



A review of artificial intelligence and its applications in soil science

Hassanpour, R.*  Khanzadeh Rik Abadi, M. R. Tavasolee, A. and Rezaei, H.

Soil and Water Research Department; East Azerbaijan Agricultural and Natural Resources Research and Education Center; Agricultural Research, Education and Extension Organization (AREEO); Tabriz; Iran. reza.hassanp@gmail.com

Undergraduate Student, Department of Soil Science and Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran. mrkhanzadeh22@gmail.com

Faculty Member; Soil and Water Research Department; East Azerbaijan Agricultural and Natural Resources Research and Education Center; Agricultural Research, Education and Extension Organization (AREEO); Tabriz; Iran. ar.tavasolee@areeo.ac.ir

Assistant Prof., Department of Soil Science and Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran. h_rezaei_1984@yahoo.com

Article Info

Article Type: Review Article

Received: November 10, 2025

Accepted: February 09, 2026

Keywords:

Artificial intelligence, Expert systems, Digital soil mapping, Machine learning

Corresponding author's email address:

reza.hassanp@gmail.com

Extended Abstract

Objectives

Artificial Intelligence (AI) has emerged as a transformative tool in the field of soil science, providing capabilities for data analysis, pattern recognition, and decision-making that go beyond those of the traditional methods. Extensive research has focused on developing and applying AI in soil science, driven by the growth of digital data, computational power, and algorithmic advancements. While machine learning (ML) currently dominates AI applications, the field encompasses broader areas including digital image analysis, natural language processing (NLP), expert systems, and knowledge representation. In soil science, AI supports diverse tasks, from predicting soil carbon stocks with ML algorithms to evaluating soil functions via decision support systems, extracting metadata from scientific texts, and analyzing digital soil images. Despite this progress, a precise consensus on AI's definition remains elusive, often conflated with ML, even though its scope extends to computer vision, control theory, and robotics. Early predictions anticipated revolutions in soil science through expert systems and natural language interfaces, some realized as fuzzy logic and decision support applications. Recently revitalized interest in AI owes much to advances in ML and digital convergence, that is, the integration of digital data, databases, the internet, and advanced tools for big data management. Nevertheless, interdisciplinary dialogue among the subfields remains limited, constraining the full exploitation of AI potentials. This review study is dedicated to providing a comprehensive overview of AI's role and applications in soil science, review of its history and definitions, its classification into key domains, and documentation of its diversity across subdisciplines as well as identification of trends, research gaps, challenges, and future opportunities, with emphasis laid on its overreliance on predictive ML and the need for explainability and knowledge integration.

Methodology

This study is a narrative review derived from an extensive body of scientific literature. For this purpose, systematic searches were conducted in major databases including Scopus, Web of Science, Google Scholar, and the Scientific Information Database (in Persian). The search strategy combined keywords such as “artificial intelligence in soil science”, “machine learning”, “expert systems”, “digital soil mapping”, “natural language processing”, “pedotransfer functions”, “soil image analysis”, and “explainable AI” (all in English) along with Persian equivalents for broader coverage. Inclusion criteria prioritized seminal works on AI history and definitions, foundational studies on soil applications, recent reviews, and empirical papers demonstrating AI techniques under various soil contexts. The information thus collected was structured around a taxonomy classifying AI into three main domains, with critical analysis of applications, algorithms, and limitations. Quantitative trends, such as publication growth, were also considered based on annual AI reports.

Results

AI traces its origins to early neural models and foundational conferences, evolving through periods of limited progress to modern breakthroughs in protein structure prediction and image generation. Definitions of AI range from emulating human intelligence to rational decision-making for goal achievement. In soil science, AI applications cover sensing and interacting, reasoning and decision-making, as well as learning and prediction. In sensing and interacting, NLP is used to extract data from legacy soil profiles, computer vision to support soil image classification, proximal and remote sensing with ML to predict soil properties, robotics to enable automated sampling, and explainable AI (XAI) to interpret model outputs using techniques such as Shapley values. Reasoning and decision-making applications include expert systems for soil classification, fuzzy logic for handling uncertainty, decision support systems for conservation planning, and optimization algorithms for land evaluation. Learning and prediction (i.e., the dominant domain) employs ML techniques such as random forests and neural networks for digital soil mapping (DSM), pedotransfer functions (PTFs) for estimating hydraulic properties, and predictive modeling for estimating soil salinity or nutrient content. Across soil subdisciplines, AI has proven effective in DSM, PTF development, image classification, and expert systems. However, the majority of applications remain ML-focused and predictive, such as mapping soil organic carbon, with relatively few studies emphasizing explainability or integration of pedological knowledge. Exceptions include NLP for meta-analysis and cognitive soil models, which demonstrate its potentials for more holistic AI uses. Persistent challenges involve overemphasis on prediction, reduced model interpretability, and limited synergy across soil science subfields.

Conclusion

AI has profoundly impacted soil science, offering tools for predicting, interacting, and decision-making, yet its applications remain heavily skewed toward ML-based forecasting. While AI effectively handles big data and complex patterns, as evidenced by DSM and PTF advancements, it often lacks interpretability and domain-specific knowledge integration, resulting in black-box models that might impede scientific understanding. Notable exceptions such as XAI and NLP for legacy data extraction highlight pathways for broader, more holistic applications. Future directions include mining historical soil profile texts to extract new insights, constructing meta-analyses from soil literature using NLP, developing interpretable ML models, and integrating cognitive models for simulating soil processes. Addressing these challenges will require interdisciplinary collaboration, fostering synergies across subfields and embedding pedological expertise into algorithms. Recommendations include establishing standardized benchmarks for AI applications, promoting open-source datasets and tools for reproducibility, investing in XAI to enhance trust and usability, and exploring hybrid approaches that combine AI with traditional methods for sustainable soil management. Responsible AI development, aligned with ethical principles such as bias mitigation, will ensure its contribution to addressing global challenges including climate resilience and food security.

Cite this Article: Hassanpour, R., Khanzadeh Rik Abadi, M.R., Tavasolee, A. and Rezaei, H., 2026. A review of artificial intelligence and its applications in soil science. *Journal of Land Management*, 14(1), PP.75-111.



DOI: <https://doi.org/10.22092/lmj.2026.370937.396>

مروری بر هوش مصنوعی و کاربردهای آن در علوم خاک

رضا حسن پور* , محمدرضا خانزاده ریک آبادی، علیرضا توسلی و حسین رضائی

محقق بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی آذربایجان شرقی، سازمان تحقیقات، آموزش و ترویج کشاورزی، تبریز، ایران.

reza.hassanp@gmail.com

دانشجوی کارشناسی گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. mrkhanzadeh22@gmail.com

استادیار بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی آذربایجان شرقی، سازمان تحقیقات، آموزش و ترویج کشاورزی، تبریز،

ایران. ar.tavasolee@areeo.ac.ir

استادیار گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. h_rezaei_1984@yahoo.com

اطلاعات مقاله

چکیده

نوع مقاله: مروری

دریافت: ۱۴۰۴/۸/۱۹

پذیرش: ۱۴۰۴/۱۱/۲۰

واژه‌های کلیدی:

سیستم‌های خیره، نقشه‌برداری رقومی خاک، هوش مصنوعی، یادگیری ماشین

آدرس ایمیل نویسنده مسئول:

reza.hassanp@gmail.com

در دهه‌های اخیر، تحقیقات گسترده‌ای به توسعه و کاربرد هوش مصنوعی در علوم خاک اختصاص یافته است. اگرچه بخش عمده‌ای از کاربردهای کنونی هوش مصنوعی در علوم خاک به یادگیری ماشین مربوط می‌شود، اما این فناوری حوزه‌های دیگری مانند تجزیه و تحلیل تصویر دیجیتال، پردازش زبان طبیعی، سیستم‌های خبره و نمایش دانش را نیز در برمی‌گیرد. هدف این مقاله مروری، ارائه یک بررسی جامع از نقش و کاربردهای هوش مصنوعی در علوم خاک است. در ابتدا، تاریخچه و تعاریف هوش مصنوعی مرور شده و سپس یک طبقه‌بندی معمول از هوش مصنوعی در سه حوزه سنجش و تعامل، استدلال و تصمیم‌گیری و یادگیری و پیش‌بینی ارائه شده است. در ادامه، کاربردها و الگوریتم‌های مرتبط با هر حوزه در علوم خاک بررسی شده‌اند. یافته‌های اصلی نشان می‌دهد: الف) کاربردهای هوش مصنوعی در علوم خاک متنوع بوده و شامل سیستم‌های پشتیبانی تصمیم‌گیری، طبقه‌بندی تصویر، پیش‌بینی با یادگیری ماشین و سیستم‌های خبره می‌شوند. ب) در حال حاضر، کاربرد هوش مصنوعی در علوم خاک تقریباً به‌طور کامل با یادگیری ماشین گره‌خورده است؛ ج) کاربردهای یادگیری ماشین به‌طور عمده در نقشه‌برداری رقومی خاک و توسعه توابع انتقالی خاک دیده می‌شوند و د) بخش عمده‌ای از کاربردهای هوش مصنوعی بر اهداف پیش‌بینی متمرکز هستند. با این حال، چند استثنای قابل توجه فراتر از این کاربردها، به‌ویژه در پردازش زبان طبیعی، توسعه مدل‌های شناختی خاک و یادگیری ماشین تفسیرپذیر مشاهده می‌شود. بر اساس این یافته‌ها، تمرکز بیش از حد بر پیش‌بینی با هوش مصنوعی، همراه با کاهش قابلیت توضیح و نبود ادغام مؤثر دانش خاک در الگوریتم‌ها، از چالش‌های مهم این حوزه می‌باشد. افق‌های آینده در این زمینه شامل بهره‌گیری از هوش مصنوعی برای استخراج داده‌ها از متون نیم‌رخ‌های خاک قدیمی به منظور بازایی منابع جدید اطلاعات خاک و نیز به‌کارگیری پردازش زبان طبیعی برای ساخت فراتحلیل‌هایی از متون علمی خاک‌شناسی است. این کاربردهای نوظهور می‌توانند سهم بسزایی در تحقیقات علوم خاک ایفا کنند.

استناد: حسن پور، رضا، خانزاده ریک آبادی، محمدرضا، توسلی، علیرضا، و رضائی، حسین، ۱۴۰۵. مروری بر هوش مصنوعی و کاربردهای آن در علوم خاک.

نشریه مدیریت اراضی، ۱۴(۱)، صص. ۷۵-۱۱۱.



DOI: <https://doi.org/10.22092/lmj.2026.370937.396>

مقدمه

کمتر کسی با این دیدگاه مخالف است که هوش مصنوعی^۱ ظرفیت زیادی برای یادگیری، تولید دانش و استخراج اطلاعات دارد و علوم خاک نیز از این قاعده مستثنا نیست. در چند دهه گذشته، پژوهش‌های متعددی به توسعه و کاربرد هوش مصنوعی در تحقیقات خاک‌شناسی اختصاص یافته است. نمونه‌هایی از این کاربردها عبارت هستند از: الف) الگوریتم‌های یادگیری ماشین برای مدل‌سازی روابط بین داده‌های اندازه‌گیری‌شده خاک و عوامل محیطی تشکیل خاک مورد استفاده قرار گرفته تا ذخایر کربن خاک را در ابعاد مکانی و زمانی پیش‌بینی کند (Heuvelink et al., 2021؛ ب) یک سیستم پشتیبانی تصمیم‌گیری، کارکردهای خاک در اراضی کشاورزی را به صورت نیمه کمی ارزیابی می‌کند (Debeljak et al., 2019؛ ج) فراداده‌های متنی به صورت خودکار از انتشارات علمی مرتبط با علوم خاک استخراج می‌شوند (Blanchy et al., 2023) و د) تصاویر دیجیتال مقاطع نازک خاک با استفاده از الگوریتمی تحلیل می‌شوند که توانایی تشخیص اجزای معدنی و غیرمعدنی را دارد (Aydemir et al., 2004). در هر یک از این موارد، سامانه‌ای طراحی یا آموزش داده می‌شود تا با سطحی از خودمختاری، به هدف مشخصی دست یابد؛ خواه این هدف، پیش‌بینی مکانی، ارزیابی کارکردهای خاک، تولید یک فراتحلیل یا شناسایی خودکار عارضه‌های خاک باشد. از اوایل دهه ۲۰۱۰، توسعه فناوری‌های مبتنی بر هوش مصنوعی با شتابی چشمگیر در سراسر حوزه‌های علمی و صنعتی گسترش یافته است. بر اساس شاخص هوش مصنوعی که سالانه توسط هیئت متخصصان AI100 منتشر می‌شود (Nestor et al., 2024)، رشد قابل توجهی در حجم پژوهش‌های مرتبط با هوش مصنوعی مشاهده شده است؛ به‌ویژه، تعداد انتشارات علمی مرتبط با یادگیری ماشین از سال ۲۰۱۵ تاکنون تقریباً هفت برابر شده است. این روند عمدتاً ناشی از

سرمایه‌گذاری‌های کلان بخش خصوصی و افزایش چشمگیر ثبت اختراعات در حوزه هوش مصنوعی است. علوم خاک نیز از این موج تحولات بی‌نصیب نمانده است. چندین مطالعه مروری اخیر (به عنوان مثال، Padarian et al., 2020; Grunwald, 2022; Chen et al., 2022; Minasny et al., 2024) نشان‌دهنده علاقه‌مندی فزاینده پژوهشگران به بررسی و توسعه کاربردهای هوش مصنوعی در تحقیقات خاک هستند.

با این حال، برای بسیاری از پژوهشگران، تعریف دقیق و قابل اجماع از هوش مصنوعی همچنان چالش برانگیز باقی مانده است. درحالی‌که تمرکز برخی از دانشمندان بر روی توسعه هوش مصنوعی با قابلیت مدل‌سازی تفکرات انسان است، برخی دیگر هوش مصنوعی را به عنوان الگوریتمی می‌بینند که برای دستیابی به نتایج بهینه طراحی شده است. اگرچه هوش مصنوعی اغلب معادل با یادگیری ماشین در نظر گرفته می‌شود، اما دامنه آن بسیار فراتر از یادگیری ماشین است. واقعیت این است که بخش عمده‌ای از کاربردهای فعلی هوش مصنوعی در علوم خاک مبتنی بر یادگیری ماشین هستند، اما مطالعه هوش مصنوعی حوزه‌هایی دیگر مانند بینایی کامپیوتر^۲، تشخیص الگو^۳، نظریه کنترل^۴ و مدیریت فرایندها^۵ را نیز در برمی‌گیرد (Nestor et al., 2024). افزون بر این، Russell and Norving (2016) بر این نکته تأکید دارند که هوش مصنوعی شامل حوزه‌هایی چون پردازش زبان طبیعی^۶، رباتیک، بازنمایی دانش^۷ و استدلال نیز هست.

کاربرد هوش مصنوعی در علوم خاک پدیده‌ای نوظهور نیست. Holt (1978) پیش‌بینی کرده بود که انقلابی در علوم خاک تحت تأثیر سیستم‌های خبره، تشخیص الگو و رابط‌های کاربر زبان طبیعی^۸ رخ خواهد داد. رابط کاربر زبان طبیعی به سیستم‌هایی اشاره دارد که به کاربران اجازه می‌دهند از طریق زبان طبیعی (مانند فارسی یا انگلیسی) به جای زبان‌های برنامه‌نویسی یا فرمان‌های پیچیده با رایانه

5- Process management
6- Natural language processing
7- Knowledge representation
8- Natural language interfaces

1- Artificial intelligence
2- Computer vision
3- Pattern recognition
4- Control theory

تاریخچه هوش مصنوعی

ریشه‌های هوش مصنوعی به دهه ۱۹۴۰ بازمی‌گردد، زمانی که مک‌کالوک و پیتس نخستین مدل ریاضی از نوروں مصنوعی را ارائه کردند و بدین ترتیب زمینه‌ساز توسعه شبکه‌های عصبی شدند (McCulloch and Pitts, 1943). اندکی بعد، آلن تورینگ در مقاله بنیادین خود با عنوان ماشین محاسبه‌گر و هوش در سال ۱۹۵۰، مفهوم تست تورینگ را به‌عنوان معیاری برای سنجش توانایی ماشین‌ها در تقلید از رفتار هوشمندانه انسانی مطرح ساخت (Turing, 1950). اصطلاح هوش مصنوعی نخستین بار در کنفرانس تاریخی دارتموث^۲ در سال ۱۹۵۵ توسط جان مک‌کارتی و همکارانش معرفی شد و این رویداد به‌عنوان آغاز رسمی این حوزه شناخته می‌شود (McCarthy et al., 1955). دهه‌های بعد شاهد توسعه سامانه‌های نمادین و نخستین سیستم‌های پردازش زبان طبیعی مانند الیزا^۳ (Weizenbaum, 1966) و ربات متحرک شیکی^۴ (Nilsson, 1984) بود.

در دهه ۱۹۸۰، سامانه‌های خبره مانند دندرال^۵ و مایسین^۶ گسترش یافته و توانستند در حوزه‌هایی چون شیمی و پزشکی به کار گرفته شوند (Shortliffe, 1976). بااین حال، محدودیت‌های محاسباتی و هزینه‌های بالا منجر به دوره‌ای موسوم به «زمستان هوش مصنوعی» شد (Crevier, 1993). این رکود تا دهه ۱۹۹۰ ادامه یافت تا اینکه موفقیت‌های برجسته‌ای مانند پیروزی سیستم Deep Blue شرکت بین‌المللی ماشین‌های تجاری بر قهرمان شطرنج جهان، گری کاسپاروف^۷، در سال ۱۹۹۷ توجهات دوباره‌ای را به این حوزه جلب کرد (Campbell et al., 2002).

با ورود به قرن بیست و یکم، پیشرفت در توان پردازشی، دسترسی به داده‌های کلان و توسعه الگوریتم‌های یادگیری ماشین و یادگیری عمیق، هوش مصنوعی را به یکی از مهم‌ترین فناوری‌های تحول‌آفرین در علوم، صنعت


یا نرم‌افزار تعامل داشته باشند. در دهه‌های پس‌از آن، برخی از این انتظارات تحقق یافتند. برای نمونه، کاربردهایی در منطق فازی (Burrough, 1992) و سیستم‌های پشتیبانی تصمیم‌گیری (Skidmore et al., 1991; Zhang and Berndtsson, 1991) توسعه یافتند. بااین حال، پیشرفت‌های مورد انتظار در مقیاس وسیع در آن زمان محقق نشدند. از دهه ۲۰۱۰ به بعد، علاقه به هوش مصنوعی در علوم خاک دوباره احیا شد که علت آن را می‌توان در پیشرفت‌های سریع در یادگیری ماشین، دسترسی گسترده به نرم‌افزارهای آسان برای استفاده و تا حدی، پدیده همگرایی دیجیتال^۱ دانست. این همگرایی، بنا به تعریف Wadoux and McBratney (2021)، به معنای همگرایی داده‌های دیجیتال، پایگاه‌های داده الکترونیکی، اینترنت و ابزارهای پیشرفته برای مدیریت و پردازش حجم انبوهی از داده‌ها است. مطالعات متعددی (Canillas and Salokhe, 2002; Behrens et al., 2005; Alvarez et al., 2011; Fajardo et al., 2016) نشان داده‌اند که هوش مصنوعی برای پاسخ به پرسش‌های متنوعی در شاخه‌های مختلف علوم خاک به کار گرفته شده است. بااین حال، به نظر می‌رسد تعامل و گفت‌وگوی بین‌رشته‌ای میان این حوزه‌ها اندک است و هر یک اغلب به‌صورت مستقل عمل می‌کنند. این در حالی است که فراتر از پیشرفت محض در توسعه هوش مصنوعی، ظرفیت بالقوه‌ای برای هم‌افزایی میان کاربردهای مختلف و مکمل هوش مصنوعی در علوم خاک وجود دارد. هدف این مقاله مروری، بررسی روند ادغام هوش مصنوعی در علوم خاک و ترسیم مسیرهای آینده این حوزه است. اهداف اصلی عبارت هستند از: (۱) توصیف گستره کاربردهای هوش مصنوعی در علوم خاک، (۲) مستندسازی استفاده از هوش مصنوعی در زیرشاخه‌های مختلف این علم و (۳) شناسایی محورهای کلیدی، خلأهای تحقیقاتی و بررسی فرصت‌های بالقوه برای تحقیقات آینده.

