادرنگ

روش‌های مهم پردازش تصویر مبتنی بر GIS

۱- کلاس‌بندی تصاویر

کلاس‌بندی تصاویر یکی از پرکاربردترین روش‌ها در پردازش تصویر GIS است که به شناسایی و دسته‌بندی انواع پوشش زمین، شامل مناطق کشاورزی، جنگل‌ها، آب‌ها و مناطق شهری می‌پردازد. این روش می‌تواند نظارت‌شده باشد که در آن داده‌های آموزشی از پیش مشخص شده به مدل داده می‌شود، یا بدون نظارت که مدل خود ویژگی‌ها را استخراج می‌کند. شبکه‌های عصبی کانولوشنی (CNN) و الگوریتم‌های یادگیری عمیق اخیراً برای بهبود دقت و کاهش خطا در کلاس‌بندی تصاویر ماهواره‌ای به‌کار گرفته شده‌اند [۱۸].

۲- ترکیب تصاویر

ترکیب تصاویر روشی است که داده‌های حاصل از سنسور از دور را از منابع مختلف، مانند تصاویر ماهواره‌ای با رزولوشن بالا و پایین، تصاویر هوایی یا داده‌های زمینی، یکپارچه می‌کند. هدف این روش افزایش کیفیت تصویر، وضوح فضایی و طیفی، و استخراج اطلاعات بیشتر است. ترکیب می‌تواند در سطوح پیکسلی، ویژگی‌ها یا تصمیم‌گیری انجام شود. استفاده از این روش در GIS به‌ویژه در کشاورزی دقیق، پایش جنگل‌ها و مدیریت منابع آب مفید است [۱۹].

۳- تشخیص تغییرات

تشخیص تغییرات روشی برای شناسایی تغییرات فضایی و زمانی در یک منطقه مشخص است. این روش با مقایسه تصاویر گرفته‌شده در زمان‌های مختلف، تغییرات در پوشش زمین، توسعه شهری، یا آسیب‌های طبیعی را شناسایی می‌کند. الگوریتم‌های مبتنی بر یادگیری عمیق، به‌ویژه CNN و ترنسفورمرها، امکان استخراج ویژگی‌های پیچیده و مقابله با نویز، تغییرات نور و ثبت تصاویر متفاوت را فراهم می‌کنند. این روش کاربرد زیادی در پایش محیط زیست، مدیریت منابع طبیعی و کشاورزی دقیق دارد [۲۰].

۴- بازسازی تصاویر

بازسازی تصاویر به منظور ترمیم تصاویر آسیب‌دیده، نویزی یا با کیفیت پایین انجام می‌شود. این فرآیند شامل حذف نویز، اصلاح اعوجاج هندسی، افزایش وضوح، و بازسازی جزئیات از دست‌رفته است. روش‌های مدرن از یادگیری عمیق برای بازسازی تصاویر

¹ Climate in a Bottle



ماهواره‌ای و پهنای استفاده می‌کنند و می‌توانند کیفیت تصاویر برای تحلیل دقیق GIS، کشاورزی دقیق و پایش محیط زیست را بهبود دهند [۲۱].

نقش داده مکانی-زمانی در پایش محصولات

داده‌های مکانی-زمانی نقش حیاتی در پایش محصولات کشاورزی ایفا می‌کنند. این داده‌ها با ترکیب اطلاعات مکانی (محل و ویژگی‌های زمین) و زمانی (تغییرات در طول زمان)، امکان تحلیل دقیق‌تری از رشد و وضعیت محصولات را فراهم می‌آورند. استفاده از این داده‌ها به‌ویژه در کشاورزی دقیق و پایش محیط‌زیست اهمیت ویژه‌ای دارد.

مطالعه‌ای که توسط Li و همکاران (۲۰۲۵) انجام شده است، چارچوبی برای به‌روزرسانی نقشه‌های سالانه مساحت‌های خاص محصول با استفاده از داده‌های مکانی-زمانی ارائه داده است. در این مطالعه، از مدل‌های یادگیری ماشین برای پیش‌بینی دینامیک‌های مکانی-زمانی مساحت‌های محصولات استفاده شده است. این رویکرد به‌ویژه در مناطقی مانند آفریقا و چین که دسترسی به داده‌های میدانی محدود است، کاربرد دارد. این مطالعه نشان‌دهنده اهمیت داده‌های مکانی-زمانی در تحلیل و پیش‌بینی وضعیت محصولات کشاورزی است [۲۲].

