

نقش کلان‌داده‌ها و هوش مصنوعی در پایش خشکسالی و پیش‌بینی تغییر اقلیم

غلامرضا فرخی^{۱*}، محبوبه گاپله^۲

۱- استادیار، گروه علوم کشاورزی، دانشکده کشاورزی، دانشگاه پیام نور، تهران، ایران.

۲- مربی، گروه کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، تفرش، ایران.

چکیده

تغییر اقلیم و شدت رخداد‌های خشکسالی، چالش‌های فزاینده‌ای را برای مدیریت منابع آب و منابع طبیعی ایجاد کرده و ضرورت بهره‌گیری از فناوری‌های نوین داده‌محور را آشکار ساخته است. هدف این پژوهش، ارائه یک چارچوب تحلیلی یکپارچه از نقش کلان‌داده‌ها و هوش مصنوعی در پایش خشکسالی، پیش‌بینی تغییرات اقلیمی و پشتیبانی از تصمیم‌گیری در مدیریت پایدار منابع طبیعی است. این مطالعه با رویکرد مرور روایتی-تحلیلی انجام شد. پژوهش‌های منتشرشده در زمینه کاربرد کلان‌داده، سنجش از دور، اینترنت اشیاء، رایانش ابری، یادگیری ماشین و یادگیری عمیق در پایش خشکسالی و تغییر اقلیم بررسی و دسته‌بندی موضوعی شدند. طبقه‌بندی پنج‌گانه روش‌های هوش مصنوعی (یادگیری ماشین کلاسیک، یادگیری عمیق، مدل‌های مبتنی بر *Transformer*، هوش مصنوعی تبیین‌پذیر و مدل‌های فیزیک-آگاه) به‌عنوان چارچوب تحلیلی مقاله به‌کار گرفته شد و پایگاه‌های داده اقلیمی پرکاربرد (نظیر *MODIS*، *CHIRPS*، *ERA5* و *Sentinel*) معرفی و مقایسه شدند. نتایج نشان داد که تلفیق داده‌های چندمنبعی حاصل از سامانه‌های مشاهده زمین، شبکه‌های پایش زمینی و زیرساخت‌های کلان‌داده با الگوریتم‌های هوش مصنوعی، امکان پایش دقیق‌تر و بلادرنگ خشکسالی، شناسایی الگوهای مکانی-زمانی تغییرات اقلیمی، بهبود پیش‌بینی متغیرهای اقلیمی و توسعه سامانه‌های هشدار زودهنگام و تصمیم‌یار را فراهم می‌کند. با این حال، چالش‌های شناسایی‌شده در چهار سطح به‌هم‌پیوسته — داده‌ای (ناهمگنی و عدم قطعیت داده‌ها)، مدل‌سازی (بیش‌برازش و عدم تفسیرپذیری)، زیرساختی و نهادی (شکاف میان علم و سیاست‌گذاری، پراکندگی داده‌ها) — همچنان از موانع اصلی به‌شمار می‌روند. تحلیل ادبیات همچنین سه شکاف پژوهشی اصلی را آشکار ساخت: محدودیت قابلیت انتقال مکانی مدل‌ها، تمرکز نامتوازن بر خشکسالی هواشناسی به‌جای انواع هیدرولوژیک و اکولوژیک، و فقدان چارچوب‌های استاندارد ارزیابی. در مجموع، کلان‌داده و هوش مصنوعی ظرفیت بالایی برای ارتقای پایش و مدیریت خشکسالی دارند، اما توسعه این حوزه ماهیتی صرفاً فناورانه ندارد. توسعه مدل‌های هیبریدی فیزیکی-داده‌محور، گسترش هوش مصنوعی قابل توضیح و استانداردسازی چارچوب‌های ارزیابی، از مهم‌ترین الزامات بهره‌برداری مؤثر از این فناوری‌ها محسوب می‌شود.

کلید واژه‌ها: سامانه‌های هشدار سریع، سنجش از دور، شاخص‌های خشکسالی، مدل‌سازی اقلیمی، یادگیری عمیق، مرور روایتی-تحلیلی.

مقدمه

در دهه‌های اخیر، گسترش فناوری‌های تولید و پردازش داده — از شبکه‌های حسگر محیطی و اینترنت اشیا گرفته تا سامانه‌های سنجش از دور و زیرساخت‌های رایانش ابری — حجم بی‌سابقه‌ای از داده‌های محیطی تولید کرده است که امکان شناخت دقیق‌تر فرآیندهای پیچیده اقلیمی را فراهم می‌سازد. در این میان، کلان داده و هوش مصنوعی به یکی از ارکان اصلی علوم اقلیمی تبدیل شده‌اند؛ نه صرفاً به عنوان ابزارهای محاسباتی جانبی، بلکه به عنوان زیرساختی که ماهیت پژوهش در این حوزه را دگرگون کرده است (Götz et al., 2015). این تحول از آن جا اهمیت می‌یابد که زمین، به عنوان یک سامانه پیچیده و پویا، از تعامل مستمر میان مؤلفه‌های جوی، هیدرولوژیکی، زیستی و انسانی شکل می‌گیرد (Purnomo and Redha, 2025) و درک این تعاملات، بدون دسترسی به داده‌های گسترده، چندمنبعی و چندمقیاسی، عملاً ممکن نیست.

در این چارچوب، خشکسالی و تشدید پدیده‌های فرین اقلیمی به یکی از مهم‌ترین حوزه‌های کاربرد این فناوری‌ها بدل شده‌اند. خشکسالی از مهم‌ترین چالش‌های زیست‌محیطی، اقتصادی و اجتماعی قرن حاضر است (Salvador et al., 2022) و افزایش فراوانی، شدت و تداوم آن در بسیاری از مناطق جهان، آثار گسترده‌ای بر منابع آب، امنیت غذایی، اکوسیستم‌های طبیعی و توسعه پایدار برجای گذاشته است (Sivakumar, 2005). ماهیت تدریجی، گستره مکانی وسیع و پیامدهای چندبعدی خشکسالی، آن را به مسئله‌ای تبدیل کرده که پایش و پیش‌بینی مؤثر آن مستلزم تحلیل حجم عظیمی از داده‌های ناهمگون در مقیاس‌های مختلف زمانی و مکانی است — دقیقاً همان قابلیتی که کلان داده و هوش مصنوعی فراهم می‌کنند.

ماهیت چندبعدی و غیرخطی خشکسالی و تغییر اقلیم سبب شده است رویکردهای سنتی تحلیل داده در بسیاری از موارد پاسخگوی پیچیدگی‌های موجود نباشند. در مقابل، فناوری‌های نوین نظیر یادگیری ماشین، یادگیری عمیق، اینترنت اشیا و سامانه‌های پردازش داده‌های عظیم، ظرفیت قابل توجهی برای شناسایی الگوهای پنهان، تحلیل روابط غیرخطی و پیش‌بینی پدیده‌های اقلیمی فراهم کرده‌اند (Martino et al., 2025). این فناوری‌ها در سال‌های اخیر کاربرد گسترده‌ای در پایش خشکسالی، پیش‌بینی بارش، ارزیابی تغییرات کاربری اراضی،

مدیریت منابع آب، کشاورزی هوشمند و توسعه سامانه‌های هشدار سریع پیدا کرده‌اند و به یکی از مهم‌ترین ابزارهای پشتیبان تصمیم‌گیری در مدیریت مخاطرات اقلیمی و منابع طبیعی تبدیل شده‌اند (Verma et al., 2019).

با وجود رشد پژوهش‌ها در حوزه کلان داده‌های محیطی، بخش قابل توجهی از مطالعات موجود بر توسعه الگوریتم‌ها، زیرساخت‌های پردازش داده و کاربردهای عمومی تغییر اقلیم متمرکز بوده‌اند (Dikshit et al., 2021)، در حالی که مطالعات مرتبط با خشکسالی اغلب به صورت پراکنده و در قالب حوزه‌های تخصصی نظیر منابع آب، کشاورزی یا هواشناسی انجام شده‌اند (Seo and Lee, 2023). این پراکندگی موضوعی، همراه با رشد چشمگیر مطالعات مرتبط با کلان داده، هوش مصنوعی و تغییر اقلیم در سال‌های اخیر — که عمده‌تاً بر چهار محور مشاهده و پایش محیطی، درک و مدل‌سازی سامانه‌های اقلیمی، پیش‌بینی مخاطرات و پشتیبانی از تصمیم‌گیری متمرکز بوده‌اند (Xu et al., 2025) — نشان می‌دهد که هنوز نیاز به مرورهای تحلیلی احساس می‌شود که بتوانند تصویری یکپارچه از این حوزه ارائه دهند. چالش‌هایی نظیر ناهمگونی داده‌ها، عدم قطعیت اطلاعات اقلیمی، محدودیت تفسیرپذیری مدل‌های هوشمند و نبود چارچوب‌های استاندارد اعتبارسنجی نیز همچنان از موانع مهم توسعه این حوزه به شمار می‌روند.

با وجود گسترش مطالعات مرتبط با کاربرد هوش مصنوعی در پایش خشکسالی و پیش‌بینی اقلیم، اغلب پژوهش‌های موجود به صورت بخشی و در حوزه‌های مجزا انجام شده‌اند و ارتباط میان زیرساخت‌های کلان داده، الگوریتم‌های هوش مصنوعی و فرآیند تصمیم‌گیری در مدیریت پایدار منابع طبیعی کمتر به صورت یکپارچه تحلیل شده است. نوآوری پژوهش حاضر در این است که برخلاف مرورهای پیشین که عمدتاً یا بر جنبه‌های فناوریانه کلان داده یا بر کاربردهای مجزای هوش مصنوعی در خشکسالی و تغییر اقلیم متمرکز بوده‌اند، این مطالعه با ارائه یک چارچوب تحلیلی یکپارچه، سه مؤلفه کلان داده، هوش مصنوعی و فرآیند تصمیم‌سازی در مدیریت پایدار منابع طبیعی را به صورت هم‌زمان و در ارتباط با یکدیگر بررسی می‌کند.

بر این اساس، هدف پژوهش حاضر ارائه یک مرور تحلیلی از نقش کلان داده‌ها و هوش مصنوعی در پایش خشکسالی، پیش‌بینی تغییر اقلیم و مدیریت پایدار منابع طبیعی است. این

مطالعه با رویکرد مرور روایی-تحلیلی انجام شده است؛
جزئیات این رویکرد، از جمله تفاوت آن با مرور سیستماتیک
و پایگاه‌های اطلاعاتی و کلیدواژه‌های مورد استفاده، در بخش
«روش، مرور» ارائه شده است.

روش مرور

این پژوهش با رویکرد مرور روایتی-تحلیلی انجام شده است. برخلاف مرورهای سیستماتیک که بر پایه فرایندهای رسمی غربالگری، معیارهای دقیق ورود و خروج و ارزیابی کمی شواهد استوارند، هدف این رویکرد، ترکیب، تفسیر و تحلیل انتقادی یافته‌های پراکنده یک حوزه پژوهشی به‌منظور ارائه چارچوبی مفهومی و یکپارچه از روندها، فرصت‌ها و چالش‌های موجود است. با توجه به گستردگی و میان‌رشته‌ای بودن حوزه کلان‌داده، هوش مصنوعی، خشکسالی و تغییر اقلیم — که در برگیرنده زیر-حوزه‌های متنوعی نظیر هواشناسی، هیدرولوژی، علوم داده و سیاست‌گذاری منابع طبیعی است — این رویکرد امکان تحلیل موضوعی و تلفیق دیدگاه‌های چندگانه را با انعطاف بیشتری نسبت به مرور سیستماتیک فراهم می‌سازد.

برای گردآوری منابع، جست‌وجو در پایگاه‌های علمی معتبر Scopus، Web of Science، Google Scholar با به‌کارگیری ترکیب کلیدواژه‌هایی نظیر «Big Data AND «Machine Learning AND Climate Drought» «Remote Sensing AND Drought Change» «Monitoring» و «Artificial Intelligence AND Climate Prediction» انجام شد. جست‌وجو عمدتاً بر مقالات منتشرشده در مجلات معتبر بین‌المللی طی سال‌های اخیر متمرکز بود.