5- DENDRAL
6- MYCIN
7- Garry Kasparov

1- Digital convergence
2- Dartmouth
3- ELIZA
4- Shakey

اتوماسیون مورد توجه قرار گرفته‌اند. جمع‌بندی فعلی نشان می‌دهد هوش مصنوعی با قدرتی روزافزون در حال رشد است و چشم‌انداز آینده شامل توسعه هوش مصنوعی عمومی مسئول و یکپارچه با زندگی انسانی است (Russell and Norvig, 2010). یعنی هوش مصنوعی که در خدمت انسان، قابل فهم، قابل کنترل و همسو با ارزش‌ها و تصمیم‌های انسانی باشد. این روند نشان می‌دهد که هوش مصنوعی همواره در تعامل با پیشرفت‌های علمی و فناوریانه تکامل یافته و چشم‌انداز آینده آن همچنان گسترده است. شکل ۱ تاریخچه و سیر تکامل هوش مصنوعی در گذر زمان را نشان می‌دهد.

و زندگی روزمره بدل کرد (Russell and Norvig, 2019; Haenlein and Kaplan, 2016). سیستم‌هایی مانند چت جی‌پی‌تی^۱ توانایی گفتگوی انسانی و تولید متن با کیفیت بسیار بالا را نشان داده‌اند. افزون بر این، هوش مصنوعی نقش مؤثری در پیشبرد پژوهش‌های علمی و حل مسائل پیچیده ایفا می‌کند؛ به گونه‌ای که سامانه آلفا فولد^۲ در سال ۲۰۲۰ موفق شد ساختار سه‌بعدی پروتئین‌ها را با دقتی بی‌سابقه پیش‌بینی کند. افزون بر این، مدل‌های مولد مانند دال‌ای^۳ (Ramesh et al., 2021) امکان تولید خودکار تصاویر هنری را فراهم آورده‌اند. در کنار این پیشرفت‌ها، ملاحظات اخلاقی و اجتماعی نظیر حریم خصوصی، تعصبات الگوریتمی و تاثیرات اقتصادی



شکل ۱- تاریخچه هوش مصنوعی
Figure 1- The History of Artificial Intelligence

3- DALL-E

1- ChatGPT
2- AlphaFold 2

تفاوت دو دوره قبل و بعد از زمستان هوش مصنوعی به تغییر توان پردازشی رایانه‌ها، دسترسی به حجم عظیمی از داده‌های دیجیتال، اتصال سیستم‌های رایانه‌ای از طریق اینترنت و توسعه گسترده حسگرها و ابزارهای دیجیتال جمع‌آوری داده نسبت داده می‌شود.

تعریف هوش مصنوعی

تعریف «هوش مصنوعی» نیز در گذر زمان دستخوش تفسیرهای گوناگون بوده است. برای مثال، فرهنگ لغت مریام-وبستر^۱ آن را «توانایی سیستم‌ها یا الگوریتم‌های رایانه‌ای در تقلید از رفتار هوشمندانه انسان» تعریف می‌کند. این تعریف که در متون علمی نیز به‌طور گسترده تکرار می‌شود، بر دو فرض کلیدی استوار است نخست، اینکه قلمرو هوش مصنوعی به شبیه‌سازی و یا تقلید رفتار انسان محدود می‌شود و دوم، اینکه مفهوم «هوش» در این زمینه به‌روشنی تعریف شده است. هرچند ممکن است برای هر دو فرض استدلال‌هایی ارائه شود، اما هر دو همچنان مورد مناقشه هستند در مورد نخست، بخش عمده‌ای از پژوهش‌های هوش مصنوعی نه برای تقلید از عملکرد زیستی انسان، بلکه برای حل مسائل واقعی و کاربردی طراحی شده‌اند. این موضوع نشان می‌دهد که دامنه هوش مصنوعی فراتر از صرفاً مطالعه و تقلید رفتار انسانی است. نکته دوم فرض می‌کند که درک روشنی از چیستی هوش وجود دارد. برخلاف تصور رایج، هنوز اجماع مشخصی در تعریف هوشی که برای انسان و ماشین به کار می‌رود، وجود ندارد. همان‌گونه که (McCarthy 2007) اشاره می‌کند، برداشت ما از هوش عمیقاً متأثر از تلقی انسان‌محورانه ما است و این امر، تعریف مستقل و جامع از هوش برای سیستم‌های محاسباتی را دشوار می‌سازد. برای نمونه، یک سیستم ممکن است برخی ویژگی‌های هوشمندانه مانند حافظه یا توان انجام وظایف را از خود نشان دهد (Legg and Hutter, 2007)، اما همان‌گونه که (McShea 2013) بیان می‌کند، هیچکدام از سیستم‌های هوش مصنوعی نمی‌تواند به پرسش‌هایی از نوع «علاق و

خواسته‌های فردی» پاسخ دهد برای مثال: «امروز دوست دارید چه کاری انجام دهید؟»- زیرا فاقد خواسته‌ها، احساسات و ارزش‌گذاری ذاتی است. عملکرد آن صرفاً بر منطق و کدهای از پیش تعیین‌شده استوار است. به همین دلیل، تفاوت بنیادینی میان هوش انسانی که شامل آگاهی، احساس، اراده و ارزش‌گذاری است و ظرفیت‌های محاسباتی سیستم‌های محاسبه‌گر وجود دارد؛ تفاوتی که هرگونه معادل‌سازی مستقیم بین این دو را با چالش جدی مواجه می‌سازد.

مفهوم وجود یک «شکل جهانی از هوش» که بتواند به‌طور مشترک انسان‌ها و ماشین‌ها را در برگیرد، همچنان مبهم و مورد مناقشه است. با این حال، وضعیت به آن پیچیدگی که ممکن است در ابتدا به نظر برسد، نیست. برخی به‌جای تمرکز بر شباهت به عملکرد یا رفتار انسانی، هوش را بر اساس توانایی تولید تفکر و تصمیم‌گیری عقلانی یعنی اتخاذ تصمیم‌های مناسب با توجه به زمینه و اهداف موجود تعریف می‌کنند. واضح است که تعریف هوش به‌عنوان عقلانیت و رفتار بهینه در سیستم‌های مصنوعی، با نگاه محدود به هوش به‌عنوان تقلید صرف از رفتار و عملکرد انسانی تفاوت دارد. این تمایز مفهومی در کتاب بنیادین (Russell and Norving 2016) برجسته شده است؛ جایی که آن‌ها تأکید می‌کنند که سیستم‌های هوش مصنوعی می‌توانند یا به تقلید از تفکر و رفتار انسانی بپردازند یا اینکه بر پایه اصول عقلانی و هدف محور طراحی شوند. تعریف اخیر که مورد حمایت Wadoux (2025) نیز قرار دارد، با تعریف کلاسیک Minsky (1969) از هوش مصنوعی به‌عنوان «علم ساختن ماشین‌هایی برای انجام وظایفی که اگر توسط انسان‌ها انجام می‌شد، نیاز به هوش داشت» هم‌راستا است. همچنین با تعریف ارائه‌شده توسط گروه متخصصان کمیسیون اروپا (European Commission, 2019) سازگار است؛ تعریفی که هوش مصنوعی را به‌عنوان «سیستم‌هایی که با تحلیل محیط و انجام اقداماتی با درجه‌ای از خودمختاری

برای تحقق اهداف مشخص، رفتار هوشمندانه‌ای از خود نشان می‌دهند» معرفی می‌کند. در هر دو دیدگاه، هوش برابر با اعمال منطقی و عقلانی تلقی می‌شود.


این رویکرد مفهومی ما را به سوی بررسی ساختار و تکنیک‌هایی سوق می‌دهد که هوش مصنوعی را شکل می‌دهند. بر اساس طبقه‌بندی ارائه‌شده توسط کمیسیون اروپا (European Commission, 2019)، تکنیک‌های هوش مصنوعی را می‌توان به سه دسته کلی تقسیم کرد: اول، استدلال و تصمیم‌گیری که شامل نمایش دانش، استنتاج مبتنی بر قواعد نمادین و الگوریتم‌های بهینه‌سازی است؛ دوم، یادگیری که روش‌های یادگیری ماشین و یادگیری عمیق را در برمی‌گیرد و سوم، رباتیک که به تعامل سیستم‌های هوشمند با محیط واقعی و دیگر سیستم‌ها می‌پردازد و قابلیت‌های آن‌ها را فراتر از سطوح استدلال و یادگیری گسترش می‌دهد. البته این دسته‌ها به‌تنهایی مجموعه‌ای یکپارچه و منسجم تشکیل نمی‌دهند، اما چارچوبی مفید برای درک تنوع گسترده تکنیک‌هایی فراهم می‌کنند که در توسعه سیستم‌های هوش مصنوعی مورد استفاده قرار می‌گیرند. این طبقه‌بندی در منابع علمی نیز به‌طور گسترده پذیرفته شده است (Russell and Norvig, 2016; Pournader et al., 2021; Doorn, 2021).

طبقه‌بندی هوش مصنوعی در علوم خاک

پس از تعریف هوش مصنوعی و تأکید بر امکان تقسیم آن به سه دسته کلی استدلال و تصمیم‌گیری، یادگیری و رباتیک، این پرسش مطرح می‌شود که چگونه می‌توان این مفاهیم را در حوزه علوم خاک به کار بست؟ Wadoux (2025) یک طبقه‌بندی را با هدف دربرگرفتن تمام کاربردها و روش‌های مورد استفاده در تحقیقات علوم خاک با بهره‌گیری از هوش مصنوعی ارائه کرد (شکل ۲).

این طبقه‌بندی سه سطح (۱) حوزه‌های اصلی هوش مصنوعی (دایره‌ها)، (۲) کاربردهای آن‌ها (بیضی‌ها) و

(۳) مثال‌هایی از تکنیک‌ها و روش‌ها (لایه‌های بیرونی) را نشان می‌دهد. تمام این سطوح حداقل یک کاربرد در پژوهش‌های علوم خاک داشته‌اند، اما اغلب تکنیک‌ها به‌طور قابل توجهی همپوشانی دارند. به‌عنوان مثال، هوش مصنوعی تبیین‌پذیر^۱ شامل طیف وسیعی از روش‌ها است که توضیحاتی را از الگوریتم‌های یادگیری ماشین آموزش‌دیده تولید می‌کنند. اولین حوزه با عنوان «سنجش و تعامل»، فناوری پردازش زبان طبیعی، تحلیل تصویر، بینایی کامپیوتر و رباتیک را در برمی‌گیرد. حوزه دوم، «استدلال و تصمیم‌گیری»، شامل نمایش دانش، استنتاج قواعد نمادین، سیستم‌های خبره و تکنیک‌های جستجو و بهینه‌سازی است. حوزه سوم، «یادگیری و پیش‌بینی»، مجموعه‌ای از روش‌های مبتنی بر داده مثل شبکه‌های عصبی و جنگل تصادفی را شامل می‌شود. زیربخش‌های بعدی توضیحات بیشتری درباره این سه حوزه ارائه می‌دهند.



شکل ۲- طبقه‌بندی هوش مصنوعی در علوم خاک (Wadoux, 2025)

Figure 2- Taxonomy of artificial intelligence in soil science (Wadoux, 2025)

سنجش و تعامل

حوزه سنجش و تعامل، مجموعه‌ای از کاربردها را در برمی‌گیرد که هوش مصنوعی را به دنیای فیزیکی متصل می‌سازد. این حوزه شامل رابط‌های انسان-هوش مصنوعی و روش‌های مبتنی بر بینایی یا سنجش است که الگوریتم‌ها را قادر می‌سازد تصاویر و سیگنال‌ها را پردازش و تفسیر کنند. پیشرفت‌های اخیر در رباتیک، به‌ویژه در حوزه‌های زراعت و تحلیل خاک، افق‌های تازه‌ای را در مطالعات خاک‌شناسی گشوده‌اند. ربات‌ها اکنون قادرند وظایفی چون نمونه‌برداری خاک (Sikora et al., 2011)، پایش و تحلیل خودکار خاک (Iqbal et al., 2020; Kitić et al., 2022) و تعامل با محیط فیزیکی از طریق برنامه‌ریزی مسیر^۱، بینایی کامپیوتر^۲، حسگرهای پیشرفته و سیستم‌های کنترل را با دقت و کارایی بالا انجام دهند. اگرچه ربات‌ها در دسته سیستم‌های هوش مصنوعی جای می‌گیرند، اما طراحی و عملکرد آن‌ها در پیوند تنگاتنگ با حوزه‌هایی فراتر از علوم خاک و هوش مصنوعی مثل مهندسی مکانیک، نظریه کنترل و نورشناسی است.

در علوم خاک، فناوری حسگری یکی از اجزای کلیدی «سنجش و تعامل» به‌شمار می‌رود. حسگرها در این حوزه به دو دسته کلی حسگرهای نزدیک‌برد^۳ و حسگرهای دوربرد^۴ تقسیم می‌شوند. این حسگرها، سیگنال‌هایی مانند طیف‌های نوری یا داده‌های فیزیکی را دریافت کرده و آن‌ها را با ویژگی‌های خاکی نظیر بافت، رطوبت یا ترکیب شیمیایی مرتبط می‌کنند. تحلیل این داده‌ها، به دلیل پیچیدگی ذاتی، اغلب نیازمند استفاده از الگوریتم‌های یادگیری ماشین است. مطالعاتی مانند (Ng et al., 2022) و (Baumann et al., 2022) نمونه‌هایی برجسته از کاربرد مدل‌های تجربی و داده محور در تفسیر خروجی حسگرها هستند.

در کنار حسگری، بینایی کامپیوتر و پردازش تصویر نیز دو حوزه نزدیک به هم با کاربردهای گسترده در

علوم خاک به‌شمار می‌روند که از فیلتر کردن و بهبود تصویر، قطعه‌بندی^۵ و استخراج عارضه استفاده می‌کنند. هرچند مرز این دو حوزه همواره روشن نیست، می‌توان گفت پردازش تصویر به شناسایی و استخراج ویژگی‌ها از تصاویر دیجیتال می‌پردازد و بینایی کامپیوتر این ویژگی‌ها را به کار می‌گیرد تا یک وظیفه مشخص انجام دهد. (Bogrecki and Godwin, 2007) چارچوبی برای تحلیل توزیع اندازه کلوخه‌ها و خاکدانه‌ها از تصاویر دیجیتال توسعه دادند. (Abeje et al., 2024) یک خط لوله بینایی کامپیوتر برای طبقه‌بندی انواع خاک ارائه کردند که گامی مهم در جهت خودکارسازی طبقه‌بندی خاکی محسوب می‌شود.

پردازش زبان طبیعی حوزه‌ای از هوش مصنوعی است که به ماشین‌ها امکان می‌دهد زبان انسانی را درک، تفسیر و تولید کنند. این حوزه شامل تولید متن، دگرنمایی واژه‌ها^۶ و استخراج متن از یک مجموعه اسناد برای پاسخ‌گویی به پرسش‌های کاربر است. از فناوری پردازش زبان طبیعی برای ایجاد یک مدل زبانی ویژه علم خاک با استفاده از دگرنمایی واژه‌ها (Padarian and Fuentes, 2019) و همچنین برای استخراج نیمه‌خودکار عوامل مؤثر مرتبط با شیوه‌های مختلف مدیریت خاک یا اصلاح‌کننده‌های آن، از میان تعداد زیادی مطالعات منتشرشده استفاده شده است (Blanchy et al., 2023). این کاربردها، نقش فناوری پردازش زبان طبیعی را به‌عنوان ابزاری برای متاآنالیز و تحلیل سیستماتیک ادبیات علمی تثبیت کرده‌اند.

هوش مصنوعی توضیح‌پذیر، روش‌هایی برای درک پیش‌بینی‌های انجام‌شده توسط الگوریتم‌های پیچیده هستند. آن‌ها در کاربردهای مختلفی مانند درک عوامل مهم مؤثر در ذخایر کربن آلی خاک (Wadoux et al., 2023) یا پیش‌بینی حاصلخیزی خاک (Chandra et al., 2023) استفاده می‌شوند. این روش‌ها در حوزه سنجش و تعامل

4- Remote Sensors
5- Segmentation
6- Word embedding

1- Path planning
2- Computer vision
3- Proximal Sensors

طبقه‌بندی می‌شوند زیرا یک رابط انسان-هوش مصنوعی هستند که توضیح را به روشی که انسان‌ها می‌توانند درک کنند، گزارش می‌دهند. آن‌ها اغلب در حوزه یادگیری ماشین قرار دارند. (Beucher et al. (2022 از یک روش هوش مصنوعی توضیح‌پذیر به نام مقادیر شپلی^۱ برای درک چگونگی عملکرد یک مدل یادگیری عمیق پیچیده در طبقه‌بندی خاک اسید-سولفات استفاده کردند. مقادیر شپلی از نظریه بازی‌های مشارکتی گرفته شده است و توسط Lloyd Shapley در سال ۱۹۵۳ معرفی شدند. در یادگیری ماشین، این روش برای توضیح سهم هر ویژگی یا خصیصه^۲ در پیش‌بینی یک مدل استفاده می‌شود. به عبارت ساده هر ویژگی مثل یک بازیکن در بازی است و مقادیر شپلی نشان می‌دهد که این بازیکن چقدر در نتیجه نهایی (پیش‌بینی مدل) نقش داشته است.

قابلیت‌های سنجش و تعامل در هوش مصنوعی، زمینه‌ای پویا و چندرشته‌ای در علوم خاک پدید آورده‌اند. از ربات‌هایی که خاک را نمونه‌برداری می‌کنند تا مدل‌های زبانی که اسناد علمی را می‌خوانند و از حسگرهایی که کیفیت خاک را اندازه می‌گیرند تا الگوریتم‌هایی که پیش‌بینی‌های خود را توضیح می‌دهند همه و همه نشان از حرکتی پرشتابی به سوی خاک‌شناسی هوشمند دارند. این تحولات نه تنها دقت و سرعت پژوهش را افزایش می‌دهند، بلکه درک ما را از پیچیدگی‌های خاک تعمیق می‌بخشند.