مطالعه‌ای دیگر توسط Omia و همکاران (۲۰۲۳) به بررسی فناوری‌های سنجش از دور برای پایش محصولات کشاورزی پرداخته است. آن‌ها تأکید دارند که استفاده از داده‌های مکانی-زمانی، به‌ویژه با ترکیب تصاویر چندطیفی و چندطیفی گسترده، امکان پایش تغییرات در قسمت‌های مختلف یک گیاه را فراهم می‌آورد. این رویکرد به‌ویژه در شبیه‌سازی رشد گیاهان و ارزیابی سلامت آن‌ها مؤثر است [۲۳].

در مطالعه‌ای دیگر، Rahman و همکاران (۲۰۲۵) با استفاده از داده‌های سنجش از دور برای ارزیابی خشکسالی‌های کشاورزی در پنجاب، پاکستان، نشان داده‌اند که داده‌های مکانی-زمانی می‌توانند تأثیر خشکسالی‌ها بر عملکرد محصولات را در طول زمان تحلیل کنند. این مطالعه نشان‌دهنده کاربرد داده‌های مکانی-زمانی در ارزیابی و مدیریت بحران‌های کشاورزی است [۲۴].

کاربردهای یادگیری ماشین (ML^1)، یادگیری عمیق و اینترنت اشیا در حوزه کشاورزی شامل طیف وسیعی از ظرفیت‌های تحول‌آفرین است [۲۵ و ۲۶]. شکل ۶ نمونه‌ای از این کاربردهای گسترده و متنوع را نشان می‌دهد و نقش بالقوه این فناوری‌ها را در جنبه‌های مختلف کشاورزی، از جمله پایش محصولات، تشخیص بیماری‌ها، مدیریت خاک، پیش‌بینی شرایط آب‌وهوایی و راهکارهای پس از برداشت، برجسته می‌سازد. بهره‌گیری از این فناوری‌ها قادر است با بهینه‌سازی مصرف منابع، افزایش بهره‌وری و ترویج شیوه‌های کشاورزی پایدار، تحولی بنیادین در بخش کشاورزی ایجاد کند [۲۷].



شکل ۶) کاربردهای عملی یادگیری ماشین، یادگیری عمیق و اینترنت اشیا در مدیریت جامع کشاورزی

¹ Machine Learning



نتایج و بحث

پیاده‌سازی سیستم‌های کشاورزی هوشمند مبتنی بر GIS، اینترنت اشیا و یادگیری عمیق با مجموعه‌ای از چالش‌ها و محدودیت‌ها مواجه است که می‌تواند بر کارایی و پذیرش این فناوری‌ها تأثیر بگذارد. کیفیت پایین و دسترسی محدود به داده‌های کشاورزی، یکی از موانع اصلی است که می‌تواند منجر به کاهش دقت مدل‌های پیش‌بینی و تحلیل شود. همچنین، اجرای مدل‌های پیچیده یادگیری عمیق نیازمند سخت‌افزار قدرتمند و منابع پردازشی ابری است که برای بسیاری از کشاورزان کوچک مقیاس قابل دسترسی نیست. یکپارچه‌سازی داده‌های مکانی با مدل‌های عمیق نیز به دلیل تفاوت در ساختار و فرمت داده‌ها، پیچیده و زمان‌بر است. علاوه بر این، مسائل امنیتی و حریم خصوصی داده‌های کشاورزی، کمبود تخصص فنی در میان کاربران، و هزینه‌های بالای زیرساختی، می‌توانند محدودیت‌های جدی برای پذیرش گسترده این فناوری‌ها ایجاد کنند. با وجود این چالش‌ها، تمرکز بر بهبود کیفیت داده‌ها، توسعه زیرساخت‌های مناسب، آموزش کشاورزان و رعایت استانداردهای امنیتی می‌تواند موجب تسهیل پذیرش و موفقیت فناوری‌های نوین در کشاورزی دقیق شود [۲۷].