فرآیند تحلیل شامل سه گام اصلی بود: نخست، دسته‌بندی موضوعی مطالعات بر اساس محورهای اصلی کاربرد (پایش، پیش‌بینی، مدل‌سازی و پشتیبانی از تصمیم‌گیری)؛ دوم، شناسایی روش‌ها، منابع داده و فناوری‌های به‌کاررفته در هر مطالعه؛ و سوم، تحلیل تطبیقی قابلیت‌ها، محدودیت‌ها و شکاف‌های پژوهشی موجود در هر محور.

مبانی نظری کلان داده و هوش مصنوعی در
علوم اقلیمی

کلان‌داده در علوم اقلیمی: مفهوم، ویژگی‌ها و منابع تولید

کلان‌داده به مجموعه‌ای از داده‌ها اطلاق می‌شود که به دلیل حجم، تنوع و سرعت تولید، با ابزارها و روش‌های سنتی مدیریت و تحلیل داده قابل پردازش نیستند. در علوم اقلیمی، این مفهوم معمولاً بر پایه پنج ویژگی اصلی تعریف می‌شود: حجم (میزان انبوه داده‌های تولیدشده توسط ایستگاه‌های هواشناسی، ماهواره‌ها و حسگرهای محیطی)، تنوع (ناهمگونی داده‌ها از نظر ساختار، فرمت و منبع تولید، از داده‌های عددی گرفته تا تصاویر ماهواره‌ای و داده‌های متنی)، سرعت (نرخ تولید و به‌روزرسانی داده‌ها، به‌ویژه در سامانه‌های پایش بلادرنگ)، صحت (میزان اعتبار، دقت و عدم قطعیت داده‌ها) و ارزش (توان استخراج دانش و بینش کاربردی از داده‌های خام) (Purnomo and Redha, 2025). این ویژگی‌ها به‌طور مستقیم بر کیفیت تحلیل‌های اقلیمی و قابلیت اعتماد نتایج حاصل از مدل‌های هوشمند اثرگذارند.

منابع تولید کلان‌داده در علوم اقلیمی را می‌توان در چهار دسته اصلی طبقه‌بندی کرد: نخست، داده‌های میدانی و ایستگاهی که از شبکه‌های پایش زمینی هواشناسی و هیدرولوژیکی حاصل می‌شوند؛ دوم، داده‌های سنجش از دور که از ماهواره‌ها و سامانه‌های مشاهده زمین تولید می‌شوند و امکان پایش پیوسته متغیرهایی نظیر پوشش گیاهی، دمای سطح زمین و رطوبت خاک را در مقیاس‌های وسیع فراهم می‌کنند؛ سوم، خروجی مدل‌های عددی شامل مدل‌های گردش عمومی جو و محصولات بازتحلیل که با ترکیب مشاهدات و شبیه‌سازی‌های فیزیکی، تصویری پیوسته از وضعیت اقلیم ارائه می‌دهند؛ و چهارم، داده‌های دیرینه‌اقلیمی که امکان بازسازی روندهای اقلیمی گذشته را فراهم می‌سازند (Purnomo and Redha, 2025). گسترش فناوری‌های اینترنت اشیا و شبکه‌های حسگر هوشمند نیز در سال‌های اخیر منبع جدیدی از داده‌های محیطی با تفکیک مکانی و زمانی بالا ایجاد کرده که تلفیق آن با منابع سنتی، امکان پایش دقیق‌تر و بلندرنج خشکسالی و تغییرات اقلیمی را فراهم کرده است (Yaqoob et al., 2016).

مدیریت و پردازش این حجم از داده‌های ناهمگون، خود به یک چالش فنی مستقل تبدیل شده است. توسعه معماری‌های پردازش توزیع‌شده، رایانش ابری و سامانه‌های پردازش جریانی و دسته‌ای، زیرساخت لازم برای ذخیره‌سازی، یکپارچه‌سازی و تحلیل کارآمد داده‌های اقلیمی حجیم را فراهم کرده است (Chen and Zhang, 2014). بدون چنین

زیرساختی، حتی پیشرفته‌ترین الگوریتم‌های هوش مصنوعی باید دو مؤلفه مکمل و به هم پیوسته در نظر گرفت، نه دو حوزه نیز قادر به بهره‌برداری مؤثر از پتانسیل کلان داده‌های اقلیمی نخواهند بود؛ به همین دلیل، کلان داده و هوش مصنوعی را .

جدول ۱. مهم‌ترین منابع کلان داده‌های اقلیمی و ویژگی‌های آن‌ها در پایش خشکسالی و پیش‌بینی اقلیم

نوع داده	نمونه منابع	مقیاس مکانی-زمانی	متغیرهای اصلی	کاربرد در خشکسالی و اقلیم	محدودیت‌ها
سنجش‌ازدور	MODIS		LST, NDVI	پایش پوشش گیاهی،	ابرناسی، نیاز به
	Sentinel	منطقه‌ای تا جهانی	رطوبت خاک،	شاخص‌های خشکسالی، پایش	اعتبارسنجی زمینی
	SMAP, Landsat		ET	بلادرنگ	
داده‌های ایستگاهی	ایستگاه‌های هواشناسی و هیدرومتری	محلی	دما، بارش، رطوبت، باد	محاسبه شاخص‌های خشکسالی و کالیبراسیون مدل‌ها	پراکندگی مکانی، داده‌های مفقود
	ERA5		متغیرهای کامل جوی و سطحی	تحلیل روندها، ورودی مدل‌ها	وابستگی به مدل‌های عددی
	MERRA-2, JRA-55	جهانی			
مدل‌های اقلیمی	CMIP6, CORDEX	منطقه‌ای تا جهانی	سناریوهای آینده دما و بارش	تحلیل سناریوهای تغییر اقلیم	عدم قطعیت سناریویی
	AWS	محلی، بلادرنگ	رطوبت خاک، دما، بارش	هشدار زودهنگام و پایش لحظه‌ای	هزینه و نگهداری
	Citizen Science	محلی	گزارش رخدادها	اعتبارسنجی و تکمیل اطلاعات مخاطرات	ناهمگونی و قابلیت اعتماد پایین

طبقه‌بندی روش‌های هوش مصنوعی در تحلیل داده‌های اقلیمی

روش‌های هوش مصنوعی مورد استفاده در مطالعات خشکسالی و تغییر اقلیم را می‌توان در پنج دسته اصلی طبقه‌بندی کرد:

یادگیری ماشین کلاسیک. این دسته شامل الگوریتم‌هایی نظیر ماشین بردار پشتیبان، جنگل تصادفی و درخت تصمیم است که با یادگیری از ویژگی‌های از پیش استخراج‌شده، قادر به مدل‌سازی روابط غیرخطی میان متغیرهای اقلیمی و هیدرولوژیکی هستند. این روش‌ها به‌ویژه در مسائل با حجم داده متوسط و نیاز به تفسیرپذیری نسبی، کاربرد گسترده‌ای دارند (Dikshit et al., 2021).

یادگیری عمیق. شبکه‌های عصبی عمیق، شبکه‌های عصبی پیچشی و به‌ویژه شبکه‌های حافظه بلندمدت کوتاه‌مدت، با توانایی استخراج خودکار ویژگی از داده‌های حجیم و چندمنبعی، در تحلیل تصاویر ماهواره‌ای و پیش‌بینی سری‌های

زمانی اقلیمی عملکرد برجسته‌ای از خود نشان داده‌اند. این مدل‌ها به‌ویژه در یادگیری وابستگی‌های زمانی بلندمدت داده‌های اقلیمی برتری قابل توجهی نسبت به روش‌های کلاسیک دارند (Danandeh et al., 2023).

مدل‌های مبتنی بر Transformer. در سال‌های اخیر، معماری‌های مبتنی بر مکانیزم توجه، که ابتدا در حوزه پردازش زبان طبیعی توسعه یافتند، به تدریج در تحلیل داده‌های سری زمانی اقلیمی و داده‌های مکانی-زمانی با تفکیک بالا نیز به کار گرفته شده‌اند. این مدل‌ها با توانایی پردازش هم‌زمان وابستگی‌های بلندمدت و کوتاه‌مدت، در برخی کاربردهای پیش‌بینی اقلیمی نتایج امیدبخشی نشان داده‌اند، هرچند نیاز به حجم داده آموزشی و منابع محاسباتی بالا، کاربرد گسترده آن‌ها را در مطالعات اقلیمی محدود کرده است (Zhao et al., 2026; Ramu et al., 2025).

هوش مصنوعی تبیین‌پذیر. با توجه به محدودیت تفسیرپذیری مدل‌های پیچیده یادگیری عمیق، رویکردهای

هوش مصنوعی تبیین‌پذیر با هدف شفاف‌سازی فرآیند تصمیم‌گیری مدل‌ها توسعه یافته‌اند. این روش‌ها با ارائه توضیحی از سهم هر متغیر ورودی در پیش‌بینی نهایی، می‌توانند اعتمادپذیری مدل‌های هوشمند را در تصمیم‌گیری‌های حساس مدیریت منابع آب و خشکسالی افزایش دهند و پاسخی به یکی از مهم‌ترین چالش‌های مطرح‌شده در ادبیات این حوزه باشند (Núñez et al., 2023).

مدل‌های مبتنی بر فیزیک. این دسته از مدل‌ها با تلفیق دانش فیزیکی حاکم بر فرآیندهای اقلیمی و هیدرولوژیکی با ظرفیت یادگیری داده‌محور مدل‌های هوش مصنوعی، تلاش می‌کنند ضمن حفظ دقت آماری بالا، پایداری نتایج به اصول فیزیکی شناخته‌شده را نیز تضمین کنند. این رویکرد به‌ویژه در

شرایطی که داده‌های آموزشی محدود است یا نیاز به تعمیم‌پذیری مدل به مناطق جغرافیایی جدید وجود دارد، اهمیت می‌یابد (Karniadakis et al., 2021).

در میان این پنج دسته، مدل‌های ترکیبی که مزایای رویکردهای فیزیکی و داده‌محور را با یکدیگر تلفیق می‌کنند، به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند، چرا که می‌توانند ضمن بهبود دقت و قابلیت تعمیم نتایج، برخی محدودیت‌های تفسیرپذیری مدل‌های صرفاً داده‌محور را نیز کاهش دهند (Lotfifard et al., 2022). با این حال، انتخاب رویکرد مناسب در هر مطالعه به عواملی نظیر حجم و کیفیت داده در دسترس، ماهیت متغیر هدف و سطح تفسیرپذیری مورد نیاز برای کاربرد نهایی بستگی دارد (Shakeri et al., 2023).

جدول ۲. طبقه‌بندی، قابلیت‌ها و محدودیت‌های روش‌های هوش مصنوعی مورد استفاده در مطالعات خشکسالی و تغییر اقلیم