یادگیری و پیش‌بینی

یادگیری ماشین، شاخه‌ای از هوش مصنوعی است که بر طراحی الگوریتم‌ها و مدل‌های آماری تمرکز دارد؛ مدل‌هایی که ماشین‌ها را قادر می‌سازند تا بدون برنامه‌نویسی صریح و صرفاً بر اساس داده‌ها، الگوهای را بیاموزند و وظایف خاصی را انجام دهند. در حال حاضر، یادگیری ماشین را می‌توان مهم‌ترین و رایج‌ترین جلوه هوش مصنوعی در علوم خاک دانست (Padarian et al., 2020). کاربردهای یادگیری ماشین در علوم خاک را

می‌توان در دو دسته کلی یادگیری نظارت‌شده و یادگیری نظارت‌نشده جای داد. در یادگیری نظارت‌شده، مدل با مجموعه‌ای از داده‌های برچسب‌گذاری شده آموزش می‌بیند؛ یعنی روابط بین ورودی‌ها و خروجی‌های شناخته‌شده را فرا می‌گیرد تا بتواند خروجی داده‌های جدید و ناشناخته را پیش‌بینی کند. الگوریتم‌های معروف در این دسته شامل شبکه‌های عصبی مصنوعی و جنگل‌های تصادفی هستند. برای نمونه، (de Oliveira et al. (2021 از چهار الگوریتم یادگیری نظارت‌شده برای پیش‌بینی تغییرات مکانی-زمانی رطوبت خاک در جنگل‌های گرمسیری برزیل استفاده کردند. (Minasny et al. (2021 با بهره‌گیری از شبکه‌های عصبی، مدلی برای تخمین منحنی نگهداشت آب خاک و هدایت هیدرولیکی توسعه دادند. در این میان، دو حوزه نوظهور بیش از سایرین مورد توجه قرار گرفته است یادگیری عمیق که از شبکه‌هایی با لایه‌های متعدد استفاده می‌کند تا بتواند مفاهیم پیچیده و انتزاعی را از داده‌ها استخراج کند و مدل‌سازی گروهی که با ترکیب چندین مدل، تلاش می‌کند پیش‌بینی‌هایی دقیق‌تر و پایدارتر ارائه دهد؛ روشی که با مفاهیمی همچون تقویت^۳، دسته‌بندی^۴ و انباشت مدل^۵ شناخته می‌شود. (Brungard et al. (2021 مجموعه‌ای از مدل‌های جنگل تصادفی را با زیرمجموعه‌های داده‌های منطقه‌ای در حوضه رودخانه کلرادو آموزش دادند تا بتوانند کلاس‌های عمق خاک را با دقت بیشتری پیش‌بینی کنند. (Ayoubi and Ghavami (2025 از چند روش یادگیری ماشین برای پیش‌بینی فاکتور فرسایش‌پذیری خاک استفاده کردند و گزارش کردند که مدل جنگل تصادفی دارای بیشترین دقت می‌باشد.

یادگیری نظارت‌نشده با داده‌های برچسب‌گذاری نشده سروکار دارد. هدف در اینجا، کشف الگوهای پنهان، ساختارهای درونی و شباهت‌ها میان داده‌ها است. روش‌هایی مانند خوشه‌بندی و تحلیل همبستگی در این گروه جای می‌گیرند. (De Bruin and Stein (1998 با

4- Bagging
5- Model stacking

1- Shapley values
2- Feature
3- Boosting

استدلال و تصمیم‌گیری

حوزه استدلال و تصمیم‌گیری به الگوریتم‌ها و برنامه‌هایی مربوط می‌شود که استدلال (یعنی فرمول‌بندی و ساختاردهی) متخصصان یا کارشناسان را به منظور حل مسائل به‌خوبی تعریف‌شده، شبیه‌سازی می‌کنند. این حوزه شامل مراحل نمایش دانش و استنتاج با استفاده از قواعد نمادین و اعداد، و همچنین جستجو در میان مجموعه‌های مختلفی از راه‌حل‌های ممکن است. یکی از نخستین و مهم‌ترین حوزه‌های کاربرد هوش مصنوعی در علوم خاک، سیستم‌های خبره یا همان سیستم‌های مبتنی بر دانش بوده است. این سیستم‌ها برنامه‌هایی دارای دانش ساختاریافته‌ای هستند و می‌توان از آن‌ها برای شبیه‌سازی رفتار متخصصان در حل یک مسئله استفاده کرد. در دهه ۱۹۸۰، سیستم‌های خبره در مرکز توجه تحقیقات هوش مصنوعی در علوم خاک قرار داشتند. به گفته McCracken and Cate (1986)، سیستم‌های خبره را می‌توان قضاوت رایانه‌ای و تجربیات عملی متخصصان دانست. در واقع ایده این است که رایانه‌ها بتوانند دانش، قواعد، و تجربه متخصصان انسانی را در قالب الگوریتم ذخیره کنند و سپس مانند یک متخصص یا خبره در مورد داده‌های جدید قضاوت یا تصمیم‌گیری کنند. این سیستم‌ها همراه با فناوری‌های مرتبط مانند مهندسی دانش، موتورهای استنتاج و سیستم‌های پشتیبانی تصمیم‌گیری به‌طور گسترده برای کاربردهایی نظیر تصمیم‌گیری زراعی (Smaling and Fresco, 1993) و طبقه‌بندی خاک (Dale et al., 1989; Galbraith et al., 1998; Galbraith and Bryant, 1998) مورد استفاده قرار گرفتند. در سال‌های اخیر نیز، کاربردهای جدیدی از جمله در ارزیابی کارکرد خاک و سنجش کیفیت خاک برای این دسته از ابزارها توسعه یافته است (Debeljak et al., 2019).

علوم شناختی^۲ و بازنمایی دانش^۳ در کاربردهای خود در علوم خاک ارتباط نزدیکی با یکدیگر دارند. پایگاه دانش سیستم‌های خبره از دانش اکتشافی^۴ و رسمی تشکیل

استفاده از الگوریتم میانگین سی فازی^۱، موفق شدند ویژگی‌های خاک-زمین‌نما را در یک حوضه زهکشی کوچک در جنوب اسپانیا دسته‌بندی کنند. یادگیری ماشین در برخی موارد با حوزه‌هایی همچون تشخیص الگو و داده‌کاوی نیز همپوشانی دارد.

تشخیص الگو، به‌ویژه زمانی که با یادگیری نظارت‌شده ترکیب می‌شود، برای شناسایی و دسته‌بندی الگوها در داده‌ها به‌کار می‌رود. با این حال، تمرکز اصلی آن بر شناسایی کلاس‌های جدید و ناشناخته است. Saadatpour et al. (2011) از این رویکرد برای ارزیابی پتانسیل فرسایش خاک در حوزه‌های آبخیز اتیوپی بهره گرفتند.

در سوی دیگر، داده‌کاوی، فراتر از پیش‌بینی، به دنبال کشف روابط، همبستگی‌ها و ساختارهای پنهان در مجموعه‌های داده‌ای بزرگ است. این حوزه، ضمن بهره‌گیری از تکنیک‌های یادگیری ماشین، به تحلیل‌های توصیفی و اکتشافی نیز می‌پردازد و در بسیاری از موارد از ابزارهای آماری و پایگاه‌های داده نیز استفاده می‌کند. از جمله نمونه‌های شاخص در این زمینه، می‌توان به مطالعات Behrens and Scholten (2006) و Bui et al. (2006) اشاره کرد.

یادگیری ماشین، در قالب روش‌های گوناگون، به بخش جدایی‌ناپذیری از پژوهش‌های نوین علوم خاک تبدیل شده است. از پیش‌بینی رطوبت و کربن خاک گرفته تا طبقه‌بندی چشم‌اندازها و تحلیل کیفیت خاک، این فناوری توانسته است جایگاهی کلیدی برای خود باز کند. به‌ویژه در جهانی که داده‌ها به‌سرعت در حال انباشت هستند، یادگیری ماشین ابزاری نیرومند برای درک، پیش‌بینی و مدیریت سامانه‌های خاکی پیچیده به شمار می‌رود.

3- Knowledge representation
4- Heuristic

1- Fuzzy c-means
2- Cognitive science

شده است. بازنمایی دانش، پیوند میان سیستم استدلال خبره و قواعد نمادین موجود در سیستم‌های خبره است. بازنمایی دانش از آناتومی و گراف‌های مفهومی استفاده می‌کند. در موازات آن، نقش علوم شناختی آن است که فرآیندهای ذهنی متخصصان را که از طریق آن مشاهده‌ها خود را رمزگذاری و سازمان‌دهی می‌کنند، کشف و توصیف کند (McCracken and Cate, 1986). علوم شناختی و بازنمایی دانش در مواردی که رسمی‌سازی دانش امکان‌پذیر است، به توسعه سیستم‌های خبره کمک می‌کنند.

سنجش و تعامل


موضوع ۱: پردازش تصاویر دیجیتال

در مجموعه مقالات مرتبط با حوزه سنجش و تعامل، تنها تعداد محدودی به‌صورت صریح یا ضمنی به ترکیب یادگیری ماشین با روش‌های تصویربرداری پیشرفته برای توصیف ساختار خاک اشاره کرده‌اند. تمرکز اغلب این مطالعات بر تحلیل الگو و طبقه‌بندی تصاویر به‌دست‌آمده از تجهیزات تصویربرداری تخصصی همچون طیف‌سنجی جرمی یون‌های ثانویه در مقیاس نانو^۱، توموگرافی کامپیوتری با اشعه ایکس^۲، و رزونانس مغناطیسی هسته‌ای^۳ بوده است. به‌عنوان مثال، در توموگرافی اشعه ایکس، تصویر حاصل از یک نمونه خاک، شامل مجموعه‌ای از مقادیر خاکستری است که به وُکسل‌های^۴ منفرد اختصاص داده شده‌اند. این مقادیر با اعمال آستانه‌گذاری به تصویر دودویی (سیاه-سفید)^۵ تبدیل می‌شوند تا مناطق متخلخل و مواد جامد از یکدیگر تفکیک شوند. برای طبقه‌بندی این ساختارهای تصویری، از الگوریتم‌های یادگیری ماشین و

یادگیری عمیق بهره گرفته شده است. به‌عنوان نمونه، در مطالعه (Lavrukhin et al. (2021، تصاویر سه‌بعدی از نمونه‌های خاک به برش‌هایی دوبعدی تفکیک‌شده، بین مجموعه‌های آموزش و آزمون تقسیم شدند و سپس به مدل‌های شبکه عصبی داده شدند تا هر پیکسل یا وُکسل را در یکی از فازهای تخلخل (مانند خلأ، مواد آلی یا معدنی) طبقه‌بندی کنند. مطالعه‌ای دیگر با استفاده از توموگرافی کامپیوتری با اشعه ایکس به بررسی توزیع سه بعدی تخلخل خاک پرداخته است که در آن انواع منافذ درشت شامل دالان‌های کرم خاکی، مجاری ریشه و منافذ درون خاکدانه‌ای قابل تشخیص هستند (شکل ۳). منافذ درشت در افق‌های A_{p1} و A_{p2} و به‌ویژه در افق B_t پیوستگی عمودی بیشتری داشتند، درحالی‌که منافذ درون خاکدانه‌ای پراکنده‌تر هستند و پیوستگی کم‌تری دارند. تخلخل ناشی از منافذ درشت از حدود ۱۵ درصد در سطح به نزدیک دو درصد در عمق بذركاری کاهش یافته و در افق B_t اندکی افزایش یافته است. این شبکه پیچیده منافذ درشت نقش مهمی در جریان و انتقال آب و مواد در خاک دارد (Luo et al., 2008). مطالعات دیگری از جمله (Han et al. (2019 و (Ferreira et al. (2022 نیز از رویکردهای مشابه برای تحلیل تصاویر پیشرفته خاک و استخراج اطلاعات ساختاری دقیق بهره گرفته‌اند. این دستاوردها مسیر را برای بررسی‌های دقیق‌تر، کم‌هزینه‌تر و غیرمخرب‌تر از خصوصیات ریزساختاری خاک هموار کرده‌اند و جایگاه ابزارهای هوش مصنوعی را در تفسیر داده‌های تصویربرداری پیچیده، برجسته ساخته‌اند.

4- Voxel
5- Binary

1- Nanoscale secondary ion Mass Spectrometry (NanoSIMS)
2- X-ray CT computed tomography (X-ray CT)
3- Nuclear magnetic resonance (NMR)



شکل ۳- تصویر سه بعدی از (a) تخلخل کلی ستون خاک که با روش ساده شده تعیین شده است، همراه با حباب‌های هوای محبوس (به رنگ صورتی) و (b) شبکه منافذ درشت بخش بندی شده (با تخلخل بیش از ۶۵ درصد) در ستون خاک (Luo et al., 2008)

Figure 3- A three-dimensional visualization of (a) the overall soil column porosity determined by the simplified method, along with entrapped air bubbles (in pink), and (b) the segmented macropore network (porosity > 65%) in the soil column (Luo et al., 2008)

خاک از جمله تعامل خاک و ریشه، ساختار سیستم ریشه، فعالیت میکروارگانیسم‌های خاک، توزیع لانه‌های کرم خاکی و تشخیص سنگ‌ریزه‌ها در بافت خاک را دارند. از جمله تکنیک‌های رایج یادگیری عمیق مورد استفاده در این زمینه می‌توان به یادگیری جانشین^۱ (Wieland et al., 2021)، شبکه عمیق کانولوشنی با یادگیری انتقالی^۲ (Douarre et al., 2018) و شبکه‌های رمزگذار-رمزگشای چند وضوحی^۳ (Soltaninejad et al., 2020) اشاره کرد. یادگیری جانشین یک رویکرد در یادگیری ماشین است که در آن به جای استفاده مستقیم از یک مدل اصلی پیچیده و پرهزینه، یک مدل ساده‌تر (مدل جانشین) آموزش داده می‌شود تا رفتار آن مدل اصلی را تقریب بزند. این کار باعث می‌شود پیش‌بینی‌ها سریع‌تر و ارزان‌تر انجام شوند، درحالی‌که دقت قابل قبولی هم حفظ می‌شود.

در برخی مطالعات، از الگوریتم‌های یادگیری ماشین و یادگیری عمیق در پردازش تصاویر حاصل از توموگرافی اشعه ایکس (نه صرفاً برای تشخیص فازهای جامد و منفذی، بلکه برای اهداف پیشرفته‌تر مانند بررسی ساختارهای زیستی و شیمیایی خاک) استفاده شده است. یکی از کاربردهای رایج در این زمینه، تخمین توزیع ریشه‌های گیاه در خاک است. به عنوان مثال، در مطالعات (Douarre et al., 2018) و (Smith et al., 2020)، از یادگیری عمیق برای استخراج معماری سیستم ریشه از داده‌های تصویری توموگرافی کامپیوتری با اشعه ایکس بهره گرفته شده است. (Hou et al., 2022) چهار گروه اصلی از الگوریتم‌های تقسیم‌بندی ریشه را معرفی کردند که الگوریتم‌های یادگیری عمیق یکی از مهم‌ترین آن‌ها بودند. این الگوریتم‌ها قابلیت بررسی طیف وسیعی از ویژگی‌های

3- Multi-resolution encoder-decoder networks

1- Surrogate learning

2- Convolutional deep network with transfer learning

همه این روش‌ها زیرمجموعه‌ای از شبکه‌های عصبی مصنوعی هستند که برای کار با تصاویر حجیم و پیچیده سه‌بعدی، مانند داده‌های توموگرافی کامپیوتری با اشعه ایکس بسیار مؤثر هستند. در کنار این روش‌ها، ابزارهای تصویربرداری پیشرفته‌تری نیز به کار رفته‌اند. Schweizer et al. (2018) با استفاده از یک الگوریتم یادگیری ماشین چندکاناله، ترکیب میکروسکوپی پوشش مواد آلی بر روی ذرات خاک را با داده‌های طیف‌سنجی جرمی یون‌های ثانویه در مقیاس نانو بررسی کردند. Steffens et al. (2017) نیز از تکنیک طیف‌سنجی جرمی یون‌های ثانویه در مقیاس نانو و طبقه‌بندی نظارت‌شده برای مطالعه ویژگی‌های یونی خاکدانه‌های دست‌نخورده بهره بردند.

موضوع ۲: سنجش از نزدیک خاک

موضوع اصلی در این بخش، بهره‌گیری از یادگیری ماشین و یادگیری عمیق برای پردازش داده‌های حاصل از سنجش از نزدیک خاک^۱ است. سنجش از نزدیک به معنای اندازه‌گیری ویژگی‌های خاک با استفاده از حسگرهایی است که در فاصله کمتر از دو متر یا درون خود خاک قرار دارند. پیشرفت این حوزه هم‌زمان با رشد فناوری‌های دیجیتال (Wadoux and McBratney, 2021) و توسعه حسگرهای جدیدی بود که داده‌هایی ارزان و فراوان تولید می‌کنند. این داده‌ها بستر مناسبی برای استقرار مدل‌های یادگیری ماشین فراهم کردند. مطالعه‌ای پیشگام در این زمینه توسط Viscarra Rossel and Behrens (2010) انجام شد، جایی که چندین الگوریتم یادگیری ماشین برای پیش‌بینی کربن آلی، درصد رس و پهاش از داده‌های طیفی بازتاب خاک مورد مقایسه قرار گرفتند. آن‌ها نشان دادند که مدل‌ها تنها از تعداد کمی از طول‌موج‌ها استفاده می‌کنند، که این طول‌موج‌ها با ارتعاشات مولکولی گروه‌های آلی و معدنی خاک در ارتباط بودند. بسیاری از مطالعات مشابه از تکنیک‌های هوش مصنوعی

برای پردازش طیف‌های مادون‌قرمز و به دست آوردن اطلاعات از مجموعه داده‌های طیفی با ابعاد بالا و هم‌بسته استفاده کرده‌اند. (Nawar and Mouazen, 2022) از چهار الگوریتم مختلف یادگیری ماشین در قالب یک مدل ترکیبی (فرامدل) برای پیش‌بینی هم‌زمان چند ویژگی خاک استفاده کردند و نتایج حاصل را با خروجی‌های یک شبکه عصبی مصنوعی مقایسه کردند. Behzadipour et al. (2023) با استفاده از حسگرهای بی‌سیم و با به‌کارگیری شبکه عصبی مصنوعی رطوبت خاک گلخانه را پیش‌بینی کردند و نتایج مثبتی به دست آوردند. مطالعات دیگری (Ng et al., 2020; Xu et al., 2022; Gruszczyński and Gruszczyński, 2022) نیز نشان داده‌اند که اغلب الگوریتم‌های رایج یادگیری ماشین برای تحلیل طیف‌های خاک به کار گرفته شده است. نتایج مطالعه میدانی Mehrabi Gohari et al. (2020a) در جنوب‌شرق ایران نشان داد که استفاده از شبکه‌های عصبی مصنوعی در ترکیب با سنجش طیفی مرئی-مادون‌قرمز نزدیک^۲ دقت بالاتری نسبت به رگرسیون حداقل مربعات جزئی در پیش‌بینی اجزای بافت خاک دارد. این برتری به توانایی مدل‌های یادگیری ماشین در شبیه‌سازی روابط غیرخطی میان داده‌های طیفی و خصوصیات خاک نسبت داده شده است. در مطالعه دیگر Mehrabi Gohari et al. (2020b) از داده‌های طیفی محدوده مرئی - مادون قرمز برای برآورد مقدار ماده آلی، کربنات‌ها و درصد گچ سطح خاک استفاده و گزارش کردند که پیش‌بینی مدل برای درصد گچ و ماده آلی در کلاس خوب و برای کربنات‌ها در کلاس ضعیف قرار گرفت. با این حال، مطالعات جدیدتر به‌طور فزاینده‌ای بر یادگیری عمیق تمرکز دارند. مطالعات Padarian et al., 2019; Shen and Viscarra Rossel 2021 به حل چالش‌های خاص کار با داده‌های بزرگ خاک با استفاده از یادگیری انتقالی یا تفسیر مدل‌های پیچیده اختصاص دارند. Shen et al. (2022) به محلی‌سازی مدل‌های طیف‌سنجی پرداختند، Wadoux, 2023; Viscarra Rossel et al., 2022 به تفسیر خروجی‌های مدل‌های یادگیری عمیق

پیچیده توجه داشتند. علاوه بر طیف‌سنجی، برخی مطالعات از الگوریتم‌های هوش مصنوعی برای تحلیل سایر داده‌های سنجش از نزدیک خاک نیز استفاده کرده‌اند. *Priori et al.* (2014) از دو الگوریتم یادگیری ماشین برای پیش‌بینی بافت خاک با استفاده از داده‌های رادیومتری در تاکستان‌های ایتالیا بهره گرفتند. *Biney et al.* (2022) از فلورسانس اشعه ایکس قابل حمل^۱ برای پیش‌بینی میزان آرسنیک در خاک‌های جمهوری چک استفاده کردند. آن‌ها دریافتند که ترکیب داده‌های آزمایشگاهی فلورسانس اشعه ایکس قابل حمل با طیف‌سنجی میدانی و مدل‌های گروهی، پیش‌بینی بسیار دقیقی از سطح آرسنیک ارائه می‌دهد. *Ji et al.* (2019) نیز رویکرد تلفیقی مشابهی را برای ادغام داده‌های پرتو گاما، رسانایی الکتریکی و طیف‌های مرئی و مادون‌قرمز نزدیک به کار بردند. *Romero-Ruiz et al.* (2024) داده‌های حاصل از القای الکترومغناطیسی با خوشه‌بندی نظارت‌شده^۲ را تلفیق کردند تا الگوهای تراکم خاک را شناسایی کنند. از دیگر کاربردهای هوش مصنوعی در سنجش از نزدیک خاک، می‌توان به استفاده از مدل‌های تحلیل طیفی-یادگیری ماشین همراه با متغیرهای مکانی برای تخمین ویژگی‌های شیمیایی خاک مانند پ‌هاش و شوری خاک توسط *Parviz et al.* (2024) اشاره کرد.