آینده کشاورزی هوشمند با یادگیری ماشین، یادگیری عمیق و اینترنت اشیا چشم‌انداز گسترده‌ای از فرصت‌ها را پیش روی پژوهشگران و کشاورزان قرار می‌دهد. توسعه مدل‌های مولد پیشرفته، مانند GAN ها و Diffusion Models، امکان شبیه‌سازی داده‌های کم‌یاب، تولید سناریوهای متنوع رشد محصول و پیش‌بینی واکنش محصولات در شرایط محیطی مختلف را فراهم می‌کند، که این امر می‌تواند دقت پیش‌بینی‌ها و تصمیم‌گیری‌ها را به‌طور چشمگیری افزایش دهد. از سوی دیگر، طراحی هوش مصنوعی توزیع‌پذیر این امکان را فراهم می‌کند که محاسبات پیچیده در سطح مزرعه یا بین چند مزرعه انجام شود، بدون نیاز به ارسال مداوم داده‌ها به سرورهای مرکزی، که باعث کاهش تأخیر و افزایش امنیت داده‌ها می‌شود.

پیشرفت فناوری‌های 5G و محاسبات لبه‌ای، امکان پایش بلادرنگ پارامترهای محیطی و وضعیت محصولات را فراهم می‌آورد. این قابلیت به کشاورزان اجازه می‌دهد تا به‌سرعت واکنش نشان دهند، مثلاً آبیاری یا مدیریت تغذیه گیاهان را بهینه کنند و از اتلاف منابع جلوگیری شود. علاوه بر این، ترکیب داده‌های سنسور از دور، حسگرهای IoT و الگوریتم‌های یادگیری عمیق، می‌تواند الگوهای پیچیده رشد محصول، بیماری‌ها و اثرات محیطی را استخراج کند و منجر به توسعه سیستم‌های پیش‌بینی و توصیه‌گر هوشمند شود. جدول ۲، یافته‌ها و تحلیل انتقادی کاربرد هر فناوری و مدل پیشرفته در کشاورزی دقیق را نشان می‌دهد. هر فناوری از نظر مزایا، محدودیت‌ها و پتانسیل ترکیب با سایر روش‌ها بررسی شده است. این مقایسه، دیدگاهی جامع از اثربخشی و قابلیت‌های ادغام فناوری‌ها برای بهبود تصمیم‌گیری و پیش‌بینی در کشاورزی دقیق ارائه می‌دهد.

جدول ۲) مقایسه فناوری‌ها و مدل‌های پیشرفته در کشاورزی دقیق و تحلیل انتقادی آن‌ها

فناوری / مدل	یافته‌ها در مقاله	تحلیل انتقادی
GIS	تحلیل دقیق خاک، پوشش گیاهی و منابع آبی؛ شناسایی نقاط تنش محیطی [۱،۷]	GIS دقت مکانی پیش‌بینی رشد محصول را افزایش می‌دهد، اما بدون ادغام با داده‌های بلادرنگ IoT یا مدل‌های DL، قابلیت پیش‌بینی بلادرنگ محدود است. ترکیب GIS با RS و DL به‌طور چشمگیر دقت و قابلیت تصمیم‌گیری را بهبود می‌دهد.
سنسور از دور (RS)	تصاویر ماهواره‌ای و پهپادی برای پایش محصولات و تشخیص بیماری‌ها [۲،۳]	RS پوشش وسیع و داده‌های تاریخی فراهم می‌کند، ولی کیفیت و وضوح تصاویر ممکن است محدود باشد. ادغام RS با IoT و یادگیری عمیق امکان تشخیص سریع بیماری‌ها و استخراج الگوهای رشد محصول را بهبود می‌دهد، خصوصاً در مناطق با دسترسی محدود به داده‌های میدانی.
IoT/حسگرهای هوشمند	جمع‌آوری داده‌های بلادرنگ خاک، آب و گیاه؛ بستر تصمیم‌گیری هوشمند [۴،۵]	IoT امکان نظارت لحظه‌ای و جمع‌آوری داده‌های دقیق را فراهم می‌کند، اما محدودیت‌هایی در امنیت داده‌ها، مقیاس‌پذیری و هزینه زیرساخت دارد. ترکیب IoT با DL و مدل‌های مولد باعث افزایش دقت پیش‌بینی و کاهش تأخیر تصمیم‌گیری در مدیریت منابع می‌شود.