روش	مزیت	محدودیت	کاربردهای متداول در مطالعات خشکسالی و اقلیم
یادگیری ماشین کلاسیک (ماشین بردار پشتیبان، جنگل تصادفی، درخت تصمیم)	عملکرد مناسب در داده‌های حجم متوسط؛ تفسیرپذیری نسبی بالاتر نسبت به مدل‌های عمیق؛ مقاومت در برابر نویز و داده‌های ناقص (جنگل تصادفی)	حساسیت به تنظیم پارامترها؛ توان محدود در طبقه‌بندی شدت خشکسالی، استخراج خودکار ویژگی از داده‌های خام و رتبه‌بندی عوامل مؤثر، تهیه نقشه‌های خطر و آسیب‌پذیری	
یادگیری عمیق (شبکه عصبی عمیق، شبکه عصبی پیچشی، LSTM)	استخراج خودکار الگوهای پیچیده از داده‌های حجیم و چندمنبعی؛ توانایی بالا در تحلیل وابستگی‌های زمانی بلندمدت (LSTM) و تصاویر ماهواره‌ای (CNN)	نیاز به داده‌های آموزشی گسترده و توان محاسباتی بالا؛ تفسیرپذیری محدود؛ زمان آموزش طولانی	پیش‌بینی سری‌های زمانی اقلیمی (بارش، دما، شاخص‌های خشکسالی)، تحلیل تصاویر ماهواره‌ای، پایش پوشش گیاهی
مدل‌های مبتنی بر Transformer	پردازش هم‌زمان وابستگی‌های بلندمدت و کوتاه‌مدت در داده‌های سری زمانی و مکانی-زمانی؛ قابلیت مقیاس‌پذیری در داده‌های حجیم	نیاز به حجم داده آموزشی و منابع محاسباتی بسیار بالا؛ کاربرد هنوز محدود و نوظهور در اقلیمی، تحلیل الگوهای مکانی-زمانی با تفکیک بالا	پیش‌بینی بلندمدت متغیرهای اقلیمی، تحلیل الگوهای مکانی-زمانی با تفکیک بالا
هوش مصنوعی تبیین‌پذیر	شفاف‌سازی سهم متغیرهای ورودی در پیش‌بینی نهایی؛ افزایش اعتمادپذیری مدل نزد تصمیم‌گیران و سیاست‌گذاران	افزایش پیچیدگی محاسباتی؛ عدم استانداردسازی کامل روش‌های تبیین در حوزه اقلیم	پشتیبانی از تصمیم‌گیری در مدیریت منابع آب، اعتبارسنجی و پذیرش مدل‌ها توسط سیاست‌گذاران
مدل‌های فیزیک-آگاه	پایبندی نتایج به اصول فیزیکی شناخته‌شده؛ عملکرد بهتر در شرایط کمبود داده آموزشی؛ قابلیت تعمیم بالاتر به مناطق جدید	پیچیدگی طراحی و تلفیق قیود فیزیکی با ساختار یادگیری؛ نیاز به دانش تخصصی میان‌رشته‌ای	مدل‌سازی هیدرولوژیکی، شبیه‌سازی فرآیندهای اقلیمی در مناطق با داده محدود
مدل‌های ترکیبی	تلفیق مزایای رویکردهای فیزیکی و داده‌محور؛ بهبود هم‌زمان دقت آماری و قابلیت تفسیر؛ افزایش قابلیت تعمیم نتایج	پیچیدگی طراحی و نیاز به اعتبارسنجی و تنظیمات بیشتر	پیش‌بینی خشکسالی، مدیریت منابع آب، توسعه سامانه‌های پشتیبان تصمیم‌گیری

پایگاه‌های داده اقلیمی پرکاربرد در پایش خشکسالی و تحلیل تغییر اقلیم

انتخاب پایگاه داده مناسب، یکی از تصمیم‌های بنیادین در هر مطالعه داده‌محور اقلیمی است، چرا که وضوح مکانی و زمانی، دقت و بازه پوشش هر پایگاه، مستقیماً بر کیفیت نتایج مدل‌های هوش مصنوعی اثر می‌گذارد. در ادامه، مهم‌ترین پایگاه‌های داده مورد استفاده در مطالعات خشکسالی و تغییر اقلیم معرفی می‌شوند.

ERA5 محصول بازتحلیل نسل پنجم مرکز اروپایی پیش‌بینی‌های میان‌مدت هواشناسی است که با ترکیب مشاهدات و مدل‌های عددی، داده‌های ساعتی متغیرهای جوی، سطحی و اقیانوسی را از سال ۱۹۴۰ تاکنون با وضوح مکانی حدود ۳۱ کیلومتر ارائه می‌دهد. این پایگاه به دلیل پوشش زمانی طولانی و سازگاری داخلی بالا، در تحلیل روندهای بلندمدت اقلیمی و پرکردن خلأهای داده ایستگاهی کاربرد گسترده‌ای دارد (Hersbach et al., 2020).

CMIP6 ششمین دوره پروژه تطبیق مدل‌های اقلیمی جفت‌شده است که خروجی ده‌ها مدل گردش عمومی جو-اقیانوس را تحت سناریوهای مختلف انتشار گازهای گلخانه‌ای (مسیرهای اجتماعی-اقتصادی مشترک) گردآوری می‌کند. این پایگاه اساس اصلی مطالعات پیش‌بینی بلندمدت تغییر اقلیم و تحلیل سناریویی است (Eyring et al., 2016). **HIRPS** مجموعه داده بارش ترکیبی است که داده‌های ماهواره‌ای و مشاهدات زمینی را تلفیق کرده و برآورد بارش روزانه با وضوح مکانی حدود ۵ کیلومتر برای مناطق خشک و نیمه‌خشک ارائه می‌دهد؛ به همین دلیل در مطالعات خشکسالی مناطق کم‌داده کاربرد ویژه‌ای دارد (Funk et al., 2015).

CRU¹ پایگاه داده شبکه‌ای ماهانه دانشگاه ایست انگلیا است که متغیرهایی نظیر دما، بارش و تبخیر-تعرق را بر پایه

مشاهدات ایستگاهی درون‌یابی شده ارائه می‌دهد و در تحلیل روندهای اقلیمی تاریخی به‌طور گسترده استفاده می‌شود (Harris et al., 2020).

MODIS سنجنده نصب‌شده بر ماهواره‌های Terra و Aqua ناسا است که تصاویر روزانه با وضوح مکانی ۲۵۰ تا ۱۰۰۰ متر برای پایش پوشش گیاهی، دمای سطح زمین و شاخص‌های خشکی ارائه می‌دهد و یکی از پرکاربردترین منابع سنجش از دور در پایش خشکسالی است (Justice et al., 2002).

Sentinel مجموعه ماهواره‌های آژانس فضایی اروپا است که با وضوح مکانی بالا (تا ۱۰ متر) و دوره بازگشت کوتاه، داده‌های اپتیک و راداری برای پایش دقیق پوشش گیاهی، رطوبت خاک و تغییرات کاربری اراضی فراهم می‌کند (Drusch et al., 2012).

Landsat طولانی‌ترین برنامه مشاهده مستمر زمین از سال ۱۹۷۲ است که با وضوح مکانی ۳۰ متر، امکان تحلیل روندهای بلندمدت تغییرات پوشش زمین و شاخص‌های پوشش گیاهی را فراهم می‌سازد (Wulder et al., 2012).

GPM² مأموریت مشترک ناسا و جاکسا برای برآورد بارش جهانی با تفکیک زمانی نیم‌ساعته است که جانشین مأموریت **TRMM** شده و در پایش بلادرنگ بارش و توسعه سامانه‌های هشدار زود هنگام خشکسالی کاربرد دارد (Hou et al., 2014).

GLDAS³ سامانه جذب داده زمینی است که با تلفیق مشاهدات ماهواره‌ای و زمینی در مدل‌های سطح زمین، برآوردهایی از رطوبت خاک، تبخیر-تعرق و جریان سطحی با وضوح مکانی و زمانی مختلف ارائه می‌دهد و در مطالعات هیدرولوژیک خشکسالی نقش مهمی دارد (Rodell et al., 2004).

³ Global Land Data Assimilation System

¹ Climatic Research Unit

² Global Precipitation Measurement

جدول ۳. مقایسه پایگاه‌های داده اقلیمی پرکاربرد در مطالعات خشکسالی و تغییر اقلیم

پایگاه داده	نوع داده	وضوح مکانی تقریبی	وضوح زمانی	حوزه کاربرد اصلی
ERA5	بازتحلیل جوی	~۳۱ کیلومتر	ساعتی	تحلیل روند بلندمدت، پرکردن خلأ داده
CMIP6	خروجی مدل اقلیمی	متغیر بر اساس مدل	ماهانه تا روزانه	سناریوهای آینده تغییر اقلیم
CHIRPS	بارش ترکیبی (ماهواره+زمینی)	~۵ کیلومتر	روزانه	خشکسالی در مناطق کم‌داده
CRU	شبکه‌ای درونیابی شده	~۰/۵ درجه	ماهانه	روندهای اقلیمی تاریخی
MODIS	سنجش از دور اپتیک	۲۵۰ تا ۱۰۰۰ متر	روزانه	پوشش گیاهی، دمای سطح زمین
Sentinel	سنجش از دور اپتیک/راداری	تا ۱۰ متر	۵ تا ۱۰ روز	رطوبت خاک، کاربری اراضی با تفکیک بالا
Landsat	سنجش از دور اپتیک	۳۰ متر	۱۶ روز	روند بلندمدت تغییرات پوشش زمین
GPM	برآورد بارش ماهواره‌ای	~۱۰ کیلومتر		پایش بلادرنگ بارش، هشدار زود هنگام
GLDAS	جذب داده زمین-اتمسفر	~۰.۲۵ تا ۱ درجه	سه ساعته تا ماهانه	رطوبت خاک، هیدرولوژی خشکسالی

مدیریت خشکسالی تبدیل شوند (Balti et al., 2020)؛
(Huntingford et al., 2019).

پایش خشکسالی مبتنی بر کلان‌داده

یکی از مهم‌ترین ظرفیت‌های کلان‌داده‌های محیطی در مطالعات خشکسالی، فراهم ساختن تصویری جامع، چندمقیاسی و پویا از وضعیت سامانه‌های اقلیمی و هیدرولوژیکی است. این داده‌ها از منابع متنوعی شامل ایستگاه‌های هواشناسی، شبکه‌های پایش زمینی، حسگرهای محیطی، سامانه‌های سنجش از دور و مدل‌های اقلیمی تولید می‌شوند. پایش مستمر متغیرهایی نظیر بارش، دما، رطوبت خاک، تبخیر و تعرق، پوشش گیاهی و جریان‌های سطحی، امکان شناسایی روندهای بلندمدت، ناهنجاری‌های اقلیمی و نشانه‌های اولیه بروز خشکسالی را فراهم می‌سازد (Purnomo and Redha, 2025).

در سال‌های اخیر، فناوری‌های مشاهده زمین نقش مهمی در توسعه سامانه‌های پایش خشکسالی ایفا کرده‌اند (Connors et al., 2025). تصاویر ماهواره‌ای و داده‌های سنجش از دور امکان پایش مستمر وضعیت پوشش گیاهی، شاخص‌های خشکی سطح زمین، رطوبت خاک و تغییرات منابع آب را در مقیاس‌های محلی تا جهانی فراهم کرده‌اند؛ قابلیت‌هایی که به‌ویژه

جدول ۳ ویژگی‌های اصلی این پایگاه‌ها را به‌صورت مقایسه‌ای خلاصه می‌کند. با وجود ارزش بالای این پایگاه‌ها، تفاوت در وضوح مکانی-زمانی، روش تولید و کالیبراسیون آن‌ها موجب می‌شود انتخاب و تلفیق منابع داده به یکی از تصمیم‌های روش‌شناختی مهم در طراحی مدل‌های هوش مصنوعی برای پایش خشکسالی تبدیل شود — موضوعی که در بخش «چالش‌های داده‌ای» به تفصیل بررسی خواهد شد.

کاربردهای کلان‌داده و هوش مصنوعی در پایش، مدل‌سازی و مدیریت ریسک خشکسالی

خشکسالی یکی از پیچیده‌ترین و پرهزینه‌ترین مخاطرات اقلیمی است که به دلیل ماهیت تدریجی، گستره مکانی وسیع و تأثیرات چندبعدی آن بر منابع آب، کشاورزی، اکوسیستم‌ها و جوامع انسانی، پایش، پیش‌بینی و مدیریت مؤثر آن اهمیت ویژه‌ای دارد (Fleming-Muñoz et al., 2023). خشکسالی و سایر پدیده‌های مرتبط با تغییر اقلیم حاصل برهم‌کنش پیچیده عوامل جوی، هیدرولوژیکی، زیستی و انسانی هستند (AghaKouchak et al., 2021) و ماهیت غیرخطی این فرایندها موجب شده است که کلان‌داده و هوش مصنوعی به ابزارهای کلیدی در سه گام به‌هم‌پیوسته شناسایی، ارزیابی و

بلندمدت اقلیمی و ارزیابی اثرات تغییر اقلیم بر منابع آب از جمله کاربردهای مهم رویکردهای داده‌محور در این حوزه محسوب می‌شوند.

مدیریت ریسک خشکسالی و پشتیبانی از تصمیم‌گیری

از منظر مدیریتی، تلفیق کلان داده‌ها با روش‌های هوش مصنوعی زمینه توسعه سامانه‌های پشتیبان تصمیم‌گیری را فراهم کرده است. این سامانه‌ها با تلفیق داده‌های اقلیمی، هیدرولوژیکی، کشاورزی و اقتصادی می‌توانند مناطق آسیب‌پذیر را شناسایی کرده، سناریوهای مختلف خشکسالی را ارزیابی کنند و راهکارهای مناسب برای تخصیص منابع آب، مدیریت کشاورزی و کاهش خسارات ناشی از خشکسالی را پیشنهاد دهند. در چنین رویکردی، هدف صرفاً پیش‌بینی وقوع خشکسالی نیست، بلکه کاهش آسیب‌پذیری و افزایش تاب‌آوری سامانه‌های انسانی و طبیعی در برابر پیامدهای آن نیز مدنظر قرار می‌گیرد.