موضوع ۳: سنجش‌ازدور خاک

مقالاتی که در این موضوع دسته‌بندی می‌شوند، معمولاً داده‌های سنجش‌ازدور را با الگوریتم‌های یادگیری ماشین یا یادگیری عمیق ترکیب می‌کنند تا ویژگی‌های خاک را ارزیابی کنند و یا از داده‌های سنجش‌ازدور به عنوان منبع اطلاعات ثانویه در نقشه‌برداری رقومی خاک استفاده کنند. *Mulder et al.* (2011) به بررسی این دو رویکرد پرداختند و ویژگی‌های خاکی را که می‌توانند با طیف‌سنجی هوایی و فضایی شناسایی شوند، فهرست کردند. تحقیقات بعدی اغلب از همین چارچوب مفهومی بهره گرفته و حسگرهای مختلف را در ترکیب با مدل‌های یادگیری

ماشین مورد استفاده قرار داده‌اند. یکی از مطالعات نمونه در این زمینه، توسط *Pasolli et al.* (2014) انجام شده است. در این مطالعه، از تصاویر رادار روزنه مصنوعی^۳ برای تخمین رطوبت خاک در منطقه‌ای کوهستانی در شمال ایتالیا استفاده شد. مدل پیش‌بینی بر اساس رگرسیون بردار پشتیبان (SVR)^۴ و متغیرهای کمکی مانند مدل رقومی ارتفاع^۵ ساخته شد و با داده‌های میدانی کالیبره شد. در نهایت، این مدل با استفاده از داده‌های پردازش‌شده تصاویر رادار روزنه مصنوعی، برای پایش زمانی رطوبت خاک در منطقه به کار گرفته شد. *Nouraki et al.* (2023) با استفاده از داده‌های سنجش از دور نوری-حرارتی و مدل‌های یادگیری ماشین به مدل‌سازی زمانی-مکانی رطوبت خاک پرداختند. مطالعات متعددی نشان داده‌اند که ویژگی‌هایی مانند بافت خاک، ظرفیت تبادل کاتیونی، کربن آلی، شوری و غلظت عناصر غذایی را می‌توان با تصویربرداری خاک‌های لخت و الگوریتم‌های یادگیری ماشین تخمین زد. *Chang and Islam* 2000 از شبکه‌های عصبی برای پیش‌بینی بافت خاک استفاده کردند؛ *Wang et al.* (2020) به بررسی شوری خاک با سنجش‌ازدور پرداختند؛ *Zhang et al.* (2023) عناصر غذایی را با همین رویکرد مدل‌سازی کردند؛ *Rezaei et al.* (2023) از جنگل تصادفی استفاده کردند و *Odebiri et al.* (2021) یادگیری عمیق را برای تحلیل ویژگی‌های خاک با داده‌های سنجش‌ازدور به کار گرفتند. مروری جامع بر استفاده از یادگیری ماشین برای تخمین ویژگی‌های خاک بر اساس داده‌های سنجش‌ازدور در مقاله *Diaz-Gonzalez et al.* (2022) ارائه شده است. این بررسی بخش بزرگی از مطالعاتی را نشان داد که در آن‌ها سنجش‌ازدور منبع اطلاعاتی برای مدل رقومی سطح^۶ است. اگرچه این حوزه تا حدودی با موضوع یادگیری و پیش‌بینی همپوشانی دارد، اما تمرکز ویژه آن بر استفاده از داده‌های سنجش‌ازدور، آن را به حوزه‌ای مستقل تبدیل کرده است. یکی از چالش‌های کلیدی در این زمینه،

4- Support vector regression (SVR)

5- Digital elevation model (DEM)

6- Digital surface model (DSM)

1- Portable X-ray fluorescence (pXRF)

2- Supervised clustering

3- Synthetic aperture radar (SAR)

تأثیر پوشش گیاهی است که مشاهده مستقیم خاک را با مشکل مواجه می‌کند و در نتیجه، تخمین‌ها معمولاً محدود به لایه سطحی خاک هستند. برای رفع این مشکل، سنجش‌ازدور با داده‌های نمونه‌برداری شده خاک و متغیرهای کمکی محیطی ترکیب می‌شود. در این راستا، هوش مصنوعی نقش کلیدی در توسعه سیستم‌های استنتاجی یا توابع انتقالی ایفا می‌کند. نمونه‌هایی از این رویکرد را می‌توان در مطالعات Lacoste et al. (2011)، Bao et al. (2022) و de Sousa Mendes et al. (2024) مشاهده کرد. در این مطالعات، داده‌های سنجش‌ازدور به صورت مستقیم یا با استفاده از شاخص‌هایی مانند شاخص تفاضلی نرمال‌شده پوشش گیاهی^۱ وارد مدل شده‌اند تا عملکرد پیش‌بینی ویژگی‌های خاک بهبود یابد.

یادگیری و پیش‌بینی

موضوع ۱: نقشه‌برداری رقومی از کلاس‌های خاک

یکی از حوزه‌های اصلی پژوهش در کاربرد هوش مصنوعی در علوم خاک، توسعه و استفاده از الگوریتم‌های یادگیری ماشین برای نقشه‌برداری از کلاس‌های خاک و تفکیک نقشه‌های سنتی نوع خاک مبتنی بر چندضلعی‌ها است. مطالعات اولیه در این زمینه به تحقیقات Cialella et al. (1997) و Bui et al. (1999) بازمی‌گردد. این پژوهش‌ها با استفاده از درخت‌های طبقه‌بندی، ارتباط میان داده‌های نمونه‌برداری شده از خاک و متغیرهای کمکی محیطی را برای پیش‌بینی کلاس‌های زهکشی و واحدهای نقشه خاک تحلیل کردند. یکی از نمونه‌های برجسته در این زمینه، مطالعه Behrens et al. (2005) است. در این تحقیق، شبکه‌های عصبی مصنوعی همراه با مجموعه‌ای بزرگ از ویژگی‌های زمین‌ریخت‌شناسی، زمین‌شناسی و کاربری زمین، برای پیش‌بینی واحدهای خاک در منطقه‌ای در غرب آلمان به کار گرفته شدند. در سال‌های اخیر، این حوزه با پیشرفت‌های روش‌شناختی قابل توجهی روبرو شده است. از جمله می‌توان به توسعه پیش‌بینی‌های احتمالاتی و

محاسبه فاصله‌های طبقه‌بندی بین کلاس‌های خاک اشاره کرد (Minasny and McBratney, 2007, Odgers et al., 2015). همچنین، مطالعات موردی گسترده‌ای با استفاده از الگوریتم‌های متنوع یادگیری ماشین انجام شده‌اند (Brungard et al., 2015, Heung et al., 2016). یکی دیگر از جریان‌های نوین تحقیقاتی در این حوزه، مربوط به به‌روزرسانی نقشه‌های خاک سنتی با استفاده از یادگیری ماشین و روش‌های داده‌محور است. این رویکردها شامل موارد زیر هستند: الف) تفکیک واحدهای نقشه خاک موجود برای افزایش تفکیک‌پذیری و وضوح؛ ب) به‌روزرسانی نقشه‌های موجود با داده‌های جدید و ج) هماهنگ‌سازی و ترکیب چندین نقشه سنتی خاک با کمک مدل‌های یادگیری ماشین. یک الگوریتم برجسته در این زمینه توسط Odgers et al. (2014) توسعه یافت. در این روش، ابتدا نمونه‌هایی به صورت تصادفی از واحدهای چندضلعی خاک انتخاب می‌شوند و سپس با استفاده از متغیرهای کمکی محیطی و درخت تصمیم‌گیری، مدلی برای پیش‌بینی نوع خاک در آن نقاط ساخته می‌شود. نتایج مدل، اطلاعات احتمالاتی برای تولید نقشه‌های خاکی دقیق‌تر ارائه می‌دهد. این روش توسط Chaney et al. (2016) برای تفکیک نقشه خاک ایالات متحده آمریکا به کار رفت. Vincent et al. (2018) آن را با قوانین خاک-چشم‌انداز مبتنی بر دانش کارشناسی ترکیب کردند تا نقشه‌های دقیق‌تری برای منطقه بریتانی در فرانسه تهیه کنند. Mahmoudi et al. (2014) گزارش کرده‌اند که اگرچه روش‌های یادگیری ماشین در نقشه‌برداری رقومی خاک توانایی قابل قبولی در پیش‌بینی کلاس‌های خاک و ویژگی‌های سطحی خاک دارند، اما با حرکت به سطوح پایین‌تر رده‌بندی خاک (زیرگروه و خانواده)، دقت مدل‌ها به‌ویژه در مناطق مسطح و کم‌شیب به‌طور معنی‌داری کاهش یافته و عدم قطعیت افزایش می‌یابد. یکی از چالش‌های رایج در این حوزه، عدم توازن در کلاس‌های خاک هنگام نمونه‌برداری است. برای غلبه بر این مشکل، پژوهشگران

روش‌هایی برای تخصیص بهینه نقاط نمونه‌برداری پیشنهاد داده‌اند تا دقت مدل‌ها بهبود یابد و کلاس‌های نادر نیز به‌درستی شناسایی شوند (Sharififar et al., 2019; Liu et al., 2020).

موضوع ۲: ارزیابی الگوریتم‌های یادگیری ماشین

در این موضوع، تمرکز اصلی بیشتر مقالات پژوهشی بر مقایسه و ارزیابی الگوریتم‌های مختلف یادگیری ماشین برای رسیدن به اهداف خاص در حوزه علوم خاک است. اگرچه این مطالعات با موضوعات دیگر مانند نقشه‌برداری خاک یا حسگری همپوشانی دارند، اما به دلیل تمرکز ویژه آن‌ها بر ارزیابی عملکرد الگوریتم‌ها، به‌عنوان یک حوزه پژوهشی مستقل شناخته می‌شوند. بخش عمده‌ای از این مطالعات، به دقت پیش‌بینی الگوریتم‌ها برای نقشه‌برداری ویژگی‌های خاک یا تحلیل داده‌های حسگر می‌پردازند. (Xu et al. (2022 در مطالعه‌ای با هدف نقشه‌برداری مقدار آهن در پروفیل‌های دست‌نخورده خاک، چهار الگوریتم یادگیری ماشین را در کنار تصویربرداری فرایندی مورد ارزیابی قرار دادند. دقت این الگوریتم‌ها با استفاده از دو شاخص آماری اعتبارسنجی شد و نتایج با یک مدل خطی سنتی مقایسه گردید. این مطالعه نشان داد که الگوریتم ماشین بردار پشتیبان^۱، هم به دلیل دقت بالا و هم هزینه محاسباتی پایین، گزینه مناسبی برای این هدف است. Zhang et al. (2020) عملکرد پنج الگوریتم یادگیری ماشین را برای پیش‌بینی کلاس‌ها یا مقادیر پیوسته بافت خاک در منطقه‌ای از چین مقایسه کردند. یافته‌های آن‌ها نشان داد که جنگل تصادفی در دقت طبقه‌بندی و پیش‌بینی بهتر از سایر الگوریتم‌ها عمل کرده، درحالی‌که گرادیان بوستینگ^۲ از نظر سرعت و کارایی محاسباتی برتری دارد. مطالعات متعددی در این زمینه منتشر شده‌اند که الگوریتم‌های یادگیری ماشین را برای طیفی از کاربردها مثل نقشه‌برداری حساسیت به فرسایش خاک (Chakraborty and Pal 2023)، پیش‌بینی ویژگی‌های خاک از طیف‌های

مرئی و مادون‌قرمز نزدیک^۳ (Gruszczyński and Gruszczyński 2022) و تخمین شوری خاک از طریق طیف‌سنجی میدانی (Wang et al., 2019). مقایسه می‌کنند. در مجموع، این مطالعات حاکی از آن هستند که هیچ الگوریتم واحدی نمی‌تواند در همه موقعیت‌ها بهترین عملکرد را داشته باشد. این نتیجه در مقاله Khaledian and Miller (2020) نیز تأیید شده است. در آن پژوهش، الگوریتم‌های یادگیری ماشین بر پایه پنج معیار برای اهداف مختلف نقشه‌برداری خاک مورد مقایسه قرار گرفتند و در نهایت نتیجه‌گیری شد که انتخاب الگوریتم مناسب به عوامل متعددی همچون نوع داده‌ها و هدف پژوهش بستگی دارد. (Parsaie et al. (2025) نیز با بهره‌گیری از الگوریتم‌های یادگیری ماشین به نقشه‌برداری رقومی مقاومت فروروی و برشی خاک پرداختند و گزارش کردند که گرادیان بوستینگ نسبت به سایر الگوریتم‌ها دقت بیشتری داشته است.

موضوع ۳: توابع انتقالی

یکی از محورهای اصلی در این حوزه، توسعه توابع انتقالی خاک^۴ با استفاده از الگوریتم‌های یادگیری ماشین است. در بسیاری از مطالعات، هوش مصنوعی ابزاری برای دستیابی به پیش‌بینی‌های دقیق‌تر تلقی شده است. (Pachepsky and Rawls (2004 دو رویکرد اصلی برای ساخت توابع انتقالی خاک را معرفی می‌کنند: (۱) استفاده از مدل‌های رگرسیون آماری (خطی یا غیرخطی) و (۲) بهره‌گیری از تکنیک‌های داده‌کاوی و الگوریتم‌های یادگیری ماشین. در میان روش‌های جدید، شبکه‌های عصبی مصنوعی از دهه ۱۹۸۰ به دلیل توانایی در مدل‌سازی روابط پیچیده و غیرخطی بین داده‌های ورودی و خروجی، به‌طور گسترده‌ای مورد استفاده قرار گرفته‌اند (Haghverdi et al., 2012). پژوهش‌های متعددی نشان داده‌اند که عملکرد پیش‌بینی شبکه‌های عصبی نسبت به مدل‌های رگرسیونی سنتی برتر است (Minasny and McBratney

3- Near-infrared spectroscopy (NIR)

4- Pedotransfer function (PTF)

1- Support vector machine (SVM)

2- Extreme gradient boosting (XGBoost)

پشتیان، جنگل تصادفی و سیستم استنتاج عصبی-فازی-تطبیقی نفوذ آب در خاک را بررسی کردند. Hasanvand et al. (2025) در مطالعه‌ای بر روی نفوذپذیری خاک سطحی الگوریتم‌های یادگیری را به عنوان ابزاری دقیق و قابل اعتماد معرفی کردند و مدل‌سازی با آن‌ها را به عنوان روشی نو و ابزاری قدرتمند برای صرفه جویی در هزینه و زمان برای تعیین میزان نفوذپذیری و محاسبه رواناب خروجی از منطقه دانستند. Haghverdi et al. (2012) و Jalilvand et al. (2023) از الگوریتم ژنتیک، شبکه عصبی مصنوعی، شبکه‌های پرسپترون و توابع انتقالی خاک برای مدل‌سازی منحنی مشخصه رطوبت خاک استفاده کردند. در مطالعات دیگری در ایران Namdar et al. (2011) و Sedaghat et al. (2022) برای برآورد رطوبت خاک کارایی شبکه عصبی مصنوعی و رگرسیون‌بردار پشتیان را مورد ارزیابی قرار دادند. Akpa et al. (2016) از الگوریتم جنگل تصادفی برای تخمین چگالی ظاهری و ظرفیت تبادل کاتیونی در عمق‌های مختلف خاک استفاده کرده و نشان دادند که مدل‌های ساخته‌شده با جنگل تصادفی، در مقایسه با مدل‌های خطی سنتی عملکرد بهتری دارند. در یک مرور جامع، Van Looy et al. (2017) مروری بر انواع خواص خاک قابل پیش‌بینی با استفاده از توابع انتقالی خاک، مدل‌های یادگیری ماشین (نزدیک‌ترین همسایه، ماشین‌های بردار پشتیان، درخت‌های تصمیم، جنگل تصادفی و درخت‌های رگرسیونی تقویت‌شده)، و شاخص‌های ارزیابی این توابع ارائه کردند که به درک بهتر عملکرد مدل‌ها در شرایط مختلف کمک می‌کند. Sakizadeh et al. (2017) از ماشین‌های بردار پشتیان و شبکه عصبی مصنوعی برای مدل‌سازی آلودگی خاک استفاده کردند. Piri and Mobaraki (2022) برای برآورد شوری سطحی خاک از درخت‌های تصمیم‌گیری، شبکه عصبی مصنوعی و ماشین‌بردار پشتیان استفاده کرده‌اند. در مطالعه‌ای دیگر در منطقه قروه کردستان، Moradian et al. (2018) شوری خاک را به کمک رگرسیون درختی و شبکه عصبی مصنوعی پیش‌بینی کردند. ماشین بردار پشتیان، شبکه عصبی

(2002 Tamari et al., 1996; Schaap et al., 1998). بررسی Pachepsky and Schaap (2004) نشان می‌دهد که درخت‌های رگرسیون نیز در برخی موارد عملکردی مشابه شبکه‌های عصبی دارند. Koekkoek and Boontink (1999) سه نوع شبکه عصبی را با ترکیب‌های متفاوتی از ویژگی‌های خاک برای پیش‌بینی نگهداشت آب در افق‌های خاک هلندی و اسکاتلندی مورد آزمایش قرار دادند. آن‌ها به نتایج رضایت‌بخشی دست یافتند، اگرچه دقت حاصل تفاوت چشم‌گیری با مدل‌های آماری نداشت. Li et al. (2024) نشان داد که استفاده از رویکرد مدل‌سازی گروهی که ترکیبی از چند الگوریتم یادگیری ماشین است، در پیش‌بینی ویژگی‌های هیدرولیکی خاک نتایج مطلوبی به همراه دارد. از نظر تاریخی، تلاش‌های بسیاری برای توسعه توابع انتقالی خاک به‌منظور تخمین خواص هیدرولیکی خاک انجام شده است. Wang et al. (2022)، Nemes et al. (2005) و Bagnall et al. (2022) نه تنها به توسعه مدل‌ها پرداختند، بلکه سعی در درک بهتر روابط میان ویژگی‌های ورودی خاک (مانند مقدار کربن آلی) و ویژگی‌های هیدرولیکی خاک نیز داشتند. پیچیدگی و چندبعدی بودن این روابط، اهمیت استفاده از ابزارهای هوش مصنوعی را در مطالعات آینده بیش‌ازپیش برجسته می‌کند.