فناوری / مدل	یافته‌ها در مقاله	تحلیل انتقادی
یادگیری عمیق (CNN, RNN, Transformers)	تشخیص بیماری‌ها، پیش‌بینی رشد محصول، استخراج ویژگی‌های پیچیده تصاویر [۸, ۹, ۱۰]	CNN و RNN برای تحلیل تصاویر و داده‌های توالی‌دار عالی هستند، ولی نیاز به داده‌های بزرگ و پردازش سنگین دارند. ترنسفورمرها و یادگیری فدرال دقت پیش‌بینی را بالا می‌برند و محدودیت نیاز به داده‌های عظیم را کاهش می‌دهند، مخصوصاً در شرایط داده محدود.
هوش مصنوعی مولد (GAN, VAE, Diffusion Models)	تولید داده‌های مصنوعی، شبیه‌سازی سناریوهای کم‌یاب، بهبود کیفیت تصاویر ماهواره‌ای و پهپادی [۱۱, ۱۲]	مدل‌های مولد محدودیت کمبود داده را جبران می‌کنند و آموزش DL را دقیق‌تر می‌سازند، ولی آموزش آن‌ها نیازمند منابع محاسباتی قوی است. استفاده ترکیبی از GAN و Diffusion Models با CNN باعث پیش‌بینی دقیق رشد محصول و شبیه‌سازی سناریوهای اقلیمی می‌شود.
یکپارچگی فناوری‌ها (GIS + IoT + DL + Generative AI)	ایجاد کشاورزی دقیق، پایش بلادرنگ، بهبود مدیریت منابع و پیش‌بینی شرایط اقلیمی [۱۱, ۲۷]	ادغام فناوری‌ها بیشترین مزیت را دارد GIS: RS داده‌های مکانی-زمانی را فراهم می‌کنند، IoT داده‌های بلادرنگ جمع‌آوری می‌کند، DL و AI مولد تحلیل و پیش‌بینی را انجام می‌دهند. با این حال، پیچیدگی یکپارچه‌سازی، هزینه پردازشی و امنیت داده‌ها همچنان چالش اصلی است. این تحلیل نشان می‌دهد که ترکیب همه فناوری‌ها عملکرد کشاورزی دقیق را به‌طور چشمگیری ارتقا می‌دهد و قابلیت تصمیم‌گیری هوشمند و پایدار را فراهم می‌کند.

نتیجه‌گیری کلی

این مقاله یک مرور نظام‌مند بر کاربرد فناوری‌های نوین در کشاورزی دقیق ارائه داد و به بررسی نقش سامانه‌های اطلاعات جغرافیایی (GIS)، سنجش از دور، اینترنت اشیا (IoT)، یادگیری ماشین، یادگیری عمیق و هوش مصنوعی مولد در پایش، پیش‌بینی و بهینه‌سازی مدیریت مزارع پرداخت. نتایج نشان می‌دهد که ادغام این فناوری‌ها امکان پایش بلادرنگ محصولات، شناسایی زودهنگام بیماری‌ها و آفات، شبیه‌سازی رشد محصول، بهبود کیفیت تصاویر ماهواره‌ای و پهپادی، و پیش‌بینی شرایط اقلیمی را با دقت و کارایی بالا فراهم می‌کند. با وجود چالش‌هایی مانند کیفیت و دسترسی محدود داده‌ها، نیاز به سخت‌افزار و پردازش ابری قدرتمند، مسائل امنیتی و یکپارچه‌سازی پیچیده داده‌ها، فناوری‌های نوین پتانسیل ایجاد تحول بنیادین در کشاورزی پایدار را دارند. فرصت‌های آینده شامل استفاده از مدل‌های مولد پیشرفته، هوش مصنوعی توزیع‌پذیر، محاسبات لبه‌ای و شبکه‌های 5G برای پایش بلادرنگ و تصمیم‌گیری هوشمند است که می‌تواند بهره‌وری، کاهش هدررفت منابع و مدیریت پایدار مزارع را بهبود بخشد. در مجموع، این مرور نشان می‌دهد که ترکیب GIS، IoT و یادگیری عمیق پایه‌ای مستحکم برای توسعه کشاورزی دقیق، داده‌محور و پایدار فراهم می‌کند و مسیر پژوهشی روشنی برای تحقیق و کاربردهای عملی آینده ارائه می‌دهد.