در این میان، بهینه‌سازی یکی از مهم‌ترین ابعاد کاربرد هوش مصنوعی در مدیریت منابع طبیعی به شمار می‌رود. توسعه مدل‌های بهینه‌سازی مبتنی بر داده می‌تواند به تخصیص کارآمد منابع آب، بهبود بهره‌وری مصرف در بخش کشاورزی، کاهش فشار بر اکوسیستم‌ها و ارتقای سازگاری با شرایط اقلیمی آینده کمک کند. به همین دلیل، رویکردهای داده‌محور از مرحله پایش و پیش‌بینی فراتر رفته و به ابزاری راهبردی برای مدیریت ریسک خشکسالی و تحقق اهداف توسعه پایدار تبدیل شده‌اند.

بررسی مطالعات انجام‌شده نشان می‌دهد که اگرچه پیشرفت‌های چشمگیری در زمینه مدل‌سازی و پیش‌بینی هوشمند خشکسالی حاصل شده است، اما چالش‌هایی نظیر عدم قطعیت داده‌های اقلیمی، ناهمگونی منابع اطلاعاتی، محدودیت تفسیرپذیری برخی مدل‌های یادگیری عمیق و کمبود چارچوب‌های استاندارد اعتبارسنجی همچنان پابرجاست. رفع این چالش‌ها می‌تواند نقش مهمی در توسعه سامانه‌های پیش‌بینی قابل اعتمادتر و افزایش اثربخشی تصمیم‌گیری‌های مرتبط با مدیریت خشکسالی و تغییر اقلیم داشته باشد.

در مناطق دارای شبکه‌های محدود پایش زمینی اهمیت زیادی دارد و موجب بهبود ارزیابی شدت، گستره و تداوم خشکسالی شده است (Jiao et al., 2021).

مطابق گزارش پرنومو و ردها (Purnomo and Redha, 2025)، داده‌های مورد استفاده در مطالعات اقلیمی و خشکسالی عموماً از چهار منبع اصلی — داده‌های میدانی، داده‌های سنجش از دور، خروجی مدل‌های عددی و داده‌های دیرینه‌اقلیمی — تأمین می‌شوند. تلفیق این منابع امکان ارائه تصویری جامع‌تر از شرایط گذشته، وضعیت کنونی و روندهای آینده را فراهم می‌سازد. همچنین ژانگ و همکاران (Zhang et al., 2026) بر اهمیت یکپارچه‌سازی داده‌های چندمنبعی در مطالعات تغییر اقلیم و خشکسالی تأکید کرده‌اند. مطالعه سان و همکاران (Sun et al., 2018) نیز نشان می‌دهد که داده‌های بارش حاصل از منابع مختلف، ظرفیت ارزشمندی برای تحلیل چرخه هیدرولوژیکی و ارزیابی کمبود منابع آب فراهم می‌کنند.

مدل‌سازی و پیش‌بینی خشکسالی با هوش مصنوعی

پیچیدگی روابط میان متغیرهای اقلیمی، هیدرولوژیکی و محیطی موجب شده است که روش‌های سنتی پیش‌بینی در بسیاری از موارد با محدودیت مواجه باشند. در مقابل، الگوریتم‌های یادگیری ماشین و یادگیری عمیق قادرند روابط غیرخطی و الگوهای پنهان موجود در داده‌های اقلیمی را شناسایی کرده و دقت پیش‌بینی شاخص‌های خشکسالی را افزایش دهند. ترکیب داده‌های بارش، دما، رطوبت خاک، شاخص‌های پوشش گیاهی و خروجی مدل‌های اقلیمی، امکان توسعه مدل‌های پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی را فراهم ساخته است.

بررسی مطالعات نشان می‌دهد که مدل‌های مبتنی بر یادگیری عمیق در تحلیل داده‌های چندمنبعی عملکرد بهتری نسبت به روش‌های آماری سنتی داشته‌اند، هرچند وابستگی شدید آن‌ها به حجم داده و توان پردازشی بالا همچنان از محدودیت‌های اصلی محسوب می‌شود. علاوه بر افزایش دقت پیش‌بینی، هوش مصنوعی نقش مهمی در درک بهتر رفتار سامانه‌های اقلیمی نیز ایفا می‌کند: تحلیل الگوهای مکانی-زمانی خشکسالی، شناسایی مناطق آسیب‌پذیر، بررسی روندهای

زیرساخت‌ها و پلتفرم‌های تخصصی پردازش کلان‌داده اقلیمی

فراتر از زیرساخت‌های عمومی رایانش ابری و پردازش توزیع‌شده که در بخش مبانی نظری معرفی شدند، در سال‌های اخیر پلتفرم‌های تخصصی متعددی برای پردازش و تحلیل داده‌های اقلیمی و محیط‌زیستی توسعه یافته‌اند که نقش مهمی در عملیاتی‌سازی تحلیل‌های کلان‌داده در حوزه خشکسالی و تغییر اقلیم ایفا می‌کنند. در مطالعات محیط‌زیستی، سامانه‌های مبتنی بر وب و پلتفرم‌های داده‌محور توسعه چشمگیری یافته‌اند. برای نمونه، سامانه EnviroAtlas با تلفیق داده‌های محیطی، اقتصادی و جمعیتی، امکان تحلیل یکپارچه ابعاد مختلف پایداری را فراهم می‌سازد (Pickard et al., 2015). چنین پلتفرم‌هایی می‌توانند در شناسایی مناطق آسیب‌پذیر در برابر خشکسالی، تحلیل اثرات تغییر اقلیم و پشتیبانی از تصمیم‌گیری‌های مدیریتی نقش مؤثری ایفا کنند.

در حوزه مدیریت و تحلیل داده‌های اقلیمی در مقیاس بزرگ، سامانه‌هایی نظیر MERRA با هدف مدیریت و تحلیل حجم عظیمی از داده‌های اقلیمی توسعه یافته‌اند و بستر مناسبی برای پژوهش‌های مرتبط با تغییر اقلیم و خشکسالی فراهم می‌کنند (Wang et al., 2025). همچنین پلتفرم‌هایی مانند ClimateSpark با بهره‌گیری از معماری‌های محاسبات توزیع‌شده اختصاصی داده‌های اقلیمی، کارایی پردازش این داده‌ها را به میزان قابل توجهی افزایش داده‌اند (Hu et al., 2018). استفاده از رایانش ابری، پردازش بلادرنگ و پردازش درون‌حافظه‌ای در چنین پلتفرم‌هایی، امکان تحلیل سریع و مقیاس‌پذیر داده‌های اقلیمی حجیم را فراهم کرده است (Wu et al., 2024).

در کنار توسعه این زیرساخت‌ها، پیشرفت الگوریتم‌های تحلیلی نیز سهم مهمی در ارتقای مطالعات خشکسالی داشته است. الگوریتم‌های تشخیص تغییرات اقلیمی و روش‌های داده‌کاوی پیشرفته، امکان تحلیل دقیق‌تر روندهای بلندمدت اقلیمی و ارزیابی اثرات تغییر اقلیم بر منابع آب و اکوسیستم‌ها را فراهم ساخته‌اند (Manogaran and Lopez, 2018). افزون بر این، تلفیق داده‌های اقلیمی با داده‌های اجتماعی،

اقتصادی و سلامت — همان‌گونه که در پلتفرم‌هایی نظیر EnviroAtlas مشاهده می‌شود — زمینه بررسی جامع‌تر پیامدهای خشکسالی و تغییر اقلیم را فراهم کرده و به توسعه رویکردهای یکپارچه مدیریت ریسک کمک کرده است. در مجموع، همگرایی این پلتفرم‌های تخصصی با زیرساخت‌های عمومی کلان‌داده (معرفی‌شده در بخش مبانی نظری) و الگوریتم‌های هوش مصنوعی (معرفی‌شده در جدول ۲)، بستری قدرتمند برای پایش، پیش‌بینی و مدیریت خشکسالی فراهم کرده است. انتظار می‌رود توسعه این فناوری‌ها در سال‌های آینده نقش مهمی در افزایش دقت پیش‌بینی‌ها، بهبود مدیریت منابع آب و ارتقای تاب‌آوری جوامع در برابر پیامدهای تغییر اقلیم ایفا کند.

کاربردهای کلان‌داده و هوش مصنوعی در تحلیل و پیش‌بینی تغییر اقلیم

پایش تغییرات اقلیمی مبتنی بر داده‌های چندمنبعی

پایش تغییرات اقلیمی در دهه‌های اخیر با گذار از داده‌های ایستگاهی محدود به رویکردهای چندمنبعی و مبتنی بر کلان‌داده، دچار تحول بنیادین شده است. در این رویکرد، ترکیب داده‌های سنجنش‌ازدور، مشاهدات زمینی و محصولات بازتحلیل اقلیمی، امکان پایش پیوسته و چندمقیاسی متغیرهای کلیدی اقلیم نظیر دما، بارش، تبخیر-تعرق و رطوبت خاک را فراهم می‌سازد (Hersbach et al., 2020). این هم‌گرایی داده‌ای به‌ویژه در مناطق خشک و نیمه‌خشک که با کمبود ایستگاه‌های هواشناسی و ناهمگنی شدید مکانی مواجه هستند، نقش تعیین‌کننده‌ای در بهبود دقت پایش و کاهش عدم قطعیت دارد (Shukla and Wood, 2008).

داده‌های سنجنش‌ازدور ماهواره‌ای نظیر Landsat، MODIS و Sentinel با فراهم‌سازی اطلاعات پیوسته زمانی-مکانی، امکان رصد تغییرات پوشش گیاهی، دمای سطح زمین و شاخص‌های مرتبط با خشکسالی را فراهم می‌کنند (AghaKouchak et al., 2021). در کنار آن، داده‌های بازتحلیل مانند ERA5 با ترکیب مشاهدات و مدل‌های عددی، خلأهای مکانی و زمانی داده‌های ایستگاهی را تا حد زیادی جبران می‌کنند. تلفیق این منابع داده‌ای، از طریق

چندمنبعی و ناهمگن را فراهم کرده است؛ به گونه‌ای که داده‌های سنجش‌ازدور، داده‌های ایستگاهی و محصولات بازتحلیل می‌توانند به صورت هم‌زمان در مدل وارد شوند. این ویژگی موجب افزایش توان مدل‌ها در شناسایی روابط پیچیده بین عوامل اقلیمی و بهبود عملکرد پیش‌بینی در مقیاس‌های مکانی و زمانی مختلف شده است (Brust et al., 2021).

در حوزه خشکسالی، مدل‌های یادگیری ماشین علاوه بر پیش‌بینی متغیرهای هواشناختی، در برآورد شاخص‌هایی نظیر SPI، SPEI و PDSI نیز به کار گرفته شده‌اند و توانسته‌اند تغییرات شدت، تداوم و فراوانی خشکسالی را با دقت بالاتری نسبت به روش‌های سنتی شبیه‌سازی کنند (Karbasi et al., 2024). همچنین ترکیب این مدل‌ها با تکنیک‌های یادگیری عمیق و روش‌های بهینه‌سازی، زمینه توسعه مدل‌های هیبریدی را فراهم کرده که در آن‌ها قابلیت تبیین فیزیکی و دقت آماری به طور هم‌زمان تقویت می‌شود (Lotfifard et al., 2022).

در مجموع، رویکردهای مبتنی بر یادگیری ماشین با ارائه چارچوبی غیرخطی و داده‌محور، نقش مهمی در ارتقای قابلیت پیش‌بینی تغییرات اقلیمی و بهبود سامانه‌های پایش و مدیریت ریسک خشکسالی ایفا کرده‌اند؛ با این حال، چالش‌هایی نظیر بیش‌برازش، عدم تفسیرپذیری مدل‌ها و وابستگی به کیفیت داده همچنان از محدودیت‌های اصلی این رویکردها محسوب می‌شود (Shakeri et al., 2023).