الگوریتم‌های متنوعی مثل نزدیک‌ترین همسایه، ماشین‌های بردار پشتیان، درخت‌های تصمیم‌گیری، جنگل تصادفی و درخت‌های رگرسیون تقویت‌شده در ساخت توابع انتقالی مدرن خاک مورد استفاده قرار گرفته‌اند (Nemes et al., 2006; Jorda et al., 2015; Van Looy et al., 2017; da Silva et al., 2023). به‌عنوان نمونه، Twarakavi et al. (2009) استفاده از ماشین‌های بردار پشتیان را برای تخمین خواص هیدرولیکی خاک از روی بافت، چگالی ظاهری و نقاط نگهداشت بررسی کردند و نسبت به مدل‌های شبکه عصبی، دقت بالاتری گزارش دادند. Sihag et al. (2010) و ParchamiAragi et al. (2019) با استفاده از شبکه عصبی مصنوعی، ماشین بردار

مصنوعی، جنگل تصادفی و درخت رگرسیون برای پیش‌بینی و تهیه نقشه کربن آلی خاک نتایج امیدوارکننده‌ای را ارائه داده‌اند (Emadi et al., 2020). علاوه بر این، کاربردهای هوش مصنوعی گاهی به مرحله طبقه‌بندی داده‌های تحقیقاتی نیز گسترش می‌یابد، زیرا سازمان‌دهی چنین داده‌هایی امری زمان‌بر است. در مطالعه‌ای توسط Rahimi Mashkale et al. (2023) جنگل تصادفی، درخت تصمیم توسعه‌یافته و رگرسیون لجستیک چندجمله‌ای را برای طبقه‌بندی داده‌های نامتعادل خاک استفاده کردند و نتایج مطلوبی حاصل شد.

موضوع ۴: نقشه‌برداری رقومی خاک

یکی از پرکاربردترین و گسترده‌ترین زمینه‌های استفاده از یادگیری ماشین در علوم خاک، نقشه‌برداری رقومی ویژگی‌های خاک است. تمرکز اصلی مطالعات این حوزه بر تولید نقشه‌هایی از خواص فیزیکی و شیمیایی خاک (مانند پ‌هاش خاک، کربن آلی خاک، رطوبت خاک، بافت خاک و غیره) با استفاده از الگوریتم‌های داده‌محور و یادگیری ماشین است؛ درحالی‌که در مطالعات، دسته‌ای دیگر بر مقایسه عملکرد الگوریتم‌ها تمرکز دارد. یک نمونه برجسته از این حوزه، مطالعه Baltensweiler et al. (2021) است. آن‌ها با ترکیب سه روش (الگوریتم‌های یادگیری ماشین، زمین‌آمار و میانگین‌گیری مدل‌ها) به پیش‌بینی هفت ویژگی شیمیایی و فیزیکی خاک در فواصل عمقی مختلف جنگل‌های سوئیس پرداختند. نتایج این تحقیق نشان داد که الگوریتم جنگل تصادفی برای اغلب ویژگی‌های خاک و در تمامی اعماق، عملکرد پیش‌بینی بهتری نسبت به سایر مدل‌ها دارد.

اغلب این مطالعات از چهارچوب مفهومی نقشه‌برداری رقومی خاک پیروی می‌کنند که توسط McBratney et al. (2003) معرفی شده است. این چهارچوب، ارتباط کمی بین ویژگی‌های خاک و فاکتورهای خاک‌سازی (اقلیم، توپوگرافی، پوشش گیاهی و ...) را از طریق مدل‌سازی داده‌محور برقرار می‌سازد. یادگیری ماشین

جایگاهی کلیدی در مدل‌سازی این رابطه تجربی دارد. نمونه‌هایی از این رویکرد را در مطالعات Malone et al. (2020)، Poggio et al. و Lacoste et al. (2014)، می‌توان مشاهده کرد. با افزایش تعداد مطالعات در این زمینه، چندین مقاله مروری نیز منتشر شده است. Minasny and McBratney (2016) روند توسعه نقشه‌برداری رقومی خاک را در ارتباط با پیشرفت‌های یادگیری ماشین بررسی کردند. (Wadoux et al. (2020) به‌طور خاص بر کاربرد یادگیری ماشین در نقشه‌برداری رقومی خاک تمرکز داشتند. مطالعات Minasny et al. (2019)، Piikki et al. و Minasny et al. (2021) نیز به‌طور تخصصی به نقشه‌برداری رقومی خاک در اراضی پست‌دار، نقشه‌برداری کربن خاک و اعتبارسنجی آماری نقشه‌های خاکی پرداخته‌اند.

Wadoux et al. (2020) در بررسی خود، چالش‌های اساسی در کاربرد یادگیری ماشین برای نقشه‌برداری رقومی خاک مثل طراحی طرح‌های نمونه‌برداری مؤثر، استخراج و محاسبه اطلاعات مکانی، نقشه‌برداری هم‌زمان چند ویژگی (نقشه‌برداری چندمتغیره)، مدل‌سازی عدم قطعیت، اعتبارسنجی آماری، ترکیب دانش خاک‌شناسی با مدل‌های یادگیری ماشین و نهایتاً تفسیر خروجی مدل‌ها را مطرح کردند. در سال‌های اخیر، توجه پژوهشگران به این چالش‌ها افزایش یافته و مطالعات متعددی بر رفع آن‌ها تمرکز کرده‌اند (van der Westhuizen et al., 2023; Dasgupta et al., 2023; Fantappiè et al., 2023). استفاده از هوش مصنوعی در نقشه‌برداری رقومی خاک در ایران هم مورد استفاده قرار گرفته است. (Mehrabi, Maghsodi et al. (2020) Gohari et al. (2025) و Rahimi Mashkale et al. (2023) با استفاده از جنگل تصادفی، رگرسیون درختی توسعه‌یافته، مدل رگرسیون درختی، شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی، جنگل تصادفی، گرادیان بوستینگ، الگوریتم K نزدیک‌ترین همسایه^۱ به نقشه‌برداری رقومی خاک پرداخته‌اند. Taghizadeh

Mehrjerdi et al. (2015) به منظور نقشه برداری رقومی ظرفیت تبادل کاتیونی خاک، از ترکیب معادلات عمق اسپیلاین^۱ با نواحی یکسان و تکنیک نقشه برداری رقومی خاک استفاده کردند. در این مطالعه برای برقراری ارتباط بین ظرفیت تبادل کاتیونی خاک و متغیرهای کمکی استخراج شده از تصاویر ماهواره ای و مدل رقومی ارتفاع، از مدل رگرسیون درختی بهره گرفته شد.

استدلال و تصمیم گیری

موضوع ۱: سیستم های پشتیبانی تصمیم گیری خاک

یکی از رایج ترین کاربردهای هوش مصنوعی در علوم خاک، توسعه و بهره گیری از سیستم های پشتیبانی تصمیم گیری^۲ است. این سیستم ها عمدتاً برای ارزیابی شیوه های مدیریت خاک، تخمین پتانسیل فرسایش و کمی سازی کارکردها و کیفیت خاک مورد استفاده قرار می گیرند. به طور کلی، سیستم های پشتیبانی تصمیم گیری نوعی سیستم اطلاعاتی مبتنی بر رایانه است که برای تصمیم گیری در مسائل نیمه ساختاریافته و ساختار نیافته طراحی شده و از طریق داده ها، مدل ها، ابزارهای تحلیلی و رابط های کاربرپسند از کاربران پشتیبانی می کند (Booty et al., 2001; Power, 2007).


یکی از نمونه های اولیه در این حوزه، کار Van Alphen and Stoorvogel (2000) بود که در آن دو مؤلفه اصلی یک سیستم های پشتیبانی تصمیم گیری برای در نظر گرفتن تنوع خاک در کشاورزی دقیق در زمین های زراعی هلند توسعه یافت که عبارت اند از؛ (۱) ایجاد پایگاه داده خاک در مقیاس مزرعه و (۲) شناسایی واحدهای کارکردی در مقیاس مزرعه به عنوان مبنای مدیریت توصیه های کودی و آبیاری. در این مطالعه، سیستم های پشتیبانی تصمیم گیری بر پایه شبیه سازی های مکانیکی ویژه هر واحد عمل می کرد. در مطالعه Kerebel et al. (2013) رویکردی متفاوت به کار گرفته شد. در اینجا، سیستم های پشتیبانی تصمیم گیری با بهره گیری از یک مدل بیلان آب

هواشناسی کشاورزی، خطر آلودگی ناشی از کاربرد کودهای آلی را با در نظر گرفتن وضعیت آب خاک برآورد می کرد. همچنین، Kaur et al. (2007) یک سیستم پشتیبان تصمیم گیری مکانیکی کاربرپسند را برای خاک های متأثر از نمک طراحی کردند که در مقیاس مزرعه عمل کرده و برنامه های پیشنهادی تناوب زراعی و مدیریت منابع آب را ارائه می داد. مطالعه ای توسط Schwenke et al. (2019) در مورد توصیه های کود نیتروژن توسط مشاوران محصولات کشاورزی در استرالیا نشان داد که کشاورزان در استفاده روزمره، سیستم های پشتیبانی تصمیم گیری های ساده تری (مانند صفحات گسترده مبتنی بر داده های میدانی) را نسبت به مدل های پیچیده حاوی فرمول های فرآیندی ترجیح می دهند. این یافته، اهمیت طراحی رابط های کاربرپسند و قابل درک را در توسعه سیستم های پشتیبانی تصمیم گیری برجسته می سازد و مشخص می کند که چرا مطالعات مربوط به توصیه های مدیریت خاک با سیستم های پشتیبانی تصمیم گیری از سال ۱۹۹۷ تا به امروز ادامه دارد. زمینه مهم دیگر استفاده از سیستم های پشتیبانی تصمیم گیری در مدیریت فرسایش خاک و حفاظت حوزه های آبخیز است. برای نمونه، Montas and Madramootoo (1992) سیستمی طراحی کردند که با ترکیب یک سیستم اطلاعات جغرافیایی، یک مدل فرسایش توزیع شده و یک سیستم خبره، راهکارهای مدیریتی برای حفاظت خاک در حوزه های کشاورزی کبک کانادا ارائه می داد. در این سیستم های پشتیبانی تصمیم گیری، اطلاعات مربوط به نوع خاک، شیوه های مدیریتی و کاربری زمین با خروجی های مدل فرسایش، ترکیب شده و توصیه های خاص حفاظتی از طریق یک رابط کاربر ارائه می شد. سیستم های مشابهی برای مناطق خاصی چون اقلیم مدیترانه ای (De la Rosa et al. 2004; Anaya-Romero et al. 2015) یا مناطق نیمه خشک هند (Agnihotri et al., 2021) نیز توسعه یافته اند.

مشابه این چارچوب، برای ارزیابی عملکردهایی مانند بهره‌وری اولیه (Sandén et al., 2019)، زیستگاه برای تنوع زیستی (Van Leeuwen et al., 2019)، چرخه عناصر غذایی (Schröder et al., 2016)، تنظیم آب (Bohanec et al., 2020) و کیفیت کلی خاک (Wall et al., 2020) در مطالعات مختلف گزارش شده است.

سیستم‌های پشتیبانی تصمیم‌گیری، ابزارهای کلیدی برای بهره‌برداری از ظرفیت هوش مصنوعی در مدیریت پایدار خاک محسوب می‌شوند. توسعه سیستم‌های پشتیبانی تصمیم‌گیری در علوم خاک، از ارزیابی فرسایش گرفته تا برنامه‌ریزی کشاورزی دقیق و تحلیل خدمات اکوسیستمی خاک، نه تنها به تصمیم‌سازی بهتر کمک می‌کند، بلکه پلی میان دانش علمی و تصمیم‌گیرندگان عملیاتی در مزرعه، حوزه آبخیز و سیاست‌گذاری کشاورزی ایجاد می‌کند.

در سال‌های اخیر، تمرکز قابل‌توجهی بر استفاده از سیستم‌های پشتیبانی تصمیم‌گیری برای ارزیابی کارکردهای خاک در مقیاس مزرعه ایجاد شده است. برای مثال اخیراً برای حفاظت از خاک (Sarangi et al., 2004) و مدیریت کشاورزی دقیق (Young et al., 2021)، مطالعات زیادی سیستم‌های پشتیبانی تصمیم‌گیری را برای ارزیابی کارکردهای خاک در مقیاس مزرعه به کار برده‌اند. مطالعه (Debeljak et al., 2019) چارچوبی فراگیر برای چنین سیستم‌های پشتیبانی تصمیم‌گیری‌هایی ارائه می‌دهد که شامل داده‌های ورودی، پایگاه دانش مبتنی بر تخصص، مدل تصمیم‌گیری و رابط کاربری برای تعامل با سیستم است. در این ساختار، مدل تصمیم‌گیری معمولاً به شکل درخت سلسله‌مراتبی تصمیم طراحی می‌شود که به حوزه تحلیل تصمیم‌گیری چندمعیاره^۱ تعلق دارد. شکل ۳، ساختاری نمونه از سیستم‌های پشتیبانی تصمیم‌گیری برای عملکرد تنظیم آب‌وهوا را به تصویر می‌کشد. کاربردهای



شکل ۴- ساختار نمونه‌ای از یک مدل تصمیم‌گیری چندمعیاره سلسله‌مراتبی که برای ارزیابی کارکرد خاک در یک سیستم پشتیبانی تصمیم‌گیری استفاده می‌شود (Zwetsloot et al., 2021). این مدل، متغیرهای خاک، محیط و مدیریت را به‌عنوان ورودی دریافت می‌کند و یک ارزیابی کیفی از کارکرد تنظیم اقلیم را از طریق سطوح چندگانه تجمیع کیفی تحویل می‌دهد. N₂O نیتروز اکسید، NO₃⁻ نیترات و NH₃ آمونیاک هستند

Figure 4- Example structure of a hierarchical multi-criteria decision model used for soil function assessment in a decision support system (Zwetsloot et al., 2021). The model takes as input soil, environment and management variables and returns a qualitative evaluation of the climate regulation function through multiple levels of qualitative aggregation. N₂O represents Nitrous oxide, NO₃⁻ as Nitrate and NH₃ as Ammonia

موضوع ۲: سیستم خبره برای رده‌بندی خاک

سیستم‌های خبره به‌عنوان یکی از حوزه‌های شاخص تحقیقاتی در زمینه هوش مصنوعی شناخته می‌شوند. در دهه ۱۹۹۰، این سیستم‌ها یکی از مهم‌ترین دستاوردهای فناوری هوش مصنوعی تلقی می‌شدند (Fisher, 1989). یک سیستم خبره اساساً متشکل از یک موتور استنتاج^۱ و یک پایگاه دانش است. عملکرد آن بر اساس مجموعه‌ای از قوانین از نوع شرط-عمل است که به تولید خروجی‌هایی منطقی بر پایه داده‌های ورودی منجر می‌شود. نقش سیستم‌های خبره و مفاهیم مرتبط با نظریه شناختی در ساخت پایگاه‌های دانش برای کاربرد در علوم خاک، در مطالعاتی چون McCracken and Cate (1986) و Dale et al. (1989) بررسی و در طبقه‌بندی خاک به کار رفته‌اند. برای نمونه، Dale al. (1989) بر این نکته تأکید کردند که مؤلفه‌های اصلی سیستم‌های خبره با مراحل تصمیم‌گیری در طبقه‌بندی خاک مطابقت دارند. همچنین، MacMillan et al. (2005) با استفاده از داده‌های چشم‌انداز خاک، جداول احتمال و پایگاه قوانین، توانستند خاک‌ها را به موقعیت‌های خاص در لندفرم نسبت دهند. Galbraith et al. (1998)، یک سیستم خبره شیء‌گرا بر اساس قوانین تصمیم‌گیری طراحی کردند که قادر به شناسایی رده‌هایی خاک هیستوسول، اسپودوسول، اندی‌سول و اکسی‌سول بود. این سیستم از روش‌های تصمیم‌گیری منطقی برای استنتاج نوع خاک از روی ویژگی‌های مشاهده‌شده استفاده می‌کرد. با وجود برخی پیشرفت‌ها، به‌ویژه در ترکیب سیستم‌های خبره با منطق فازی (McBratney and Odeh, 1997)، توسعه این سیستم‌ها در حوزه طبقه‌بندی خاک در دو دهه گذشته نسبتاً محدود باقی‌مانده است و پیشرفت عمده‌ای نداشته است. این موضوع تا حدی به دلیل پیچیدگی‌های ذاتی خاک، دشواری در رسمی‌سازی دانش کارشناسی، و ظهور ابزارهای جایگزین مانند یادگیری ماشین بوده است. بااین‌حال در ایران مطالعاتی با کمک گرفتن از سیستم‌های

استنتاج در حوزه‌های نظیر برآورد سیلاب (Nouri et al., 2019)، مدل‌سازی منحنی رخنه^۲ (Palangi et al., 2019)، شبیه‌سازی دمای روزانه خاک (Bahmani et al., 2019)، نقشه‌برداری رقومی خاک (Maghsodi et al., 2025; Mehrabi et al., 2020)، تأثیر دمای روزانه و رطوبت خاک روی تنفس خاک (Hosseini et al., 2021)، پیش‌بینی ظرفیت تبادل کاتیونی (Emamgholizadeh et al., 2022) و پیش‌بینی مقدار ترسیب کربن در خاک مراتع (Jafarian et al., 2024) انجام شده است.

تحلیل و تبیین یافته‌ها

روند تکامل کاربرد هوش مصنوعی در علوم خاک

بررسی منابع نشان می‌دهد که هوش مصنوعی نخستین کاربردهای خود را در علوم خاک از طریق توسعه سیستم‌های خبره و سامانه‌های پشتیبان تصمیم‌گیری پیدا کرد؛ برای نمونه، در مطالعاتی مانند McCracken and Cate 1986; Van Alphen and Stoorvogel 2000 این سیستم‌ها با تکیه بر برنامه‌نویسی و شبیه‌سازی استدلال کارشناسان ساخته شده بودند. بااین‌حال، از دهه ۱۹۹۰ به بعد، این حوزه با افتی محسوس روبه‌رو شد. این دوران هم‌زمان با دوره‌ای به نام «زمستان هوش مصنوعی» بود؛ دوره‌ای که در آن به دلیل برآورده‌نشدن انتظارات و محدودیت‌های فناوری، علاقه و سرمایه‌گذاری در تحقیقات مرتبط با هوش مصنوعی کاهش یافت. در مقابل، از اوایل دهه ۲۰۰۰، کاربرد هوش مصنوعی در علوم خاک دوباره رو به رشد گذاشت و در دهه ۲۰۱۰ شتاب قابل‌توجهی گرفت. این بازگشت را می‌توان به پیشرفت‌ها و گسترش استفاده از روش‌های یادگیری ماشین و یادگیری عمیق نسبت داد؛ روش‌هایی که در زمینه‌های مختلفی مانند پیش‌بینی مکانی کلاس‌های خاک (Heung et al., 2016)، تحلیل ساختمان نمونه‌های خاک (Lavrukhin et al., 2021)، توسعه توابع انتقالی دقیق (Li et al., 2024) و

باعث شده است که پیوند بین متغیرهای ورودی و نتایج نهایی به راحتی قابل تبیین نباشد. پژوهشگران هشدار داده‌اند که ممکن است الگوریتم‌ها همبستگی‌هایی را بیابند که الزاماً ارتباط علی ندارند، و این می‌تواند به برداشت‌های نادرست منجر شود.