منابع

- [1] Padhiary, M., Saikia, P., Roy, P., Hussain, N., & Kumar, K. (2025). A review on advancing agricultural efficiency through geographic information systems, remote sensing, and automated systems. *Cureus Journal of Engineering*.
- [2] Nandeha, N., Trivedi, A., Adawadkar, M. P., Subhasish, B., & Sonowal, S. (2025). Review on IoT, Remote Sensing, GIS and AI for Climate Smart Agriculture. *Journal of Experimental Agriculture International*, 47(6), 784-793.
- [3] Cheema, M. J. M., & Khan, M. A. (2019). Information technology for sustainable agriculture. In *Innovations in sustainable agriculture* (pp. 585-597). Cham: Springer International Publishing.



- [4] Mansoor, S., Iqbal, S., Popescu, S. M., Kim, S. L., Chung, Y. S., & Baek, J. H. (2025). Integration of smart sensors and IOT in precision agriculture: trends, challenges and future perspectives. *Frontiers in Plant Science*, 16, 1587869.
- [5] Miller, T., Mikiciuk, G., Durlik, I., Mikiciuk, M., Łobodzińska, A., & Śnieg, M. (2025). The IoT and AI in Agriculture: The Time Is Now—A Systematic Review of Smart Sensing Technologies. *Sensors (Basel, Switzerland)*, 25(12), 3583.
- [6] Nakalembe, C., Becker-Reshef, I., Bonifacio, R., Hu, G., Humber, M. L., Justice, C. J., ... & Sanchez, A. (2021). A review of satellite-based global agricultural monitoring systems available for Africa. *Global food security*, 29, 100543.
- [7] Mahanta, Chandan & Prusty, Ajay & Saha, Parnika. (2024). Application of GIS in Agriculture. 10.5281/zenodo.11340751.
- [8] Gülmez, B. (2024). A comprehensive review of convolutional neural networks based disease detection strategies in potato agriculture. *Potato Research*, 1-35.
- [9] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [10] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [11] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
- [12] Sai, S., Kumar, S., Gaur, A., Goyal, S., Chamola, V., & Hussain, A. (2025). Unleashing the power of generative AI in agriculture 4.0 for smart and sustainable farming. *Cognitive Computation*, 17(1), 63.
- [13] Lokesh, G. H., Chandregowda, S. B., Vishwanath, J., Ravi, V., Ravi, P., & Al Mazroa, A. (2024). Intelligent Plant Leaf Disease Detection Using Generative Adversarial Networks: a Case-study of Cassava Leaves. *The Open Agriculture Journal*, 18(1).
- [14] Hua, X., Chen, H., Duan, Q., Hong, D., Li, R., Shang, H., ... & Zhang, D. (2025). A Comprehensive Review of Diffusion Models in Smart Agriculture: Progress, Applications, and Challenges. *arXiv preprint arXiv:2507.18376*.
- [15] Han, H., Du, W., Feng, Z., Guo, Z., & Xu, T. (2024). An Effective Res-Progressive Growing Generative Adversarial Network-Based Cross-Platform Super-Resolution Reconstruction Method for Drone and Satellite Images. *Drones*, 8(9), 452.
- [16] Rühling Cachay, S., Henn, B., Watt-Meyer, O., Bretherton, C. S., & Yu, R. (2024). Probabilistic Emulation of a Global Climate Model with Spherical Diffusion. *Advances in Neural Information Processing Systems*, 37, 127610-127644.