تحلیل سناریوهای تغییر اقلیم و ارزیابی اثرات

تحلیل سناریوهای تغییر اقلیم یکی از ارکان اساسی در مطالعات نوین اقلیم‌شناسی کاربردی و مدیریت ریسک خشکسالی محسوب می‌شود که با هدف کاهش عدم قطعیت در پیش‌بینی‌های بلندمدت و بهبود تصمیم‌سازی‌های سازگاری توسعه یافته است. در این چارچوب، سناریوهای اقلیمی نظیر مسیرهای تمرکز نمایندگی و مسیرهای اجتماعی-اقتصادی مشترک به عنوان ابزارهای استاندارد برای شبیه‌سازی شرایط محتمل آینده اقلیم، تحت اثر ترکیبی عوامل طبیعی و انسانی به کار گرفته می‌شوند (Shiru et al., 2020). این سناریوها امکان بررسی طیفی از وضعیت‌های محتمل تغییرات دما، بارش و سایر متغیرهای کلیدی اقلیم را در مقیاس‌های

تکنیک‌های هم‌جوشی داده و روش‌های یادگیری ماشین، منجر به تولید محصولات اقلیمی با وضوح بالاتر و قابلیت اعتماد بیشتر می‌شود (Soci et al., 2024).

در این میان، کلان داده‌های اقلیمی نه تنها امکان پایش تغییرات تدریجی متغیرهای هواشناختی را فراهم می‌سازند، بلکه شناسایی الگوهای غیرخطی و ناگهانی مانند وقوع خشکسالی‌های شدید یا موج‌های گرمایی را نیز تسهیل می‌کنند. به کارگیری الگوریتم‌های هوش مصنوعی در پردازش این داده‌های چندمنبعی، نقش مهمی در استخراج شاخص‌های ترکیبی خشکسالی و بهبود سیستم‌های پایش بلادرنگ ایفا کرده است. در مجموع، رویکرد پایش چندمنبعی مبتنی بر کلان داده، زمینه را برای گذار از پایش ایستا و گذشته‌نگر به پایش پویا، پیش‌نگر و تصمیم‌یار فراهم ساخته است (Ahmed Osman et al., 2025).

مدل‌سازی غیرخطی و پیش‌بینی تغییرات اقلیمی با یادگیری

ماشین

مدل‌سازی تغییرات اقلیمی در سال‌های اخیر از چارچوب‌های خطی و ایستا به سمت رویکردهای مبتنی بر یادگیری ماشین و مدل‌سازی غیرخطی حرکت کرده است. این گذار عمدتاً ناشی از ماهیت پیچیده، چندمتغیره و غیرایستای سیستم اقلیم است که در آن روابط بین متغیرهایی نظیر دما، بارش، تبخیر-تعرق، رطوبت خاک و شاخص‌های خشکسالی به صورت خطی قابل تبیین نیستند (Dikshit et al., 2021).

در میان روش‌های معرفی شده در جدول ۲، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی عمیق و به ویژه مدل‌های حافظه بلندمدت کوتاه مدت به دلیل توانایی در یادگیری وابستگی‌های زمانی بلندمدت، کاربرد گسترده‌ای در پیش‌بینی متغیرهای اقلیمی و شاخص‌های خشکسالی پیدا کرده‌اند (Danandeh et al., 2023). این مدل‌ها قادرند رفتار غیرخطی سیستم اقلیم را از طریق داده‌های تاریخی استخراج کرده و روندهای آتی را با دقت بالاتری نسبت به روش‌های آماری کلاسیک مانند رگرسیون خطی یا مدل‌های ARIMA برآورد نمایند.

علاوه بر این، استفاده از الگوریتم‌های یادگیری ماشین در ترکیب با داده‌های کلان اقلیمی، امکان ادغام متغیرهای

زمانی آینده فراهم می‌سازند و به‌ویژه در مناطق خشک و نیمه‌خشک، نقش مهمی در ارزیابی حساسیت منابع آب و اکوسیستم‌ها نسبت به تغییر اقلیم دارند. ترکیب خروجی مدل‌های گردش عمومی جو و مدل‌های منطقه‌ای اقلیم با تکنیک‌های کاهش مقیاس آماری و دینامیکی، امکان افزایش دقت مکانی و کاربردی‌سازی نتایج سناریویی را در مطالعات اثرات فراهم کرده است (Granata and Di Nunno, 2025).

در این میان، ارزیابی اثرات تغییر اقلیم بر مؤلفه‌های هیدرولوژیک و خشکسالی — از جمله تغییر در شدت و فراوانی خشکسالی‌های هواشناسی، کشاورزی و هیدرولوژیک — از اهمیت ویژه‌ای برخوردار است. به‌کارگیری روش‌های داده‌محور و مبتنی بر هوش مصنوعی در کنار مدل‌های فیزیکی، امکان تحلیل حساسیت سیستم‌های طبیعی نسبت به تغییرات سناریویی را تقویت کرده و به شناسایی نقاط بحرانی و آستانه‌های ریسک کمک می‌کند (Reichstein et al., 2019). از منظر کاربردی، نتایج حاصل از تحلیل سناریوهای اقلیمی به‌عنوان ورودی کلیدی در برنامه‌ریزی‌های مدیریت منابع آب، طراحی راهبردهای سازگاری اقلیمی و تدوین سیاست‌های کاهش آسیب‌پذیری مورد استفاده قرار می‌گیرند. رویکردهای نوین مبتنی بر کلان‌داده و یادگیری ماشین با تسهیل پردازش حجم وسیعی از خروجی مدل‌های اقلیمی، امکان تولید نقشه‌های ریسک و ارزیابی‌های مکانی-زمانی دقیق‌تر را فراهم ساخته‌اند (Addor et al., 2020). با این حال، عدم قطعیت ناشی از تفاوت بین مدل‌های اقلیمی و فرضیات سناریویی همچنان یکی از چالش‌های اساسی در کاربرد عملی این رویکردها به‌شمار می‌رود.

سامانه‌های تصمیم‌یار اقلیمی مبتنی بر کلان‌داده

سامانه‌های تصمیم‌یار اقلیمی مبتنی بر کلان‌داده، یکی از مهم‌ترین دستاوردهای همگرایی علم داده، هوش مصنوعی و علوم اقلیم محسوب می‌شوند که با هدف تبدیل داده‌های حجیم و پیچیده اقلیمی به اطلاعات قابل‌استفاده برای تصمیم‌گیری توسعه یافته‌اند (Oladeji and Mousavi, 2023). این سامانه‌ها با یکپارچه‌سازی داده‌های

سنجش‌ازدور، مشاهدات زمینی، محصولات بازتحلیل و خروجی مدل‌های اقلیمی، بستری برای پیش، تحلیل و پیش‌بینی بلندمدت وضعیت اقلیم و مخاطرات مرتبط از جمله خشکسالی فراهم می‌سازند (Rhee and Im, 2017).

در ساختار این سامانه‌ها، معماری داده‌محور نقش محوری دارد؛ داده‌های ناهمگن پس از پیش‌پردازش، استانداردسازی و تلفیق، وارد لایه‌های تحلیلی مبتنی بر الگوریتم‌های یادگیری ماشین می‌شوند و امکان تولید شاخص‌های ترکیبی خشکسالی، نقشه‌های خطرپذیری و پیش‌بینی‌های کوتاه‌مدت تا فصلی را با دقت بالاتر نسبت به روش‌های سنتی فراهم می‌کنند. یکی از کارکردهای کلیدی این سامانه‌ها، توسعه سیستم‌های هشدار زودهنگام خشکسالی است که با پیش‌مستمر متغیرهای اقلیمی و هیدرولوژیکی، وقوع شرایط بحرانی را شناسایی و اطلاع‌رسانی می‌نماید (Sutanto et al., 2024)؛ قابلیت‌هایی که برای مناطق آسیب‌پذیر در برابر خشکسالی‌های شدید، نقش مهمی در کاهش خسارات اقتصادی، اجتماعی و زیست‌محیطی دارد.

علاوه بر این، سامانه‌های تصمیم‌یار اقلیمی با ارائه داشبوردهای تحلیلی و ابزارهای مصورسازی پیشرفته، امکان دسترسی سریع سیاست‌گذاران و مدیران منابع آب به اطلاعات کلیدی را فراهم کرده و فرآیند تصمیم‌گیری را از حالت واکنشی به حالت پیش‌نگر و سازگار با تغییر اقلیم ارتقا می‌دهند (Liu et al., 2026). با این حال، چالش‌هایی نظیر یکپارچه‌سازی داده‌های ناهمگن، نیاز به زیرساخت‌های محاسباتی پیشرفته و مسئله اعتمادپذیری مدل‌های هوشمند همچنان از موانع توسعه گسترده این سامانه‌ها به‌شمار می‌رود.

ارتباط میان کاربردهای خشکسالی و تغییر اقلیم

اگرچه در بخش‌های پیشین، کاربردهای هوش مصنوعی و کلان‌داده در پیش و مدیریت خشکسالی از یک‌سو، و در تحلیل و پیش‌بینی تغییر اقلیم از سوی دیگر، به‌صورت مستقل بررسی شدند، این دو حوزه در عمل ارتباطی تنگاتنگ و دوسویه دارند. خشکسالی به‌عنوان یکی از بارزترین تجلی‌های اقلیمی تغییر اقلیم، هم پیامد روندهای بلندمدت اقلیمی است و هم خود به‌عنوان متغیری کلیدی در سناریوهای پیش‌بینی تغییر اقلیم مورد استفاده قرار می‌گیرد. از منظر

به‌منظور ارائه تصویری فشرده و قابل‌مقایسه از نحوه به‌کارگیری هوش مصنوعی در مطالعات کاربردی خشکسالی و تغییر اقلیم، جدول ۴ تعدادی مطالعه را که هر کدام یک الگوریتم هوش مصنوعی مشخص را بر داده‌های واقعی اقلیمی یا هیدرولوژیکی به‌کار برده و نتایج را با معیارهای کمی ارزیابی کرده‌اند، از میان مطالعات مرورشده در بخش‌های پیشین مقاله انتخاب و مقایسه می‌کند. این مطالعات به‌گونه‌ای انتخاب شده‌اند که تنوعی از الگوریتم‌ها (از یادگیری ماشین کلاسیک تا مدل‌های ترکیبی یادگیری عمیق)، انواع داده (سری زمانی ایستگاهی، سنجش‌ازدور، بازتحلیل) و کاربردها (پیش‌بینی خشکسالی هواشناسی، جریان رودخانه، ارزیابی کیفیت داده اقلیمی) را نمایندگی کنند.

داده‌ای و روش‌شناختی، تفاوت اصلی این دو حوزه در مقیاس زمانی (پیش‌بینی خشکسالی عمدتاً کوتاه‌مدت تا فصلی است، در حالی که تحلیل تغییر اقلیم افق زمانی چنددهه‌ساله دارد) و معیارهای ارزیابی (شاخص‌هایی مانند SPI و SPEI برای خشکسالی در برابر سناریوهای انتشار و آنومالی‌های دمایی برای تغییر اقلیم) نهفته است. با این حال، از نظر زیرساخت داده‌ای (پایگاه‌هایی نظیر ERA5 و CHIRPS) و ابزارهای الگوریتمی (یادگیری عمیق، مدل‌های ترکیبی)، هر دو حوزه بر بستری مشترک استوارند؛ همین اشتراک بستری، مبنای اصلی چارچوب تحلیلی یکپارچه‌ای است که در این مقاله دنبال می‌شود.