– ادغام دانش خاک‌شناسی با مدل‌های هوش مصنوعی؛ مدل‌های هوش مصنوعی فعلی، بیشتر به دنبال یافتن روابط میان داده‌ها هستند، بدون آنکه الزاماً بر اصول علمی یا فیزیکی مبتنی باشند. این مسئله باعث می‌شود تا گاهی پیش‌بینی‌ها فاقد بنیان علمی مشخص باشند. برای مثال، مدلی که تغییرات کربن آلی خاک را پیش‌بینی می‌کند، آیا واقعاً درک درستی از فرایندهای زیستی دارد یا صرفاً بر اساس الگوهای آماری پیش‌بینی می‌کند؟ مشکل دیگر، کمبود داده‌های کافی برای نمایش کامل تنوع خاکی در بسیاری از مناطق است. در چنین شرایطی، مدل‌ها نمی‌توانند رفتار واقعی سیستم را به خوبی یاد بگیرند. در نتیجه، محققان بر اهمیت ادغام «دانش موجود خاک‌شناسی» در مدل‌ها تأکید دارند؛ چه این دانش مفهومی باشد، چه شهودی یا تجربی.

– محدودیت‌های نرم‌افزارهای اختصاصی هوش مصنوعی؛ یکی از چالش‌های مهم، استفاده از نرم‌افزارهای بسته یا مالکیتی است که کاربران نمی‌توانند به کدهای درونی آن‌ها دسترسی داشته باشند. در بسیاری از موارد، ابزارهای هوش مصنوعی در علوم خاک به صورت «جعبه سیاه» عمل می‌کنند و تفسیر دقیق آن‌ها ممکن نیست. این مسئله در نرم‌افزارهای نقشه‌برداری، تجزیه و تحلیل تصویر و حتی ابزارهای میدانی نیز دیده می‌شود. برای حفظ قابلیت اطمینان نتایج، باید شفافیت، تکرارپذیری و مستندسازی دقیق عملکرد مدل‌ها تضمین شود. وجود معیارهایی برای ارزیابی کیفیت مدل‌ها و اطمینان از در دسترس بودن نسخه‌های نرم‌افزاری در طول زمان، برای اعتبار علمی مدل‌های هوش مصنوعی ضروری است.

– اخلاق در اشتراک‌گذاری و برداشت داده‌ها؛ هوش مصنوعی برای عملکرد مناسب به داده‌های زیاد و

تخمین ویژگی‌های خاک با استفاده از داده‌های سنجش‌ازدور و نزدیک (Ng et al., 2020) به کار گرفته شده‌اند. با وجود تنوع در کاربردها، وجه مشترک بیشتر آن‌ها، استفاده از الگوریتم‌های هوش مصنوعی برای پیش‌بینی ویژگی‌های خاک است. یکی از تفاوت‌های مهم میان کاربردهای اخیر و تلاش‌های اولیه در دهه ۱۹۸۰، حجم بالای داده‌های دیجیتال موجود در زمان حال است. این افزایش داده‌ها، که حاصل همگرایی فناوری‌های دیجیتال مختلف است، امکان آموزش دقیق‌تر و قدرتمندتر مدل‌های یادگیری ماشین و یادگیری عمیق را فراهم کرده است (Wadoux and McBratney, 2021). با این حال، حوزه‌هایی مانند پردازش زبان طبیعی، مدل‌سازی شناختی خاک و یادگیری ماشین قابل تفسیر نیز در سال‌های اخیر مورد توجه قرار گرفته‌اند؛ گرچه هنوز به اندازه‌ی کافی گسترش نیافته‌اند که به عنوان یک حوزه مطالعاتی مستقل شناخته شوند. این حوزه‌های نوظهور، فرصت‌هایی ارزشمند برای تحقیقات آینده در علوم خاک به شمار می‌روند.

نکات قابل توجه

بررسی منابع نشان می‌دهد که هوش مصنوعی در طیف وسیعی از مطالعات خاک به کار گرفته، اما در این مسیر، با پنج چالش اصلی روبرو است که توجه به آن‌ها برای توسعه علمی آینده ضروری است:

– پیش‌بینی در برابر تبیین؛ در سال‌های اخیر، بیشتر پژوهش‌ها بر استفاده از هوش مصنوعی برای پیش‌بینی دقیق ویژگی‌های خاک تمرکز داشته‌اند؛ از جمله تولید نقشه‌های رقومی خاک، تخمین توابع انتقالی خاک، یا پیش‌بینی از طریق طیف‌سنجی. این رویکرد با «موج اول» کاربردهای هوش مصنوعی در علوم خاک، که بیشتر بر استدلال کارشناسانه و مدل‌سازی دانش‌محور متکی بود، تفاوت اساسی دارد. گرچه مدل‌های پیچیده هوش مصنوعی می‌توانند نتایج دقیقی ارائه دهند، اما درک منطق پیش‌بینی‌های آن‌ها اغلب دشوار است. با رشد داده‌های پیچیده و حجیم خاک، مدل‌ها نیز پیچیده‌تر شده‌اند و این

پروفیل‌های خاک هستند، می‌توانند با کمک تکنولوژی‌هایی مانند بینایی کامپیوتری و استخراج خودکار متن وارد چرخه تحقیقات شوند. هرچند این داده‌ها ممکن است از نظر دقت با داده‌های جدید قابل رقابت نباشند، اما ارزش تاریخی و پوشش مکانی بالای آن‌ها آن‌قدر مهم است که نادیده گرفتنشان اشتباه بزرگی خواهد بود. این روند می‌تواند به جبران کمبود فعلی در توصیف‌های میدانی کمک کند.

– هوش مصنوعی تفسیرپذیر، نه فقط دقیق؛ پیش‌بینی‌های دقیق خوب هستند، اما فهم اینکه "چرا" یک مدل چنین پیش‌بینی انجام داده، اهمیت بیشتری دارد؛ به‌ویژه در علوم خاک که تحلیل روابط بین متغیرها برای تصمیم‌گیری حیاتی است. هوش مصنوعی تفسیرپذیر به دنبال همین هدف است. روش‌هایی مانند مقادیر شیلی می‌توانند نقش متغیرها را در پیش‌بینی‌ها شفاف کنند. فراتر از آن، ایده هوش مصنوعی "خود توضیح‌دهنده" نیز در حال رشد است. مدل‌هایی که نه تنها پیش‌بینی می‌کنند، بلکه دلیل پیش‌بینی را نیز به زبان قابل فهم توضیح می‌دهند. این رویکردها اعتماد به مدل‌ها را بالا می‌برند و کاربرد آن‌ها را در علوم حساس‌تری مانند خاک‌شناسی افزایش می‌دهند.

– ترکیب هوش مصنوعی با مدل‌های فرآیندی خاک؛ یکی از مسیرهای جالب آینده، تلفیق مدل‌های فیزیکی با مدل‌های یادگیری ماشین است. برای مثال، می‌توان جریان آب در خاک را نه فقط با داده‌های مشاهده‌ای، بلکه با در نظر گرفتن اصول فیزیکی پیش‌بینی کرد—کاری که در برخی مطالعات اولیه مانند کار Ghorbani et al. (2021) انجام شده است. این روش‌ها به مدل‌های ترکیبی (فیزیکی-داده‌محور) معروف هستند. همچنین مفاهیمی مانند استنتاج علی (که سعی در کشف روابط علی واقعی بین متغیرها دارند) نیز در حال ورود به حوزه علوم خاک هستند. گرچه کاربرد این مفاهیم در خاک هنوز نوپا است، اما پتانسیل بزرگی برای شناخت پویایی‌های پیچیده خاک دارد.

– درک متون علمی با زبان ماشین؛ تعداد مقالات منتشرشده در علوم خاک به‌طور پیوسته رو به افزایش است

متنوع نیاز دارد، اما این نیاز سؤالات اخلاقی جدیدی را ایجاد کرده است. داده‌هایی که از منابع مختلف گردآوری می‌شوند، باید به‌درستی هماهنگ شوند، منشأ آن‌ها حفظ شود و مجوز استفاده از آن‌ها مشخص باشد. همچنین، توسعه مدل‌ها بدون اطلاع یا رضایت تأمین‌کنندگان داده، به‌ویژه در مواردی که داده‌ها عمومی نیستند، می‌تواند از نظر اخلاقی مشکل‌ساز باشد. از سوی دیگر، نبود فراداده‌های کافی ممکن است باعث شود که داده‌ها بدون معنای دقیق در کاربردهای بعدی استفاده شوند. یکی از راهکارهای پیشنهادی برای حل این مسائل، استفاده از فناوری بلاک‌چین برای ردیابی و ثبت مطمئن داده‌ها است.

– کمبود داده‌های باکیفیت برای آموزش مدل‌ها؛ مدل‌های هوش مصنوعی برای عملکرد بهتر به مجموعه داده‌های گسترده و با کیفیت نیاز دارند. مطالعات نشان داده‌اند که افزایش اندازه داده‌های آموزشی می‌تواند به بهبود چشمگیر نتایج بینجامد، همان‌طور که در پروژه‌های نقشه‌برداری عناصر خاک در آفریقا مشاهده شده است (Hengl et al., 2021). اما این سؤال وجود دارد که آیا در آینده با کمبود داده‌های قابل اعتماد مواجه خواهیم شد؟ در بسیاری از کشورها، نرخ تولید داده‌های پایه خاکی در حال کاهش است. یکی از راه‌حل‌ها، تولید داده‌های مصنوعی یا استفاده از تکنیک‌های افزایش داده مثل استفاده از تصاویر چرخانده شده برای آموزش بهتر مدل‌های یادگیری عمیق است.

فرصت‌ها

نوآوری‌های جدید در حوزه هوش مصنوعی، افق‌های تازه‌ای را پیش روی علوم خاک گشوده‌اند. در ادامه، پنج مسیر مهم و امیدبخش تحقیقاتی معرفی می‌شود که می‌توانند زمینه‌ساز تحول در این حوزه باشند:

– گنجینه‌ای از داده‌های خاکی که دوباره زنده می‌شوند؛ در بایگانی‌های خاک‌شناسی، حجم قابل توجهی از داده‌های کیفی و توصیفی وجود دارد که سال‌ها نادیده گرفته شده‌اند، اما امروزه در حال رقومی شدن هستند. این اطلاعات که شامل گزارش‌های توصیفی قدیمی از

و خلاصه‌سازی یا تحلیل دستی آن‌ها بسیار دشوار شده است. در این میان، پردازش زبان طبیعی می‌تواند به کمک محققان بیاید. مدل‌های زبانی بزرگی مانند ChatGPT این قابلیت را دارند که متون علمی را خلاصه کرده، روابط را استخراج کنند یا حتی به زبان‌های مختلف ترجمه کنند. با این حال، این مدل‌ها هنوز نیازمند آموزش بیشتر با داده‌های خاص علوم خاک هستند. آینده این خط تحقیقاتی می‌تواند به ساخت مدل‌های زبانی تخصصی خاک منتهی شود که بتوانند متون علمی را با دقت بالا تحلیل و ترکیب کنند.

- ورای یادگیری ماشین؛ نسل جدید هوش مصنوعی. درحالی‌که بیشتر پژوهش‌های فعلی در علوم خاک بر یادگیری ماشین متمرکزند، زمینه‌های دیگری از هوش مصنوعی هنوز به‌خوبی کاوش نشده‌اند. برای مثال، هوش مصنوعی مولد می‌تواند پروفیل‌های خاک یا داده‌های مصنوعی ایجاد کند که در شرایط خاص مثل ساخت دوقلوهای دیجیتال خاک^۱ برای شبیه‌سازی‌های دقیق کاربرد دارد. دوقلوهای دیجیتال به‌طورکلی به یک مدل دیجیتال پویا و هوشمند گفته می‌شود که وضعیت، فرایندها و رفتار یک سامانه واقعی را به‌صورت مجازی شبیه‌سازی و به‌روز می‌کند. وقتی این مفهوم در علوم خاک به‌کار می‌رود، یک مدل دیجیتال زنده از خاک و فرایندهای آن ساخته می‌شود. داده‌های خاک (رطوبت، دما، مواد آلی، فرسایش و ...) از طریق حسگرها، تصاویر ماهواره‌ای و مدل‌های هوش مصنوعی به‌طور پیوسته به این مدل منتقل می‌شود. دوقلو دیجیتال می‌تواند تغییرات خاک را در زمان واقعی رصد کند و حتی آینده را پیش‌بینی کند (Zhou et al., 2022). همچنین، الگوریتم‌های ژنتیکی و سیستم‌های خبره، که در گذشته توجه زیادی جلب کرده بودند، دوباره می‌توانند با قدرت محاسباتی امروز بازتعریف شوند. این فناوری‌ها می‌توانند درک ما از پویایی، تغییرپذیری و تکامل خاک را به شکل بنیادین ارتقا دهند.

آینده‌ای در مسیر هم‌افزایی انسان و هوش مصنوعی در علوم خاک

بررسی‌های انجام‌شده نشان می‌دهد که هوش مصنوعی در حوزه تحقیقات خاک، در حال ایفای نقش رو به رشدی است. این فناوری با خودکارسازی یا تسریع برخی مراحل پژوهشی که پیش‌تر به‌دست انسان انجام می‌شد از جمله پیش‌بینی، تحلیل داده‌ها و حتی خواندن و خلاصه‌سازی متون علمی توانسته مسیر علم خاک را در جهتی تازه هدایت کند. در اصل، هوش مصنوعی با تکیه بر داده‌ها و الگوریتم‌ها، الگوهای پنهان را شناسایی کرده و بر اساس آن‌ها پیش‌بینی می‌کند، همان‌طور که انسان‌ها با استفاده از دانش و تجربه خود برای آینده تصمیم می‌گیرند. به‌طور مشابه، سیستم‌های هوشمند می‌توانند متون علمی را مانند یک پژوهشگر بخوانند، خلاصه کنند، و تحلیل‌هایی مشابه متاآنالیز انجام دهند؛ چیزی که در گذشته تنها از عهده انسان برمی‌آمد (Hastings, 2023). با این حال، باید توجه داشت که کاربرد هوش مصنوعی در علوم خاک فعلاً محدود به برخی وظایف است و معمولاً تحت نظارت و قضاوت انسانی صورت می‌گیرد.

پژوهشگر انسانی همچنان کسی است که با گردآوری داده‌ها، طرح فرضیه‌ها، طراحی آزمایش‌ها و تجزیه و تحلیل نتایج، روند کلی تحقیق را هدایت می‌کند. این چرخه علمی از مشاهده گرفته تا نتیجه‌گیری و انتشار یافته‌ها در حال حاضر هنوز به ذهن و قضاوت انسانی وابسته است. اما آیا در آینده‌ای نه‌چندان دور، ممکن است برخی از این مراحل به‌طور کامل خودکار شوند؟

نمونه‌هایی از این چشم‌انداز در حال ظهور هستند. مثلاً «آمارشناس خودکار» (Steinruecken et al., 2019) می‌تواند به‌طور خودکار تحلیل‌های آماری انجام دهد. حتی تلاش‌هایی برای ساخت «دانشمند هوش مصنوعی» شکل گرفته که کل فرایند علمی از طراحی تحقیق تا نوشتن مقاله و حتی بررسی همتای علمی را خودکار می‌سازد (Castelvecchi, 2024; Lu et al., 2024). در حوزه آزمایشگاهی و میدانی نیز، ربات‌های هوشمند به کمک آمده‌اند (Gibney, 2024).

عمیق و نیز دسترسی گسترده به داده‌های دیجیتال بوده است. بر پایه تحلیل جامع منابع و مطالعات موجود (Wadoux, 2025)، می‌توان به نتایج و برداشت‌های کلیدی زیر رسید:

الف) تعریف کاربردی هوش مصنوعی بر پایه عقلانیت است: یعنی سیستم‌های هوشمند با درجه‌ای از استقلال، برای دستیابی به اهداف خاص تصمیم‌گیری و اقدام می‌کنند. ب) هوش مصنوعی فراتر از یادگیری ماشین است و به‌طور کلی در سه حوزه اصلی تقسیم می‌شود: استدلال و تصمیم‌گیری، یادگیری و پیش‌بینی، و سنجش و تعامل. در علوم خاک، این تقسیم‌بندی تطبیقی به‌وضوح قابل مشاهده است و بیشترین فعالیت‌ها در حال حاضر در بخش یادگیری و پیش‌بینی متمرکز شده‌اند.

ج) کاربردهای هوش مصنوعی در علوم خاک بسیار متنوع‌اند؛ از تحلیل تصاویر و سنجش‌ازدور گرفته تا توسعه توابع انتقالی خاک و طراحی سیستم‌های پشتیبان تصمیم‌گیری و تحلیل طیف‌سنجی. با این حال، یادگیری ماشین برای اهداف پیش‌بینی همچنان پرکاربردترین حوزه باقی‌مانده است.

د) دسته‌بندی مطالعات نشان می‌دهد که نوآوری‌ها در این حوزه، به‌ویژه در زمینه نقشه‌برداری رقومی خاک و مدل‌سازی خواص خاک از طریق فناوری‌های سنجش از نزدیک و دور، بیشترین سهم را در کاربردهای فعلی دارند. این فعالیت‌ها اغلب در مرز میان سنجش‌گرها و الگوریتم‌های یادگیری ماشین انجام می‌شوند.

هم‌زمان، پنج چالش و تهدید اصلی نیز مورد توجه قرار گرفته‌اند: (۱) تمایز مهم میان پیش‌بینی صرف و توضیح‌پذیری مدل‌ها، (۲) دشواری در ادغام دانش تخصصی خاک با مدل‌های داده‌محور، (۳) ریسک‌های ناشی از وابستگی به نرم‌افزارهای اختصاصی و بسته، (۴) ملاحظات اخلاقی در برداشت، مالکیت و اشتراک داده‌ها و (۵) احتمال کاهش منابع داده‌های باکیفیت برای آموزش مدل‌های آینده. با این وجود، فرصت‌های مهمی برای گسترش هوش مصنوعی در علوم خاک پیش‌رو است. این فرصت‌ها

با وجود این پیشرفت‌ها، هنوز هیچ هوش مصنوعی نتوانسته همانند انسان، مسیرهای علمی کاملاً نوآورانه‌ای را خلق کند یا فراتر از دانش موجود، نظریه‌پردازی کند. همان‌طور که (Hartemink et al., 2006) و (McBratney, 2024) اشاره کرده‌اند، نوآوری علمی معمولاً از کنجکاوی و تخیل سرچشمه می‌گیرد توانایی‌هایی که هوش مصنوعی فعلاً فاقد آن است. اما در بیشتر بخش‌های تحقیقات روزمره مثل آزمون فرضیه‌های موجود یا تکرار آزمایش‌ها هوش مصنوعی می‌تواند نیرویی تسهیل‌گر و حتی شتاب‌دهنده باشد. همان‌طور که (McBratney, 2024) می‌گوید، بیشتر کار علمی ما در نواحی "ناشناخته‌های شناخته‌شده" می‌گذرد، و در اینجا هوش مصنوعی نقش بزرگی ایفا خواهد کرد. در نهایت، آینده علوم خاک به احتمال زیاد در دستان پژوهشگرانی خواهد بود که با هوش مصنوعی هم‌افزایی دارند: انسان‌ها با چشم‌انداز، شهود و تخیل، و ماشین‌ها با توان پردازشی، تکرارپذیری و سرعت بالا. به بیان دیگر، «چشم‌انداز با انسان باقی می‌ماند، اما اجرای آن بیش‌ازپیش به هوش مصنوعی واگذار خواهد شد».