- [17] https://www.wsj.com/articles/nvidia-climate-in-a-bottle-opens-a-view-into-earths-future-what-will-we-do-with-it-f602d8de?utm_source=chatgpt.com
- [18] Mehmood, M., Shahzad, A., Zafar, B., Shabbir, A., & Ali, N. (2022). Remote sensing image classification: A comprehensive review and applications. *Mathematical problems in engineering*, 2022(1), 5880959.
- [19] Li, Y., Zhuang, Y., Zhang, P., Lan, H., Niu, X., & El-Sheimy, N. (2017). An improved inertial/wifi/magnetic fusion structure for indoor navigation. *Information Fusion*, 34, 101-119.
- [20] Kadhim, I., & Abed, F. M. (2023). A critical review of remote sensing approaches and deep learning techniques in archaeology. *Sensors*, 23(6), 2918.
- [21] Rasti, B., Chang, Y., Dalsasso, E., Denis, L., & Ghamisi, P. (2021). Image restoration for remote sensing: Overview and toolbox. *IEEE Geoscience and Remote Sensing Magazine*, 10(2), 201-230.
- [22] Li, X., Yu, L., Du, Z., & Liu, X. (2025). Crop Statistic to Annual Map: Tracking spatiotemporal dynamics of crop-specific areas through machine learning and statistics disaggregating. *Scientific Data*, 12(1), 1249.
- [23] Karmakar, P., Teng, S. W., Murshed, M., Pang, S., Li, Y., & Lin, H. (2024). Crop monitoring by multimodal remote sensing: A review. *Remote Sensing Applications: Society and Environment*, 33, 101093.
- [24] Rahman, G., Khalid, S., Arshad, S., Moazzam, M. F. U., & Kwon, H. H. (2025). Remote sensing-based spatiotemporal assessment of agricultural drought and its impact on crop yields in Punjab, Pakistan. *Scientific Reports*, 15(1), 20586.
- [25] Jouini, O., Sethom, K., & Bouallegue, R. (2023, June). The impact of the application of deep learning techniques with IoT in smart agriculture. In *2023 International Wireless Communications and Mobile Computing (IWCMC)* (pp. 977-982). IEEE.
- [26] Marković, D., Koprivica, R., Pešović, U., & Randić, S. (2015). Application of IoT in monitoring and controlling agricultural production. *Acta Agriculturae Serbica*, 20(40), 145-153.
- [27] Benti, N. E., Chaka, M. D., Semie, A. G., Warkineh, B., & Soromessa, T. (2024). Transforming agriculture with Machine Learning, Deep Learning, and IoT: perspectives from Ethiopia—challenges and opportunities. *Discover Agriculture*, 2(1), 63.



Applications of Artificial Intelligence Models in Monitoring and Optimizing Crop Performance

Negar Harivandi¹, Jalal Baradaran Motie^{2*}

1. Undergraduate Student, Department of Biosystems Mechanical Engineering, Ferdowsi University of Mashhad, Mashhad, Iran, E-mail address: negar.harivandi@um.ac.ir
2. Faculty Member, Department of Biosystems Mechanical Engineering, Ferdowsi University of Mashhad, Mashhad, Iran, E-mail address: j.baradaran@um.ac.ir

Abstract

This systematic review examines the applications of emerging technologies in precision agriculture, analyzing the roles of Geographic Information Systems (GIS), remote sensing, the Internet of Things (IoT), deep learning, and generative artificial intelligence in monitoring, analyzing, and managing agricultural crops. The literature indicates that GIS and remote sensing enable detailed analysis of land characteristics, detection of environmental stressors, and prediction of crop performance, while IoT provides real-time data on soil, plant, and water conditions, forming the foundation for intelligent decision-making and farm automation. Artificial intelligence, particularly deep learning and generative models, can analyze complex datasets and generate synthetic data to support early detection of diseases and pests, enhance the quality of satellite and drone imagery, model crop growth, and simulate scarce datasets. The review also highlights key challenges, including limited data availability, the need for high-performance hardware and cloud computing, complexities in integrating spatial data with deep learning models, and data security and privacy concerns. Furthermore, future opportunities, such as advanced generative models, distributed AI, and leveraging 5G networks and edge computing for real-time monitoring and decision-making, promise to improve accuracy and productivity. The article concludes that integrating these technologies can optimize resource use, enhance productivity, and improve decision-making, paving the way toward smart, sustainable, and data-driven agriculture while opening new horizons for research and practical applications in comprehensive farm management.

Keywords

Deep Learning, Generative Artificial Intelligence, Geographic Information Systems (GIS), Internet of Things (IoT), Precision Agriculture, Remote Sensing.

***Corresponding authors name and email:** Jalal Baradaran Motie, j.baradaran@um.ac.ir