مقایسه تطبیقی مطالعات پیشین

جدول ۴. مقایسه مطالعات کاربردی پیشین در به‌کارگیری هوش مصنوعی برای پایش و پیش‌بینی خشکسالی و تغییر اقلیم

نویسنده (سال) نوع داده	روش/الگوریتم	هدف	معیار ارزیابی	قوت / محدودیت
Danandeh et al. (2023) سری زمانی بارش، SPI	CNN-LSTM	پیش‌بینی خشکسالی هواشناسی و هشدار زودهنگام	RMSE, MAE, NSE, R ² , MAPE	+ یادگیری وابستگی زمانی بلندمدت / - نیاز داده زیاد، تفسیرپذیری کم
Karbasi et al. SPEI-12 (2024) سری زمانی	TVF-EMD + LASSO + Ensemble Deep RVFL	پیش‌بینی چندگام خشکسالی	RMSE, R	+ ترکیب تجزیه سیگنال و پیچیدگی، محدودیت تعمیم مکانی
Lotfifard et al. (2022) بارش و دمای ماهانه (ایران)	Random Forest (تأخیر ۱-۱۲ ماهه)	مقایسه SPI و SPEI برای پیش‌بینی خشکسالی بیش/کم‌برآورد	همبستگی، Accuracy، خطای	+ کاربرد مستقیم پایش/پیش‌بینی / - متغیرهای محدود، بدون سنجش‌ازدور
Brust et al. (2021) بارش، دما، رطوبت خاک ماهواره‌ای	RNN (DroughtCast)	پیش‌بینی USDN تا ۱۲ هفته آینده	MSE، خطای طبقه‌بندی	+ هشدار زودهنگام مقیاس وسیع / - محدود به آمریکا، مدل جعبه‌سیاه
Dikshit et al. CRU (2021) سری زمانی	LSTM	پیش‌بینی کوتاه‌مدت SPEI	R ² , RMSE, MAE, ROC-AUC	+ بررسی هم‌زمان شدت/طبقه/پراکنش مکانی / - محدود به NSW استرالیا
Xu et al. (2025) جریان رودخانه، دما	DL + Data Augmentation + XAJ	بهبود پیش‌بینی جریان با افزایش داده	KGE, NSE, RMSE, MAE	+ ترکیب داده‌محور و فیزیکی / - محدود به یک حوضه

نویسنده (سال) نوع داده	روش/الگوریتم	هدف	معیار ارزیابی	قوت / محدودیت
Soci et al. بازتحلیل (2024) جوی/سطحی	4D-Var) ERA5 (توسعه یافته)	معرفی و ارزیابی کیفیت ERA5 تا ۱۹۶۰	مقایسه با مشاهدات، سازگاری زمانی	+ پوشش زمانی/مکانی طولانی / — عدم قطعیت در دوره‌های پیش‌ماهوره‌ای

همان‌گونه که جدول فوق نشان می‌دهد، این مطالعات با مرورهای کتاب‌سنجی و انتقادی متعددی که در ادبیات اخیر منتشر شده‌اند تکمیل می‌شوند. بررسی هم‌زمان جدول ۴ و این مرورهای مکمل نشان می‌دهد که اگرچه هر یک از این مطالعات به یک روش، منطقه جغرافیایی یا حوزه کاربردی خاص محدود بوده‌اند، ارتباط میان زیرساخت کلان‌داده، الگوریتم هوش مصنوعی و فرآیند تصمیم‌سازی در مدیریت پایدار منابع طبیعی — که هدف اصلی مقاله حاضر است — در هیچ‌یک از آن‌ها به‌صورت یکپارچه بررسی نشده است.

چالش‌ها، شکاف‌های پژوهشی و مسیرهای آینده

با وجود ظرفیت‌های گسترده‌ای که کلان‌داده و هوش مصنوعی برای پایش خشکسالی و پیش‌بینی تغییرات اقلیمی فراهم کرده‌اند، بهره‌برداری کامل از این ظرفیت‌ها همچنان با چالش‌های متعددی در چهار سطح به‌هم‌پیوسته — داده‌ای، مدل‌سازی، محاسباتی-زیرساختی و نهادی — مواجه است. در ادامه، هر یک از این سطوح به‌طور مجزا بررسی و در پایان، شکاف‌های پژوهشی استخراج‌شده از مرور حاضر به‌صورت تحلیلی ارائه می‌شود.

چالش‌های داده‌ای

با وجود گسترش چشمگیر منابع داده‌ای در علوم اقلیم، یکی از مهم‌ترین موانع در بهره‌برداری مؤثر از کلان‌داده‌ها و هوش مصنوعی در پایش و پیش‌بینی خشکسالی، چالش‌های مرتبط با کیفیت، دسترس‌پذیری و سازگاری داده‌هاست (Naughten et al., 2023). این چالش‌ها به‌ویژه در مناطق خشک و نیمه‌خشک که از نظر شبکه‌های پایش زمینی

محدودیت‌های جدی دارند، نمود بیشتری پیدا می‌کنند (AghaKouchak et al., 2021).

یکی از مهم‌ترین مسائل در این حوزه، ناهمگنی مکانی و زمانی داده‌هاست. داده‌های سنجش‌ازدور، ایستگاهی و بازتحلیل — که در بخش «پایگاه‌های داده اقلیمی پرکاربرد» با جزئیات معرفی شدند — هر یک وضوح مکانی، گام زمانی و ساختار آماری متفاوتی دارند که تلفیق آن‌ها را با پیچیدگی مواجه می‌سازد و در صورت عدم پیش‌پردازش مناسب، می‌تواند به بروز خطاهای سیستماتیک در مدل‌های پیش‌بینی منجر شود (Himeur et al., 2022). چالش دیگر، کمبود داده‌های زمینی با کیفیت بالا و پیوسته زمانی است؛ بسیاری از ایستگاه‌های هواشناسی در مناطق خشک با داده‌های مفقود یا دوره‌های ثبت کوتاه مواجه‌اند، که وابستگی به داده‌های سنجش‌ازدور و در نتیجه عدم قطعیت در برآورد متغیرهای سطحی را افزایش می‌دهد.

علاوه بر این، ناسازگاری بین منابع داده‌ای مختلف — ناشی از تفاوت در روش‌های اندازه‌گیری، کالیبراسیون سنجنده‌ها و الگوریتم‌های پردازش — می‌تواند اختلافات قابل توجهی بین محصولات مختلف اقلیمی ایجاد کند، به‌گونه‌ای که انتخاب منبع داده مناسب خود به یک مسئله پژوهشی مستقل تبدیل شده است (Mankin et al., 2025). وجود نویز و عدم قطعیت ذاتی در این داده‌ها نیز می‌تواند قابلیت تعمیم‌پذیری مدل‌های یادگیری ماشین را کاهش دهد، که نیاز به روش‌های پیش‌پردازش پیشرفته و کنترل کیفیت داده را بیش از پیش آشکار می‌سازد.

چالش‌های مدل‌سازی

فرآیند مدل‌سازی داده‌محور در مطالعات خشکسالی و تغییر اقلیم با مجموعه‌ای از چالش‌های بنیادین مواجه است که ناشی از ماهیت پیچیده، غیرخطی و غیرایستای سامانه اقلیم و محدودیت‌های ذاتی الگوریتم‌های هوش مصنوعی است.

نگهداری آن‌ها هزینه‌بر و پیچیده است (Sedona et al., 2019).

وابستگی به رایانش ابری و زیرساخت‌های توزیع‌شده نیز چالشی دوگانه است: اگرچه پلتفرم‌های ابری پردازش کلان‌داده را تسهیل می‌کنند، مسائل مرتبط با هزینه، محدودیت پهنای باند، امنیت داده‌ها و وابستگی به ارائه‌دهندگان خدمات می‌تواند استفاده پایدار از این فناوری‌ها را محدود کند. علاوه بر این، مدیریت و ذخیره‌سازی حجم عظیم و مداوم‌التولید داده‌های اقلیمی، نیازمند سامانه‌های ذخیره‌سازی مقیاس‌پذیر است که در غیاب آن، اتلاف داده و کاهش کارایی پردازش محتمل خواهد بود. محدودیت دسترسی به نرم‌افزارها و نیروی انسانی متخصص پردازش کلان‌داده نیز از دیگر موانع مهم در بسیاری از مراکز پژوهشی است. در مجموع، بهره‌برداری مؤثر از کلان‌داده و هوش مصنوعی در حوزه اقلیم، صرفاً یک مسئله الگوریتمی نیست، بلکه نیازمند توسعه هم‌زمان زیرساخت‌های سخت‌افزاری، نرم‌افزاری و انسانی است.

چالش‌های نهادی و تصمیم‌سازی

در کنار چالش‌های داده‌ای، مدل‌سازی و زیرساختی، چالش‌های نهادی و مرتبط با فرآیندهای تصمیم‌سازی از موانع بنیادین بهره‌برداری مؤثر از کلان‌داده و هوش مصنوعی در مدیریت خشکسالی و تغییر اقلیم‌اند. این چالش‌ها عمدتاً ناشی از شکاف میان تولید دانش علمی و به‌کارگیری عملی آن در نظام‌های حکمرانی منابع طبیعی است.

نخستین مسئله، فاصله میان جامعه علمی و نهادهای سیاست‌گذار است؛ خروجی مدل‌های پیچیده اقلیمی اغلب به‌صورت مستقیم در تصمیم‌گیری‌های اجرایی استفاده نمی‌شوند یا به‌دلیل پیچیدگی فنی به‌درستی تفسیر نمی‌شوند — همان مسئله‌ای که سامانه‌های تصمیم‌یار اقلیمی تلاش می‌کنند با ارائه داشبوردهای قابل‌فهم پاسخ دهند، هرچند این تلاش‌ها هنوز کاملاً این شکاف را پر نکرده‌اند. دومین مسئله، عدم یکپارچگی نهادی و پراکندگی داده‌ها میان سازمان‌های مختلف (هواشناسی، منابع آب، کشاورزی، محیط‌زیست) است؛ نبود استانداردهای مشترک برای تبادل داده، کارایی

نخستین چالش، بیش‌برازش است: مدل‌ها اغلب عملکرد مطلوبی بر روی داده‌های آموزشی دارند اما در مواجهه با داده‌های جدید یا مناطق اقلیمی متفاوت، دقت آن‌ها به‌طور قابل‌توجهی کاهش می‌یابد — مسئله‌ای که در مطالعات خشکسالی، با توجه به نوسانات شدید زمانی و مکانی این پدیده، اهمیت ویژه‌ای دارد. دومین چالش، عدم تفسیرپذیری مدل‌های پیچیده است؛ این مدل‌ها با وجود دقت پیش‌بینی بالا، ارائه توضیح فیزیکی یا اقلیمی از روابط استخراج‌شده در آن‌ها دشوار است — چالشی که مدل‌های هوش مصنوعی تبیین‌پذیر به‌عنوان راهکار بالقوه آن مطرح شده‌اند.

سومین چالش، نایستایی داده‌های اقلیمی است: تغییرات تدریجی یا ناگهانی در الگوهای اقلیمی تحت تأثیر تغییر اقلیم جهانی باعث می‌شود روابط آماری گذشته لزوماً در آینده پایدار نباشند، که کارایی مدل‌های متکی بر فرض ثبات آماری را کاهش داده و نیاز به مدل‌های تطبیقی و یادگیرنده در زمان واقعی را افزایش می‌دهد. چهارمین چالش، وابستگی شدید به کیفیت و حجم داده‌های آموزشی است؛ در مناطق خشک و کم‌داده، نبود داده‌های کافی و نماینده موجب می‌شود مدل‌ها نتوانند الگوهای واقعی سیستم اقلیم را به‌درستی یاد بگیرند — همان چالشی که مدل‌های فیزیک-آگاه با تلفیق دانش فیزیکی تلاش می‌کنند تا حدی جبران کنند.

در مجموع، این چالش‌ها نشان می‌دهند که دستیابی به پیش‌بینی‌های دقیق و قابل اعتماد، صرفاً با افزایش پیچیدگی الگوریتم‌ها امکان‌پذیر نیست، بلکه نیازمند توجه هم‌زمان به اصول فیزیکی اقلیم، بهبود کیفیت داده‌ها و توسعه روش‌های تفسیرپذیر و مقاوم در برابر تغییرات محیطی است.

چالش‌های محاسباتی و زیرساختی

گسترش کاربرد کلان‌داده و الگوریتم‌های هوش مصنوعی در مطالعات اقلیم و خشکسالی، وابستگی شدیدی به زیرساخت‌های محاسباتی پیشرفته ایجاد کرده که در بسیاری از موارد، به‌ویژه در کشورهای در حال توسعه، به‌طور کامل در دسترس نیست. آموزش و اجرای مدل‌های یادگیری عمیق و پردازش داده‌های سنجش‌ازدور در مقیاس وسیع، نیازمند منابع محاسباتی گسترده — شامل واحدهای پردازش گرافیکی و زیرساخت‌های موازی‌سازی — است که تأمین و

مدل‌های داده‌محور را کاهش داده و موجب تکرار و اتلاف منابع داده‌ای می‌شود.