نتیجه‌گیری

هوش مصنوعی نخستین بار در علوم خاک از طریق سیستم‌های خبره و سیستم‌های پشتیبانی تصمیم‌گیری وارد شد؛ ابزارهایی که با الگوبرداری از منطق و استدلال کارشناسان، تلاش داشتند فرآیندهای تصمیم‌سازی در این علم را شبیه‌سازی کنند. با این حال، پس از دهه ۱۹۹۰، در دوره‌ای که با عنوان «زمستان هوش مصنوعی» شناخته می‌شود، این حوزه با رکود مواجه شد. در این دوره، بودجه‌ها کاهش یافت و علاقه عمومی به توسعه فناوری‌های هوش مصنوعی، در همه شاخه‌های علمی رو به افول گذاشت. اما از آغاز دهه ۲۰۰۰، و به‌ویژه در دهه ۲۰۱۰، شاهد رونق دوباره و چشمگیر کاربردهای هوش مصنوعی در علوم خاک هستیم. این رشد، در درجه اول به دلیل پیشرفت چشمگیر در یادگیری ماشین و یادگیری

منابع قدیمی می‌تواند منبع ارزشمندی برای مدل‌های جدید باشد. با وجود آن‌که همگرایی دیجیتال، دسترسی به داده‌ها را آسان‌تر کرده، اما همچنان ادغام کامل این اطلاعات با فناوری‌های نوین هوش مصنوعی در علوم خاک با کندی انجام می‌شود به‌ویژه در مقایسه با حوزه‌های دیگر علمی که بهره‌وری بیشتری از این ابزارها داشته‌اند.

تعارض منافع

در این مقاله تعارض منافی وجود ندارد و این مسئله مورد تأیید نویسندگان مقاله است.

شامل تقویت مشاهده‌های میدانی برای بهبود مدل‌ها، توسعه الگوریتم‌های قابل تفسیر و مبتنی بر دانش تخصصی خاک، استفاده از پردازش زبان طبیعی برای استخراج اطلاعات از متون علمی خاک، بررسی ظرفیت‌های روش‌های نوین مانند محاسبات تکاملی و بازنگری در سیستم‌های خبره و ایجاد پل ارتباطی میان علم داده و دانش خاک‌شناسی می‌شود. در مجموع، هوش مصنوعی نه تنها در تسهیل و شتاب بخشی به تحلیل‌های خاک نقش مهمی ایفا کرده، بلکه با استفاده از داده‌های نوظهور، به باز کردن منابعی کمک می‌کند که پیش‌تر کمتر در دسترس یا قابل استفاده بودند. به‌ویژه، استخراج اطلاعات از متون تاریخی خاک و دیجیتالی‌سازی

References

1. Abeje, B, T., Salau, A, O., Gela, B, M., Mengistu, A, D., 2024. Soil type identification model using a hybrid computer vision and machine learning approach. *Multimedia Tools and Applications*, 83, pp. 575–589. <https://doi.org/10.1007/s11042-023-15692-4>
2. Agnihotri, D., Kumar, T., Jhariya, D., 2021. Intelligent vulnerability prediction of soil erosion hazard in semi-arid and humid region, *Environment. Development and Sustainability* 23, pp. 2524–2551. <https://doi.org/10.1007/s10668-020-00685-2>
3. Akpa, S, I, C., Ugbaje, S, U., Bishop, T, F, A., Odeh, I, O, A., 2016. Enhancing pedotransfer functions with environmental data for estimating bulk density and effective cation exchange capacity in a Data-Sparse situation. *Soil Use and Management* 32, pp. 644–658. <https://doi.org/10.1111/sum.12310>
4. Alvarez, R, Steinbach, H, S., Bono, A., 2011. An artificial neural network approach for predicting soil carbon budget in agroecosystems. *Soil Science Society of America Journal*, 75, pp. 965–975. <https://doi.org/10.2136/sssaj2009.0427>
5. Anaya-Romero, M., Abd-Elmabod, S, K., Muñoz-Rojas, M., 2015. Evaluating soil threats under climate change scenarios in the Andalusia region, Southern Spain. *Land Degradation & Development*, 26, 441–449. <https://doi.org/10.1002/ldr.2363>
6. Aydemir, S., Keskin, S., Drees, L, R., 2004. Quantification of soil features using Digital Image Processing (DIP) techniques. *Geoderma*, 119, pp. 1-8. [https://doi.org/10.1016/S0016-7061\(03\)00218-0](https://doi.org/10.1016/S0016-7061(03)00218-0)
7. Ayoubi, S., Ghavami, M. S. 2025. Using machine learning methods to estimate soil erosion with the RUSLE model in a part of central Iran. *Water and Soil*, [in press] (in Persian) <https://doi.org/10.22067/jsw.2025.95566.1502>
8. Bagnall, D. K., Morgan, C, L, S., Cope, M., 2022. Carbon-sensitive pedotransfer functions for plant available water. *Soil Science Society of America Journal* 86, pp. 612–629 <https://doi.org/10.1002/saj2.20395>
9. Bahmani, F., Pirisahragard, H., Piri, J., 2019. Application of artificial intelligence methods to estimate soil daily temperature in arid and semi-arid climates. *Iranian Journal of Range and Desert Research*, 26(1), pp. 201-213. (In Persian) <https://doi.org/10.22092/ijrdr.2019.119337>
10. Baltensweiler, A., Walthert, L., Hanewinkel, M., Zimmermann, S., Nussbaum, M., 2021. Machine learning based soil maps for a wide range of soil properties for the forested area of Switzerland. *Geoderma Regional*, 27, e00437 <https://doi.org/10.1016/j.geodrs.2021.e00437>
11. Bao, Y., Yao, F., Meng, X., 2024. A fine digital soil mapping by integrating remote sensing-based process model and deep learning method in northeast china. *Soil and Tillage Research*, 238, 1060 <https://doi.org/10.1016/j.still.2024.106010>

12. Baumann, P., Lee, J., Behrens, T., 2022. Modelling soil water retention and water-holding capacity with visible–near-infrared spectra and machine learning. *European Journal of Soil Science* 73, e13220. <https://doi.org/10.1111/ejss.13220>
13. Behrens, T., Förster, H., Scholten, T., Steinrücken, T., Spies, E. D., Goldschmitt, M., 2005. Digital soil mapping using artificial neural networks. *Journal of Plant Nutrition and Soil Science*, 168, pp. 21–33. <https://doi.org/10.1002/jpln.200421414>
14. Behrens, T., Scholten, T., 2006. A comparison of data-mining techniques in predictive soil mapping. *Developments in Soil Science*, 31, pp. 353–617. [https://doi.org/10.1016/S0166-2481\(06\)31025-2](https://doi.org/10.1016/S0166-2481(06)31025-2)
15. Behzadipour, F., Ghaseminezhad, M., Abdanan Mehdizadeh, S., Taki, M., Khalili Moghadam, B., Zare Bavani, M. R. 2023. Predictions of greenhouse soil moisture using artificial neural network and wireless network sensing. *Iranian Journal of Biosystem Engineering*, 53(4), pp. 341-356. (In Persian)
<https://doi.org/10.22059/ijbse.2023.341992.665482>
16. Beucher, A., Rasmussen, C. B., Moeslund, T. B., Greve, M. A., 2022. Interpretation of convolutional neural networks for acid sulfate soil classification. *Frontiers in Environmental Science*, 9, 809995. <https://doi.org/10.3389/fenvs.2021.809995>
17. Biney, J. K. M., Vašát, R., Blöcher, J. R., Boruvka, L., Němecček, K., 2022. Using an ensemble model coupled with portable x-ray fluorescence and visible near-infrared spectroscopy to explore the viability of mapping and estimating arsenic in an agricultural soil. *Science of the Total Environment*, 818, 151805.
<https://doi.org/10.1016/j.scitotenv.2021.151805>
18. Blanchy, G., Albrecht, L., Koestel, J., Garré, S., 2023. Potential Change. *European Journal of Soil Science* 72, pp.1607–1623.
19. Blanchy, G., Albrecht, L., Koestel, J., Garré, S., 2023. Potential of natural language processing for metadata extraction from environmental scientific publications. *Soil*, 9, pp. 155–168. <https://doi.org/10.5194/soil-9-155-2023>
20. Bogrecki, I., Godwin, R. J., 2007. Development of an imageprocessing technique for soil tilth sensing. *Biosystems Engineering*, 97, pp. 323–331.
<https://doi.org/10.1016/j.biosystemseng.2007.03.025>
21. Bohanec, M., Cortet, J., Griffiths, J., 2007. A qualitative multiattribute model for assessing the impact of cropping systems on soil quality. *Pedobiologia*, 51, pp. 239–250.
<https://doi.org/10.1016/j.pedobi.2007.03.006>
22. Booty, W. G., Lam, D. C. L., Wong, I. W. S., Siconolfi, P., 2001. Design and Implementation of an Environmental Decision Support System. *Environmental Modelling & Software*, 16, pp. 453–458. [https://doi.org/10.1016/S1364-8152\(01\)00016-0](https://doi.org/10.1016/S1364-8152(01)00016-0)
23. Brungard, C. W., Boettinger, J. L. B., Duniway, M. C., Wills, S. A., Edwards Jr, T. C., 2015. Machine learning for predicting soil classes in three semi-arid landscapes. *Geoderma*, 239, pp. 68–83.
24. Brungard, C., Nauman, T., Duniway, M., 2021. Regional ensemble modeling reduces uncertainty for digital soil mapping. *Geoderma*, 397, 114998.
<https://doi.org/10.1016/j.geoderma.2021.114998>
25. Bui, E. N., Loughhead, A., Corner, R., 1999. Extracting soil landscape rules from previous soil surveys. *Soil Research*, 37, pp. 495–508. <https://doi.org/10.1071/S98047>
26. Burrough, P. A., 1992. Development of intelligent geographical information systems, *international Journal of Geographical Information Systems*, 6, pp. 1–11.
27. Campbell, M., Hoane, A. J., Hsu, F. H., 2002. Deep Blue. *Artificial Intelligence*, 134(1–2), pp. 57–83. [https://doi.org/10.1016/S0004-3702\(01\)00129-1](https://doi.org/10.1016/S0004-3702(01)00129-1)
28. Canillas, E. C., Salokhe, V. M., 2002. A decision support system for compaction assessment in agricultural soils. *Soil and Tillage Research*, 65, pp. 221–230.
29. Castelveccchi, D., 2024. Researchers Built an “AI scientist” – What can it do?” Available at <https://www.nature.com/articles/d41586-024-02842-3>, accessed: 21 July 2025.
30. Chakraborty, R., Pal, S. C., 2023. Modeling soil erosion susceptibility using gis-based different machine learning algorithms in monsoon dominated diversified landscape in India. *Modeling Earth Systems and Environment*, 9, pp. 2927–2942.

- <https://doi.org/10.1007/s40808-022-01681-3>
31. Chandra, H., Pawar, P. M., Elakkiya, R., Tamizharasan, P. S., Muthalagu, R., Panthakkan, A., 2023. Explainable ai for soil fertility prediction. *IEEE Access*, 11, pp. 97866–97878. <https://doi.org/10.1109/ACCESS.2023.3311827>
 32. Chaney, N. W., Wood, E. F., McBratney, A. B., 2016. POLARIS: A 30-meter probabilistic soil series map of the contiguous united state. *Geoderma*, 274, pp. 54–67. <https://doi.org/10.1016/j.geoderma.2016.03.025>
 33. Chang, D., -H., Islam, S., 2000. Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sensing of Environment*, 74, pp. 534–544. <https://doi.org/10.1371/journal.pone.0129977>
 34. Chen, Q., Li, L., Chong, C., Wang, X., 2022. AI-enhanced soil management and smart farming. *Soil Use and Management*, 38, pp. 7–13. <https://doi.org/10.1111/sum.12771>
 35. Cialella, A. T., Lawrence, W., Levine, E., 1997. Predicting soil drainage class using remotely sensed and digital elevation data. *Photogrammetric Engineering and Remote Sensing*, 63, pp. 171–177.
 36. Crevier, D., 1993. *AI: The Tumultuous Search for Artificial Intelligence*. Basic Books.
 37. Da Silva, L. d. C. M., Amorim, R. S., Fernandes-Filho, E. I., Bocuti, E. D., Da Silva, D. D., 2023. Pedotransfer functions and machine learning: advancements and challenges in tropical soils. *Geoderma Regional*, 35, e00720. <https://doi.org/10.1007/s12665-026-12835-2>
 38. Dale, M. B., McBratney, A. B., Russell, J. S., 1989. On the role of expert systems and numerical taxonomy in soil classification. *Journal of Soil Science*, 40, pp. 223–234. <https://doi.org/10.1111/j.1365-2389.1989.tb01268.x>
 39. Dasgupta, S., Debnath, S., Das, A., 2023. Developing Regional Soil Micronutrient Management Strategies through Ensemble learning based digital soil mapping. *Geoderma*, 433, 116457. <https://doi.org/10.1016/j.geoderma.2023.116457>
 40. De Bruin, S., Stein, A., 1998. Soil-landscape modelling using fuzzy c-means clustering of attribute data derived from a digital elevation model (DEM). *Geoderma*, 83, pp. 17–33.
 41. De la Rosa, D., Mayol, F., Daz-Pereira, E., Fernandez, M., de la Rosa Jr, D., 2004. A land evaluation decision support system (MicroLEIS DSS) for agricultural soil protection: with special reference to the mediterranean region. *Environmental Modelling & Software*, 19, pp. 929–942. <https://doi.org/10.1016/j.envsoft.2003.10.006>
 42. De Oliveira, V. A., Rodrigues, A. F., Morais, M. A. V., Terra, M. D. C. N. S., Guo, L. M., de Mello, C. R., 2021. Spatiotemporal modelling of soil moisture in an Atlantic forest through machine learning algorithms. *European Journal of Soil Science*, 72, pp. 1969–1987. <https://doi.org/10.1111/ejss.13123>
 43. De Sousa Mendes, W., Demattê, J. A. M., Minasny, B., 2022. Free iron oxide content in tropical soils predicted by integrative digital mapping. *Soil and Tillage Research*, 219, 105346. <https://doi.org/10.1016/j.still.2022.105346>
 44. Debeljak, M., Trajanov, A., Kuzmanovski, V., 2019. A field-scale decision support system for assessment and management of soil environmental scientific publications, *Soil*, 9, pp. 155–168, Functions. *Frontiers in Environmental Science*, 7 (115) <https://doi.org/10.3389/fenvs.2019.00115>
 45. Diaz-Gonzalez, F. A., Vuelvas, J., Correa, C. A., Vallejo, V. E., Patino, D., 2022. Machine learning and remote sensing techniques applied to estimate soil indicators–review. *Ecological Indicators*, 135, 108517. <https://doi.org/10.1016/j.ecolind.2021.108517>
 46. Doorn, N., 2021. Artificial intelligence in the water domain: opportunities for responsible use. *Science of the Total Environment*, 755, 142561. <https://doi.org/10.1016/j.scitotenv.2020.142561>
 47. Douarre, C., Schielein, R., Frindel, C., Gerth, S., Rousseau, D., 2018. Transfer learning from synthetic data applied to soil–root segmentation in x-ray tomography images. *Journal of Imaging*, 4(65) <https://doi.org/10.3390/jimaging4050065>
 48. Emadi, M., Taghizadeh-Mehrjardi, R., Cherati, A., Danesh, M., Mosavi, A., Scholten, T., 2020. Predicting and mapping of soil organic carbon using machine learning algorithms in northern Iran. *Remote Sensing*, 12(14), 2234.

49. Emamgholizadeh, S., Bazoobandi, A., Mohammadi, B., Ghorbani, H. & Amel Sadeghi, M., 2022. Prediction of soil cation exchange capacity using enhanced machine learning approaches in the southern region of the Caspian Sea. *Ain Shams Engineering Journal*, 14(2). <https://doi.org/10.1016/j.asej.2022.101876>
50. European Commission, 2019. High-level expert group on artificial intelligence. Ethics guidelines for trustworthy AI, 6.
51. Fajardo, M., McBratney, A. B., Field, D. J., Minasny, B., 2016. Soil slaking assessment using image recognition. *Soil and Tillage Research*, 163, pp. 119–129. <https://doi.org/10.1016/j.still.2016.05.018>
52. Fantappiè, M., L'Abate, G., Schillaci, C., Costantini, E. A. C., 2023. Digital soil mapping of Italy to map derived soil profiles with neural networks. *Geoderma Regional*, 32, e00619. <https://doi.org/10.1016/j.geodrs.2023.e00619>
53. Ferreira, T. R., Cássaro, F. A. M., Zhou, H., Pires, L. F., 2022. X-ray computed tomography image processing & segmentation: a case study applying machine learning and deep learning-based strategies, in x-ray imaging of the soil porous architecture. Edited by Mooney, S. J., Young, I. M., Heck, R. J., Peth, S., 57–80. Springer Cham. https://doi.org/10.1007/978-3-031-12176-0_5
54. Fisher, P. F., 1989. Expert system applications in geography. *Area*, 21, pp. 279–287.
55. Galbraith, J. M., Bryant, R. B., 1998. A functional analysis of soil taxonomy in relation to expert system techniques. *Soil Science*, 163, pp. 739–747.
56. Galbraith, J. M., Bryant, R. B., Ahrens, R. J., 1998. An expert system for soil taxonomy. *Soil Science*, 163, pp. 748–758.
57. Ghorbani, A., Sadeghi, M., Jones, S. B., 2021. Towards new soil water flow equations using physics-constrained machine learning. *Vadose Zone Journal*, 20, e20136. <https://doi.org/10.1002/vzj2.20136>
58. Gibney, E., 2024. The AI revolution is coming to robots: How will it change them. *Nature*, 8015(630), pp. 22–24. <https://doi.org/10.1038/d41586-024-01442-5>
59. Grunwald, S., 2022. Artificial intelligence and soil carbon modeling demystified: power, potentials, and perils. *Carbon Footprints*, 1, pp. 1–5. <https://doi.org/10.20517/cf.2022.03>
60. Gruszczyński, S., Gruszczyński, W., 2022. Supporting soil and land assessment with machine learning models using the vis-nir spectral response. *Geoderma*, 405, 115451.
61. Haenlein, M., Kaplan, A., 2019. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), pp. 5–14. <https://doi.org/10.1177/0008125619864925>
62. Haghverdi, A., Cornelis, W., Ghahraman, B., 2012. A PseudoContinuous Neural Network Approach for Developing Water Retention Pedotransfer Functions with Limited Data. *Journal of Hydrology*, 442, pp. 46–54. <https://doi.org/10.1016/j.jhydrol.2012.03.036>
63. Han, Q., Bai, H., Liu, L., Zhao, Y., Zhao, Y., 2021. Model representation and quantitative analysis of pore three-dimensional morphological structure based on soil computed tomography images. *European Journal of Soil Science*, 72, pp. 1530–1542. <https://doi.org/10.1111/ejss.13072>
64. Han, Q., Zhao, Y., Liu, L., Chen, Y., Zhao, Y., 2019. A simplified convolutional network for soil pore identification based on computed tomography imagery. *Soil Science Society of America Journal*, 83, pp. 1309–1318. <https://doi.org/10.2136/sssaj2019.04.0119>
65. Hartemink, A. E., 2006. The future of soil science. *Iuss international union of soil sciences*.
66. Hasanvand, S., Sepahvand, A., Beiranvand, N., Arjmand, N., 2025. Performance assessment of the artificial intelligence models for prediction of the infiltration rate in the Surface Soil of Geological Formations (Case Study: Aleshtar Watershed, Lorestan Province). *Water and Soil Management and Modelling*, 5(2), pp. 290–308 (In Persian) <https://doi.org/10.22098/mmws.2025.16276.1520>
67. Hastings, J., 2023. AI for scientific discovery. CRC Press.
68. Hengl, T., M. A. Miller, J. Križan, et al. 2021. African soil properties and nutrients mapped at 30 m spatial resolution using two-scale ensemble machine learning. *Scientific Reports* 11: 6130.