سومین مسئله، نبود استانداردهای مشخص برای کیفیت، اشتراک‌گذاری و حاکمیت داده است که در غیاب چارچوب‌های حقوقی و فنی مشخص، دسترسی به داده‌های حیاتی را محدود و ناپایدار می‌سازد. چهارمین مسئله، مقاومت نهادی در برابر پذیرش فناوری‌های نوین است که می‌تواند ناشی از عدم آشنایی کافی با قابلیت‌ها و محدودیت‌های این فناوری‌ها یا نبود چارچوب‌های اعتمادسازی و اعتبارسنجی مدل‌ها باشد.

در مجموع، موفقیت در به‌کارگیری کلان‌داده و هوش مصنوعی در مدیریت خشکسالی و تغییر اقلیم صرفاً به پیشرفت‌های فنی وابسته نیست، بلکه نیازمند اصلاح ساختارهای حکمرانی داده، تقویت همکاری‌های بین‌سازمانی و ارتقای تعامل میان دانش علمی و فرآیندهای اجرایی است.

شکاف‌های پژوهشی

بر اساس مرور صورت‌گرفته در این مطالعه، سه شکاف اصلی در ادبیات موجود قابل شناسایی است:

۱. شکاف در قابلیت انتقال مکانی مدل‌ها. بخش عمده مطالعات مرور شده (از جمله موارد ارجاع‌داده‌شده در بخش‌های مدل‌سازی غیرخطی و پیش‌بینی) بر توسعه و بهینه‌سازی الگوریتم‌ها در یک منطقه جغرافیایی مشخص متمرکز بوده‌اند، در حالی که ارزیابی نظام‌مند قابلیت تعمیم این مدل‌ها به مناطق اقلیمی دیگر — به‌ویژه انتقال از مناطق پرداده به مناطق کم‌داده — کمتر مورد توجه قرار گرفته است.
۲. شکاف در پوشش انواع خشکسالی. همان‌گونه که در بخش‌های پیشین مشاهده شد، غالب مطالعات مرور شده بر

جدول ۵. جمع‌بندی یافته‌های اصلی مقاله بر اساس محورهای بررسی‌شده

محور بررسی‌شده	مهم‌ترین دستاورد شناسایی‌شده	مهم‌ترین چالش/شکاف باقی‌مانده
پایش خشکسالی و تلفیق داده‌های چندمنبعی (سنجش‌ازدور، زمینی، بازتحلیل) امکان ناهمگنی مکانی-زمانی داده‌ها و کمبود شبکه‌های تغییر اقلیم	پایش پیوسته و چندمقیاسی را فراهم کرده	پایش زمینی در مناطق خشک
مدل‌سازی و پیش‌بینی	مدل‌های یادگیری عمیق (به‌ویژه LSTM) دقت پیش‌بینی را نسبت به‌باززش، عدم تفسیرپذیری و وابستگی شدید به روش‌های آماری کلاسیک بهبود داده‌اند	به کیفیت داده آموزشی

خشکسالی هواشناسی (مبتنی بر شاخص‌های SPI و SPEI) متمرکز بوده‌اند، در حالی که خشکسالی هیدرولوژیک، اکولوژیک و اجتماعی-اقتصادی — که پیامدهای مدیریتی متفاوتی دارند — کمتر با رویکردهای مبتنی بر هوش مصنوعی بررسی شده‌اند.

۳. شکاف در ارزیابی بلندمدت و استانداردسازی. پژوهش‌های موجود غالباً به ارزیابی کوتاه‌مدت عملکرد مدل‌ها محدود بوده و مطالعات بلندمدت در مقیاس‌های منطقه‌ای و ملی هنوز محدودند. همچنین، کمبود چارچوب‌های استاندارد برای ارزیابی و مقایسه عملکرد مدل‌های هوش مصنوعی مختلف — مسئله‌ای که جدول مقایسه‌ای مطالعات پیشین در این مقاله بخشی از آن را پوشش می‌دهد — یکی دیگر از خلأهای مهم پژوهشی است. این سه شکاف، مستقیماً زمینه‌ساز مسیرهای پژوهشی آینده هستند که در بخش نتیجه‌گیری بدان‌ها پرداخته می‌شود.

نتیجه‌گیری و مسیرهای آینده

جمع‌بندی تحلیلی

تحلیل انجام‌شده در این مقاله نشان می‌دهد که همگرایی کلان‌داده و هوش مصنوعی، ساختار سنتی پایش، پیش‌بینی و مدیریت خشکسالی و تغییر اقلیم را به‌صورت بنیادین دگرگون کرده است؛ تحولی که نه صرفاً در سطح افزایش دقت محاسباتی، بلکه در سطح تغییر پارادایم از رویکردهای ایستا و گذشته‌نگر به سامانه‌های پویا، چندمنبعی و پیش‌نگر قابل مشاهده است. جدول ۳ یافته‌های اصلی هر محور بررسی‌شده در این مقاله را در برابر مهم‌ترین شکاف و چالش باقی‌مانده آن خلاصه می‌کند

محور بررسی شده	مهم‌ترین دستاورد شناسایی شده	مهم‌ترین چالش/شکاف باقی‌مانده
مدیریت ریسک و سامانه‌های تصمیم‌یار اقلیمی امکان‌گذار از مدیریت واکنشی به شکاف ارتباطی میان جامعه علمی و نهادهای تصمیم‌سازی	پیش‌نگر را فراهم کرده‌اند	سیاست‌گذار
زیرساخت و فناوری	پلتفرم‌های تخصصی (نظیر ClimateSpark، MERRA) کارایی وابستگی به منابع محاسباتی پرهزینه، به‌ویژه در پردازش کلان‌داده اقلیمی را افزایش داده‌اند	کشورهای در حال توسعه
قابلیت تعمیم مدل‌ها	مدل‌های ترکیبی (فیزیکی-داده‌محور) قابلیت تعمیم بهتری نسبت به فقدان ارزیابی نظام‌مند قابلیت انتقال مدل‌ها میان مدل‌های صرفاً داده‌محور نشان داده‌اند	مناطق اقلیمی مختلف

همان‌گونه که جدول فوق نشان می‌دهد، در هر محور، پیشرفت فناوریانه با چالشی متناظر همراه بوده است — الگویی که نشان می‌دهد توسعه این حوزه ماهیتی صرفاً فناوریانه ندارد و نیازمند رویکردی میان‌رشته‌ای و نظام‌مند است که هم‌زمان ابعاد داده‌ای، الگوریتمی، زیرساختی و نهادی را در بر گیرد.

چشم‌اندازهای آینده

بر اساس شکاف‌های پژوهشی شناسایی شده در بخش قبل، مسیرهای آینده پژوهش در این حوزه را می‌توان در پنج جهت‌گیری اصلی خلاصه کرد:

توسعه مدل‌های هیبریدی فیزیکی-داده‌محور. ادغام دانش فیزیکی حاکم بر فرآیندهای اقلیمی با ظرفیت یادگیری مدل‌های داده‌محور، می‌تواند ضمن افزایش دقت پیش‌بینی، تا حدی مشکل عدم تفسیرپذیری مدل‌های صرفاً داده‌محور و محدودیت قابلیت تعمیم آن‌ها به مناطق کم‌داده را کاهش دهد. **گسترش هوش مصنوعی قابل توضیح.** توسعه و استانداردسازی روش‌های هوش مصنوعی قابل توضیح، نقش مهمی در پاسخ به شکاف ارتباطی میان جامعه علمی و نهادهای سیاست‌گذار ایفا خواهد کرد و می‌تواند اعتمادپذیری خروجی مدل‌ها را در فرآیندهای تصمیم‌گیری حساس اقلیمی افزایش دهد.

توسعه دوقلوهای دیجیتال اقلیم. شبیه‌سازی پویا و بلادرنگ سیستم‌های اقلیمی و هیدرولوژیکی می‌تواند به‌عنوان زیرساختی پیشرفته برای پیش‌بینی و مدیریت خشکسالی در مقیاس منطقه‌ای عمل کند و پلی میان پایش و مدیریت ریسک ایجاد نماید.

ادغام کلان‌داده با اینترنت اشیا و رایانش لبه‌ای. این ادغام افق جدیدی در پایش بلادرنگ متغیرهای اقلیمی ایجاد می‌کند که می‌تواند به‌ویژه در مناطق با شبکه پایش زمینی محدود — که در بخش چالش‌های داده‌ای به‌عنوان یکی از موانع اصلی شناسایی شد — دقت و سرعت واکنش به مخاطرات اقلیمی را افزایش دهد.

استانداردسازی و توسعه چارچوب‌های ارزیابی مشترک. توسعه زیرساخت‌های داده‌باز، استانداردسازی داده‌های محیطی و طراحی چارچوب‌های ارزیابی مشترک برای مقایسه عملکرد مدل‌های هوش مصنوعی می‌تواند مستقیماً شکاف سوم شناسایی شده در بخش قبل (فقدان استانداردسازی) را پوشش دهد و قابلیت مقایسه و اعتبار نتایج پژوهش‌های آینده را افزایش دهد.

در نهایت، موفقیت این تحولات آینده منوط به هم‌راستایی پیشرفت‌های فناوریانه با اصلاحات نهادی، توسعه زیرساخت‌های داده‌ای و ارتقای تعامل میان علوم اقلیم، علوم داده و سیاست‌گذاری عمومی خواهد بود. در چنین بستری، کلان‌داده و هوش مصنوعی نه تنها ابزار تحلیل، بلکه به‌عنوان زیرساختی راهبردی برای حکمرانی پایدار منابع طبیعی و افزایش تاب‌آوری اقلیمی در مناطق خشک و نیمه‌خشک عمل خواهند کرد.

منابع

1. Addor, N., Do, H. X., Alvarez-Garretón, C., Coxon, G., Fowler, K., & Mendoza, P. A. (2020). Large-sample hydrology: recent progress, guidelines for new datasets and grand challenges. *Hydrological Sciences Journal*, 65(5), 712-725.
doi:10.1080/02626667.2019.1683182

- Colin, O., Fernandez, V., Gascon, F., ... Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36. doi:https://doi.org/10.1016/j.rse.2011.11.026
11. Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geosci. Model Dev.*, 9(5), 1937-1958. doi:10.5194/gmd-9-1937-2016
12. Fleming-Muñoz, D. A., Whitten, S., & Bonnett, G. D. (2023). The economics of drought: A review of impacts and costs. *Australian Journal of Agricultural and Resource Economics*, 67(4), 501-523. doi:https://doi.org/10.1111/1467-8489.12527
13. Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... Michaelsen, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific Data*, 2(1), 150066. doi:10.1038/sdata.2015.66
14. Götz, M., Richerzhagen, M., Bodenstein, C., Cavallaro, G., Glock, P., Riedel, M., & Benediktsson, J. (2015). On Scalable Data Mining Techniques for Earth Science. *Procedia Computer Science*, 51, 2188-2197. doi:10.1016/j.procs.2015.05.494
15. Granata, F., & Di Nunno, F. (2025). Rising threats to groundwater recharge: Adaptive strategies for the Sahel under climate change. *Groundwater for Sustainable Development*, 30, 101468. doi:https://doi.org/10.1016/j.gsd.2025.101468
16. Harris, I., Osborn, T. J., Jones, P., & Lister, D. (2020). Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. *Scientific Data*, 7(1), 109. doi:10.1038/s41597-020-0453-3
17. Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., . . . Thépaut, J.-N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999-2049. doi:https://doi.org/10.1002/qj.3803
18. Himeur, Y., Rimal, B., Tiwary, A., & Amira, A. (2022). Using artificial intelligence and data fusion for
2. AghaKouchak, A., Mirchi, A., Madani, K., Di Baldassarre, G., Nazemi, A., Alborzi, A., ... Wanders, N. (2021). Anthropogenic Drought: Definition, Challenges, and Opportunities. *Reviews of Geophysics*, 59(2), e2019RG000683. doi:https://doi.org/10.1029/2019RG000683
3. Ahmed Osman, A. I., AlDahoul, N., Chong, K. L., Huang, Y. F., Ng, J. L., Elshafie, A., . . . Ahmed, A. N. (2025). A review on machine learning models for drought monitoring and forecasting. *Climate Risk Management*, 50, 100758. doi:https://doi.org/10.1016/j.crm.2025.100758
4. Balti, H., Ben Abbes, A., Mellouli, N., Farah, I. R., Sang, Y., & Lamolle, M. (2020). A review of drought monitoring with big data: Issues, methods, challenges and research directions. *Ecological Informatics*, 60, 101136. doi:https://doi.org/10.1016/j.ecoinf.2020.101136
5. Brust, C., Kimball, J. S., Maneta, M. P., Jencso, K., & Reichle, R. H. (2021). DroughtCast: A machine learning forecast of the United States drought monitor. *Frontiers in big Data*, 4, 773478.
6. Chen, C., & Zhang, C.-Y. (2014). Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*, 275, 314-347. doi:10.1016/j.ins.2014.01.015
7. Connors, S., Schneider, R., Nalau, J., Hawkins, M., Ferdini, S., Wang, Y., ... Yobánolo del Rea, A. (2025). Earth observations for climate adaptation: tracking progress towards the Global Goal on Adaptation through satellite-derived indicators. *npj Climate and Atmospheric Science*, 8(1), 359. doi:10.1038/s41612-025-01251-1
8. Danandeh Mehr, A., Rikhtehgar Ghiasi, A., Yaseen, Z. M., Sorman, A. U., & Abualigah, L. (2023). A novel intelligent deep learning predictive model for meteorological drought forecasting. *Journal of Ambient Intelligence and Humanized Computing*, 14(8), 10441-10455.
9. Dikshit, A., Pradhan, B., & Huete, A. (2021). An improved SPEI drought forecasting approach using the long short-term memory neural network. *Journal of environmental management*, 283, 111979.
10. Drusch, M., Del Bello, U., Carlier, S.,

- 124900.
26. Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., & Yang, L. (2021). Physics-informed machine learning. *Nature Reviews Physics*, 3(6), 422-440. doi:10.1038/s42254-021-00314-5
27. Liu, Z., Yang, H., & Yang, D. (2026). Enhancing hydrological hazard early warning: A 60-day streamflow forecasting framework integrating deep learning and process-based modeling. *EGUsphere*, 2026, 1-21. doi:10.5194/egusphere-2026-393
28. Lotfirad, M., Esmacili-Gisavandani, H., & Adib, A. (2022). Drought monitoring and prediction using SPI, SPEI, and random forest model in various climates of Iran. *Journal of Water and Climate Change*, 13(2), 383-406.
29. Mankin, K. R., Mehan, S., Green, T. R., & Barnard, D. M. (2025). Review of gridded climate products and their use in hydrological analyses reveals overlaps, gaps, and the need for a more objective approach to selecting model forcing datasets. *Hydrol. Earth Syst. Sci.*, 29(1), 85-108. doi:10.5194/hess-29-85-2025
30. Manogaran, G., & Lopez, D. (2017). Spatial cumulative sum algorithm with big data analytics for climate change detection. *Computers & Electrical Engineering*, 65. doi:10.1016/j.compeleceng.2017.04.006
31. Martino, G., Astarita, V., Guido, G., Shaffiee Haghsheenas, S., & Shaffiee Haghsheenas, S. (2025). Risk Management in Transportation Systems: How Big Data Can Help Predict Behaviors and Events. *Procedia Computer Science*, 257, 39-46. doi:10.1016/j.procs.2025.03.008
32. Naughten, K. A., Holland, P. R., & De Rydt, J. (2023). Unavoidable future increase in West Antarctic ice-shelf melting over the twenty-first century. *Nature Climate Change*, 13(11), 1222-1228. doi:10.1038/s41558-023-01818-x
33. Núñez, J., Cortés, C., & Yáñez, M. (2023). Explainable Artificial Intelligence in Hydrology: Interpreting Black-Box Snowmelt-Driven Streamflow Predictions in an Arid Andean Basin of North-Central Chile. *Water*, 15, 3369. doi:10.3390/w15193369
34. Oladeji, O., & Mousavi, S. S. (2023). Towards AI-driven Integrative Emissions Monitoring & Management environmental monitoring: A review and future perspectives. *Information Fusion*, 86-87, 44-75. doi:https://doi.org/10.1016/j.inffus.2022.06.003
19. Hou, A. Y., Kakar, R. K., Neeck, S., Azarbarzin, A. A., Kummerow, C. D., Kojima, M., . . . Iguchi, T. (2014). The Global Precipitation Measurement Mission. *Bulletin of the American Meteorological Society*, 95(5), 701-722. doi:https://doi.org/10.1175/BAMS-D-13-00164.1
20. Hu, F., Yang, C., Schnase, J. L., Duffy, D. Q., Xu, M., Bowen, M. K., . . . Song, W. (2018). ClimateSpark: An in-memory distributed computing framework for big climate data analytics. *Computers & Geosciences*, 115, 154-166. doi:https://doi.org/10.1016/j.cageo.2018.03.011
21. Huntingford, C., Jeffers, E. S., Bonsall, M. B., Christensen, H. M., Lees, T., & Yang, H. (2019). Machine learning and artificial intelligence to aid climate change research and preparedness. *Environmental Research Letters*, 14(12), 124007. doi:10.1088/1748-9326/ab4e55
22. Huntingford, C., Jeffers, E. S., Bonsall, M. B., Christensen, H. M., Lees, T., & Yang, H. (2019). Machine learning and artificial intelligence to aid climate change research and preparedness. *Environmental Research Letters*, 14(12), 124007.
23. Jiao, W., Wang, L., & McCabe, M. F. (2021). Multi-sensor remote sensing for drought characterization: current status, opportunities and a roadmap for the future. *Remote Sensing of Environment*, 256, 112313. doi:https://doi.org/10.1016/j.rse.2021.112313
24. Justice, C. O., Townshend, J. R. G., Vermote, E. F., Masuoka, E., Wolfe, R. E., Saleous, N., . . . Morisette, J. T. (2002). An overview of MODIS Land data processing and product status. *Remote Sensing of Environment*, 83(1), 3-15. doi:https://doi.org/10.1016/S0034-4257(02)00084-6
25. Karbasi, M., Ali, M., Farooque, A. A., Jamei, M., Khosravi, K., Cheema, S. J., & Yaseen, Z. M. (2024). Robust drought forecasting in Eastern Canada: Leveraging EMD-TVF and ensemble deep RVFL for SPEI index forecasting. *Expert Systems with Applications*, 256,

- Probabilistic evaluation of drought propagation using satellite data and deep learning model: from precipitation to soil moisture and groundwater. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 6048-6061.
44. Shakeri, R., Amini, H., Fakheri, F., & Ketabchi, H. (2023). Assessment of drought conditions and prediction by machine learning algorithms using Standardized Precipitation Index and Standardized Water-Level Index (case study: Yazd province, Iran). *Environmental Science and Pollution Research*, 30(45), 101744-101760.
 45. Shiru, M. S., Shahid, S., Dewan, A., Chung, E.-S., Alias, N., Ahmed, K., & Hassan, Q. K. (2020). Projection of meteorological droughts in Nigeria during growing seasons under climate change scenarios. *Scientific Reports*, 10(1), 10107.
 46. Shukla, S., & Wood, A. W. (2008). Use of a standardized runoff index for characterizing hydrologic drought. *Geophysical Research Letters*, 35(2). doi:https://doi.org/10.1029/2007GL032487
 47. Sivakumar, M. V. (2005). Impacts of natural disasters in agriculture, rangeland and forestry: an overview. *Natural disasters and extreme events in agriculture: Impacts and mitigation*, 1-22.
 48. Soci, C., Hersbach, H., Simmons, A., Poli, P., Bell, B., Berrisford, P., . . . Thépaut, J.-N. (2024). The ERA5 global reanalysis from 1940 to 2022. *Quarterly Journal of the Royal Meteorological Society*, 150(764), 4014-4048. doi:https://doi.org/10.1002/qj.4803
 49. Sun, Q., Miao, C., Duan, Q., Ashouri, H., Sorooshian, S., & Hsu, K. L. (2018). A review of global precipitation data sets: Data sources, estimation, and intercomparisons. *Reviews of Geophysics*, 56(1), 79-107.
 50. Sutanto, S. J., Syaehuddin, W. A., & de Graaf, I. (2024). Hydrological drought forecasts using precipitation data depend on catchment properties and human activities. *Communications Earth & Environment*, 5(1), 118. doi:10.1038/s43247-024-01295-w
 51. Verma, S., Bhatia, A., Chug, A., & Singh, A. P. (2019). Recent advancements in multimedia big data computing for IoT applications in for Nature-Based Climate Solutions. arXiv preprint arXiv:2312.11566.
 35. Pickard, R., Starr, K., MacLennan, G., Lam, T., Thomas, R., Burr, J., . . . McClinton, S. (2015). Medical expulsive therapy in adults with ureteric colic: a multicentre, randomised, placebo-controlled trial. *Lancet*, 386(9991), 341-349. doi:10.1016/s0140-6736(15)60933-3
 36. Purnomo, E. P., & Redha, M. R. M. (2025). Mapping the big data's impact on urban land use and climate change sustainability in ASEAN. *Discover Cities*, 2(1), 129. doi:10.1007/s44327-025-00176-x
 37. Ramu, T. B., Kocherla, R., Sirisha, G. N. V. G., Chetana, V. L., Sagar, P. V., Balamurali, R., & Boddu, N. (2025). Transformer based models with hierarchical graph representations for enhanced climate forecasting. *Scientific Reports*, 15(1), 23464. doi:10.1038/s41598-025-07897-4
 38. Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204. doi:10.1038/s41586-019-0912-1
 39. Rhee, J., & Im, J. (2017). Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data. *Agricultural and Forest Meteorology*, 237, 105-122.
 40. Rodell, M., Houser, P., Jambor, U., Gottschalck, J., Mitchell, K., Meng, J., . . . Toll, D. (2004). The Global Land Data Assimilation System. *Bulletin of the American Meteorological Society*, 85, 381-394. doi:10.1175/BAMS-85-3-381
 41. Salvador, C., Vicedo-Cabrera, A. M., Libonati, R., Russo, A., Garcia, B. N., Belem, L. B. C., . . . Nieto, R. (2022). Effects of Drought on Mortality in Macro Urban Areas of Brazil Between 2000 and 2019. *GeoHealth*, 6(3), e2021GH000534. doi:https://doi.org/10.1029/2021GH000534
 42. Sedona, R., Cavallaro, G., Jitsev, J., Strube, A., Riedel, M., & Benediktsson, J. A. (2019). Remote Sensing Big Data Classification with High Performance Distributed Deep Learning. *Remote Sensing*, 11(24), 3056.
 43. Seo, J. Y., & Lee, S.-I. (2023).

- precision agriculture: opportunities, issues, and challenges Multimedia Big Data Computing for IoT Applications: Concepts, Paradigms and Solutions (pp. 391-416): Springer.
52. Wang, Y., Neubauer, D., Chen, Y., Jordan, G., Malavelle, F., Yuan, T., . . . Lohmann, U. (2025). Challenges in global climate models to represent cloud response to aerosols: insights from volcanic eruptions. *Nature Communications*, 17(1), 627. doi:10.1038/s41467-025-67359-3
 53. Wu, J., Gan, W., & Yu, P. (2024). Geospatial Big Data: Survey and Challenges. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, PP, 1-14. doi:10.1109/JSTARS.2024.3438376
 54. Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R., & Woodcock, C. E. (2012). Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, 122, 2-10. doi:https://doi.org/10.1016/j.rse.2012.01.010
 55. Xu, W., Chen, J., & Corzo, G. (2025). Combining data augmentation and hybrid modeling approaches for deep learning-based monthly streamflow forecasting. *Journal of Hydrology*, 659, 133318.
 56. Yaqoob, I., Hashem, I., Gani, A., Mokhtar, S., Ahmed, E., Anuar, N., & Vasilakos, A. (2016). Big Data: From Beginning to Future. *International Journal of Information Management*, 36. doi:10.1016/j.ijinfomgt.2016.07.009
 57. Zhang, Q., Wang, H., Wen, H., Long, C., Su, L., He, X., . . . Yin, H. (2026). A Survey of Generative Techniques for Spatial-Temporal Data Mining. *Data Science and Engineering*. doi:10.1007/s41019-026-00346-w
 58. Zhao, J., Chu, F., Xie, L., Che, Y., Wu, Y., & Burke, A. F. (2026). A survey of transformer networks for time series forecasting. *Computer Science Review*, 60, 100883. doi:https://doi.org/10.1016/j.cosrev.2025.100883