69. Heung, B., Ho, H. C., Zhang, J., Knudby, A., Bulmer, C. E., Schmidt, M. G., 2016. An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma*, 265, pp. 62–77.
<https://doi.org/10.1016/j.geoderma.2015.11.014>
70. Heuvelink, G. B. M., Angelini, M. E., Poggio, L., 2021. Machine learning in space and time for modelling soil organic carbon of natural language processing for metadata extraction for modelling soil organic carbon change. *European Journal of Soil Science*, 72, pp. 1607–1623. **<https://doi.org/10.1111/ejss.12998>**
71. Holt, D., 1978. Potentials for artificial intelligence and supercomputers in soil science, in future developments in soil science research. American society of agronomy, edited by Boersma, L. L., pp. 459–468. **<https://doi.org/10.2136/1987.futuredevelopmentssoil.c49>**
72. Hosseini, M., Bahrami, H., Khormali, F., 2021. Artificial intelligence statistical analysis of soil respiration improves predictions compared to regression methods. *Journal of Soil Science and Plant Nutrition*, 21, 2242–2251.
<https://doi.org/10.1007/s42729-021-00517-w>
73. Hou, L. H., Gao, W., Weng, Z. H., 2022. Use of X-ray tomography for examining root architecture in soils. *Geoderma*, 405, 115405.
<https://doi.org/10.1016/j.geoderma.2021.115405>
74. Hutter, M., 2012. One decad of universal artificial intelligence. *Theoretical Foundation of Artificial General Intelligence*, pp. 66–88, Paris: Atlantis Press.
https://doi.org/10.2991/978-94-91216-62-6_5
75. Iqbal, J., Xu, R., Halloran, H., Li, C., 2020. Development of a Multi-Purpose Autonomous Differential Drive Mobile Robot for Plant Phenotyping and Soil Sensing. *Electronics*, 9, 1550. **<https://doi.org/10.3390/electronics9091550>**
76. Jafarian, Z., Ghorbani, Z., 2024. Prediction of soil carbon sequestration in rangelands regarding the depth and elevation of sample locations using adaptive neuro-fuzzy inference system (ANFIS) (Case Study: Lar watershed). *Journal of Watershed Management Research*. 15(2), pp. 142–153. (In Persian) **<https://doi.org/10.61186/jwmr.15.2.142>**
77. Jalilvand, K., Farhadi, B. B., Ghobadian, R., 2023. Comparative study on the models and pedotransfer functions for estimating parameters describing soil moisture characteristic curve (Case Study: Mahidasht, Kermanshah province). *Irrigation and Water Engineering*, 13(3), pp. 421–436. (In Persian) **<https://doi.org/10.22125/iwe.2023.169908>**
78. Ji, W., Adamchuk, V. I., Chen, S., 2019. Simultaneous measurement of multiple soil properties through proximal sensor data fusion: a case study. *Geoderma*, 341, pp. 111–128.
<https://doi.org/10.1016/j.geoderma.2019.01.006>
79. Jorda, H., Bechtold, M., Jarvis, N., Koestel, J., 2015. Using boosted regression trees to explore key factors controlling saturated and near-saturated hydraulic conductivity. *European Journal of Soil Science*, 66, pp. 744–756.
80. Kaur, R., Malik, R., Paul, M., 2007. Long-term effects of various crop rotations for managing salt-affected soils through a field scale decision support system—a case study. *Soil Use and Management*, 23, pp. 52–62.
<https://doi.org/10.1111/j.1475-2743.2006.00055.x>
81. Kerebel, A., Cassidy, R., Jordan, P., Holden, N. M., 2013. Soil moisture deficit as a predictor of the trend in soil water status of grass fields. *Soil Use and Management*, 29, pp. 419–431. **<https://doi.org/10.1111/sum.12054>**
82. Khaledian, Y., Miller, B. A., 2020. “Selecting Appropriate Machine Learning Methods for Digital Soil Mapping. *Applied Mathematical Modelling*, 81, pp. 401–418.
<https://doi.org/10.1016/j.apm.2019.12.016>
83. Kitić, G., Krklješ, D., Panić, M., Petes, C., Birgermajer, S., Crnojević, V., 2022. Agrobot Lala—an autonomous robotic system for real-time, in-field soil sampling, and analysis of nitrates. *Sensors*, 22, 4207. **<https://doi.org/10.3390/s22114207>**
84. Koekkoek, E. J. W., Booltink, H., 1999. Neural network models to predict soil water retention. *European Journal of Soil Science*, 50, pp. 489–495.
<https://doi.org/10.1046/j.1365-2389.1999.00247.x>

85. Lacoste, M., Lemerrier, B., Walter, C., 2011. Regional mapping of soil parent material by machine learning based on point data. *Geomorphology*, 133, pp. 90–99.
<https://doi.org/10.1016/j.geomorph.2011.06.026>
86. Lacoste, M., Minasny, B., McBratney, A. B., Michot, D., Viaud, V., Walter, C., 2014. High resolution 3d mapping of soil organic carbon in a heterogeneous agricultural landscape. *Geoderma*, 213, pp. 296–311. **<https://doi.org/10.1016/j.geoderma.2013.07.002>**
87. Lavrukhin, E. V., Gerke, K. M., Romanenko, K. A., Abrosimov, K. N., Karsanina, M. V., 2021. Assessing the fidelity of neural network-based segmentation of soil xct images based on porescale modelling of saturated flow properties. *Soil and Tillage Research*, 209, 104942. **<https://doi.org/10.1016/j.still.2021.104942>**
88. Legg, S., Hutter, M., 2007. Universal intelligence: a definition of machine intelligence. *Minds and Machines*, 17, pp. 391–444. **<https://doi.org/10.1007/s11023-007-9079-x>**
89. Li, X., Wang, H., Qin, S., Lin, L., Wang, X., Cornelis, W., 2024. Evaluating ensemble learning in developing pedotransfer functions to predict soil hydraulic properties. *Journal of Hydrology*, 640, 131658. **<https://doi.org/10.1016/j.jhydrol.2024.131658>**
90. Liu, X., Zhu, A., -X., Yang, L., 2020. A graded proportion method of training sample selection for updating conventional soil maps. *Geoderma*, 357, 113939.
91. Lu, C., C. Lu, R. T. Lange, J. Foerster, J. Clune, and D. Ha. 2024. The AI scientist: towards fully automated open-ended scientific discovery. Available at: <https://www.arxiv.org/abs/2408.06292>, Accessed: September 26, 2024.
92. Luo, L., Lin, H., Hallecl, P., 2008. Quantifying soil structure and preferential flow in intact soil using x-ray computed tomography, *SSSAJ*, 72(4), pp. 1058-1069.
<https://doi.org/10.2136/sssaj2007.0179>
93. MacMillan, R. A., Pettapiece, W. W., Brierley, J. A., 2005. An expert system for allocating soils to landforms through the application of soil survey tacit knowledge. *Canadian Journal of Soil Science*, 85, 103–112.
94. Maghsodi, Z., Rostaminia, M., Faramarzi, M., Keshavarzi, A., Rahmani, A., Mousavi, S. R., 2020, Digital mapping of soil family class using the machine learning approach (a case study: semi-arid lands in the west of Iran). *Journal of Water and Soil Science*, 24(2), pp.153-163. (In Persian) **<https://doi.org/10.47176/jwss.24.2.32993>**
95. Mahmoudi, M., Momtaz, H., Servati, M., Mohammadi, H., 2024. Digital soil mapping by machine learning techniques. *Journal of Soil and Plant Science*, 34(4), pp. 1–14. (in Persian) **<https://doi.org/10.22034/sps.2024.19179>**
96. Malone, B. P., Luo, Z., He, D., Rossel, R. A. V., Wang, E., 2020. Bioclimatic variables as important spatial predictors of soil hydraulic properties across Australia’s agricultural region. *Geoderma Regional*, 23, e00344. **<https://doi.org/10.1016/j.geodrs.2020.e00344>**
97. McBratney, A. B., 2024. Developing the new soil science—advice for early-career soil scientists. *Pedosphere*, 34, pp. 3–4.
98. McBratney, A. B., Odeh, I. O. A., 1997. Application of fuzzy sets in soil science: fuzzy logic, fuzzy measurements and fuzzy decisions. *Geoderma*, 77, pp. 85–113.
99. McBratney, A. B., Santos, M. L. M., Minasny, B., 2003. On digital soil mapping. *Geoderma*, 117, pp. 3–52. **[https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)**
100. McCarthy, J., 2007. What is artificial intelligence? Available at <http://www.formal.stanford.edu/jmc/>, accessed: 21 July 2025
101. McCarthy, J., Minsky, M. L., Rochester, N., Shannon, C. E. 1955, A proposal for the dartmouth summer research project on artificial intelligence
102. McCracken, R. J., Cate, R. B., 1986. Artificial intelligence, cognitive science, and measurement theory applied in soil classification. *Soil Science Society of America Journal*, 50, pp. 557–561.
103. McCulloch, W. S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, pp. 115–133.
104. McShea, D. W., 2013. Machine wanting, studies in history and philosophy of science part C. *Studies in History and Philosophy of Biological and Biomedical Sciences*, 44, pp. 679–687.

105. Mehrabi Gohari, E., Matinfar, H., Taghizadeh-Mehrjardi, R., Jafari, A. 2020a. Visible-Near infrared (VIS-NIR) spectrophotometry in predicting soil particle percentage using artificial neural network and partial least squares regression. *Water and Soil*, 34(3), pp. 623-635. (in Persian) <https://doi.org/10.22067/v34i2.80806>
106. Mehrabi Gohari, E., Matinfar, H. R., Jafari, A., Taghizadeh-Mehrjardi, R., khayamim, F. 2020b. Comparing Different Statistical Models and Pre-processing Techniques for Estimation several chemical properties of the soil Using VNIR/SWIR Spectrum. *Iranian Journal of Remote Sensing and GIS*, 11(4), pp. 47-60. (in Persian) <https://doi.org/10.52547/gisj.11.4.47>
107. Mehrabi Gohari, E., Shahriyari-pour, R., Tagabadipoor, A., Mousavi, S, R., 2025, Digital mapping of soil texture components in the sirjan region using machine learning models. *Journal of Rang and Watershed management*, 78(2), pp. 265-288. (In Persian) [10.22059/jrwm.2024.375890.1760](https://doi.org/10.22059/jrwm.2024.375890.1760)
108. Merriam-Webster, 2025. Artificial intelligence. Available at: <https://www.merriam-webster.com/dictionary/artificial%20intelligence>, accessed: 21 July 2025
109. Minasny, B., Bandai, T., Ghezzehei, T, A., 2024. Soil science informed machine learning. *Geoderma*, 452, 117094. <https://doi.org/10.1016/j.geoderma.2024.117094>
110. Minasny, B., Berglund, O., Connolly, J., 2019. Digital mapping of peatlands—a critical review. *Earth-Science Reviews*, 196,
111. Minasny, B., Chaney, N, W., Maggi, F., 2021. Pedotransfer functions for estimating soil hydraulic properties from saturation to dryness. *Geoderma*, 403, pp.115194. <https://doi.org/10.1016/j.geoderma.2021.115194>
112. Minasny, B., McBratney, A, B., 2002. The neurom method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66, pp. 352–361. <https://doi.org/10.2136/sssaj2002.0352>
113. Minasny, B., McBratney, A, B., 2016. Digital soil mapping: a brief history and some lessons. *Geoderma*, 264, pp. 301–311. <https://doi.org/10.1016/j.geoderma.2015.07.017>
114. Minasny, B., McBratney, A, B., Malone, B, P., Wheeler, I., 2013. Digital mapping of soil carbon. *Advances in Agronomy*, 118, pp. 1–47. <https://doi.org/10.1016/B978-0-12-405942-9.00001-3>
115. Minsky, M, L., 1969. Semantic information processing. MIT Press.
116. Montas, H., Madramootoo, C, A., 1992. A decision support system for soil conservation planning. *Computers and Electronics in Agriculture*, 7, pp. 187–202.
117. Moradian, S., Nabiollahi, K., Taghizadeh, R. 2018. Prediction of soil salinity using tree regression and artificial neural network in Ghorveh soils, Kurdistan Province. *Journal of Soil Management and Sustainable Production*, 7(4), pp. 115-129. (In Persian) <https://doi.org/10.22069/ejsms.2018.13223.1741>
118. Mulder, V. L., De Bruin, S., Schaepman, M, E., Mayr, T, R., 2011. The use of remote sensing in soil and terrain mapping—a review. *Geoderma*, 162, pp. 1–19. <https://doi.org/10.1016/j.geoderma.2010.12.018>
119. Namdar, K, D., Sharfa, M., Omid, M., 2011. Estimating soil volumetric moisture using artificial neural networks. *Iran-Watershed Management Science & Engineering*, 5(14), pp. 53-60.
120. Nawar, S., Mouazen, A, M., 2022. Combining mid infrared spectroscopy with stacked generalisation machine learning for prediction of key soil properties. *European Journal of Soil Science*, 73, e13323. <https://doi.org/10.1111/ejss.13323>
121. Nemes, A., Rawls, W, J., Pachepsky, Y, A., 2005. Influence of organic matter on the estimation of saturated hydraulic conductivity. *Soil Science Society of America Journal*, 69, pp. 1330–1337. <https://doi.org/10.2136/sssaj2004.0055>
122. Nemes, A., Rawls, W, J., Pachepsky, Y, A., van Genuchten, M, T., 2006. Sensitivity analysis of the nonparametric nearest neighbor technique to estimate soil water retention. *Vadose Zone Journal*, 5, pp. 1222–1235. <https://doi.org/10.2136/vzj2006.0017>
123. Nestor, M., Loredana, F., Raymond, P., 2024. The AI index 2024 annual report. AI Index Steering Committee. Institute for HumanCentered AI, Stanford University

124. Ng, W., Minasny, B., Mendes, W, D, S., Demattê, J, A, M., 2020. The influence of training sample size on the accuracy of deep learning models for the prediction of soil properties with near-infrared spectroscopy data. *Soil*, 6, pp. 565–578. <https://doi.org/10.5194/soil-6-565-2020>
125. Nilsson, N, J., 1984, Shakey the Robot. Technical note 323, AI Center, SRI International.
126. Nouraki, A., Golabi, M., Albaji, M., Naseri, A., Homayouni, S., 2023. Spatial-temporal modeling of soil moisture using optical and thermal remote sensing data and machine learning algorithms. *Iranian Journal of Soil and Water Research*, 54(4), pp. 637-653. (In Persian) <https://doi.org/10.22059/ijswr.2023.356707.669469>
127. Nouri, H., Ildoromi, A., Sepehri, M., Artimani, M. 2019. Comparing three main methods of artificial intelligence in flood estimation in yalphan catchment. *Geography and Environmental Planning*, 29(4), pp. 35-50. (In Persian) <https://doi.org/10.22108/gep.2018.98036.0>
128. Odebiri, O., Odindi, J., Mutanga, O., 2021. Basic and deep learning models in remote sensing of soil organic carbon estimation: a brief review. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102389. <https://doi.org/10.1016/j.jag.2021.102389>
129. Odgers, N, P., McBratney, A, B., Minasny, B., 2015. Digital Soil Property Mapping and Uncertainty Estimation Using Soil Class Probability Rasters. *Geoderma*, 237, pp. 190–198. <https://doi.org/10.1016/j.geoderma.2014.09.009>
130. Odgers, N, P., McBratney, A, B., Minasny, B., Sun, W., Clifford, D., 2014. DSMART: An algorithm to spatially disaggregate soil map units, in *globalsoilmap: Basis of the Global Spatial Soil Information*. <https://doi.org/10.1201/b16500-49>
131. Pachepsky, Y, A., Schaap, M, G., 2004. Data mining and exploration techniques. *Developments in Soil Science*, 30, pp. 21–32.
132. Pachepsky, Y., Rawls, W, J., 2004. Development of Pedotransfer Functions in Soil Hydrology. *Development in Soil Science*, 30.
133. Padarian, J., Fuentes, I., 2019. Word embeddings for application in geosciences: development, evaluation, and examples of soil-related concepts. *Soil*, 5, pp. 177–187. <https://doi.org/10.5194/soil-5-177-2019>, 2019.
134. Padarian, J., McBratney, A, B., 2020. A new model for intra- and inter-institutional soil data sharing. *Soil*, 6, pp. 89–94. <https://doi.org/10.5194/soil-6-89-2020>, 2020.
135. Padarian, J., Minasny, B., McBratney, A, B., 2019. Using deep learning to predict soil properties from regional spectral data. *Geoderma Regional*, 16, e00198. <https://doi.org/10.1016/j.geodrs.2018.e00198>
136. Padarian, J., Minasny, B., McBratney, A, B., 2020. Machine learning and soil sciences: a review aided by machine learning tools. *Soil*, 6, pp. 35–52. <https://doi.org/10.5194/soil-6-35-2020>, 2020.
137. Palangi, A, J., Gholami, S, M, A., Bahmanyar, M, A., 2019. Effect of surfactant concentration on zeolite modification for nitrate removal and its simulation with kinetics models and Anfis in fixed-bed column. *Journal of Water and Wastewater*, 30(3), pp. 73-86. (In Persian) <https://doi.org/10.22093/wwj.2018.110863.2567>
138. ParchamiAragi, A., Mirlatifi, S, M., Gorbani, D, SH., Mahdian, M, H., 2010. Estimating cumulative infiltration using artificial neural networks in calcareous soils. *Journal of Water and Soil*, 24(3), pp.512-526. (In Persian) <https://doi.org/10.22067/jsw.v0i0.3622>
139. Parsaie, F., Farrokhian, F, A., Davari, M., Taghizadeh-Mehrjardi, R., 2025, Digital mapping of soil penetration resistance and shear strength using machine learning algorithms in the kilane watershed, kurdistan province. *Journal of Rang and Watershed Management*, 78(1), pp. 124-143. (In Persian) [10.22059/jrwm.2025.389637.1801](https://doi.org/10.22059/jrwm.2025.389637.1801)
140. Parviz, L., Azizi, N., kaili, M. 2024. Spectral analysis-artificial intelligence model with spatial variables for some soil chemical properties estimation. *Water and Soil Management and Modelling*, 4(3), pp. 321-338. (In Persian) <https://doi.org/10.22098/mmws.2023.13308.1321>

141. Piikki, K., Wetterlind, J., Söderström, M., Stenberg, B., 2021. Perspectives on validation in digital soil mapping of continuous attributes—a review. *Soil Use and Management*, 37, pp. 7–21. <https://doi.org/10.1111/sum.12694>
142. Piri, H., Mobaraki, M., 2022. Comparison of artificial intelligence and geostatistical methods in soil surface salinity prediction in Ghorghori, Hirmand. *Environment and Water Engineering*, 8(3), pp. 622-635. (In Persian)
<https://doi.org/10.22034/jewe.2022.312194.1656>
143. Poggio, L., De Sousa, L, M., Batjes, N, H., 2021. SoilGrids 2.0: Producing soil information for the globe with quantified spatial uncertainty. *Soil*, 7, pp. 217–240.
<https://doi.org/10.5194/soil-7-217-2021>
144. Pournader, M., Ghaderi, H., Hassanzadegan, A., Fahimnia, B., 2021. Artificial intelligence applications in supply chain management. *International Journal of Production Economics*, 241, 108250. <https://doi.org/10.1016/j.ijpe.2021.108250>
145. Power, D, J., 2007. A brief history of decision support systems. Accessed July 17, 2025.
146. Priori, S., Bianconi, N., Costantini, E, A, C., 2014. Can radiometrics predict soil textural data and stoniness in different parent materials? A comparison of two machine-learning methods. *Geoderma*, 226, pp. 354–364.
147. Rahimi Mashkale, M, M., Delavar, M, A., Jamshidi, M., Sharififar, A., 2023, Improving the classification of soil imbalanced data using machine learning algorithms in Some Part of Zanjan province land. *Agricultural Engineering Scientific Journal of Agriculture*, 46 (1), pp. 61-81. (In Persian) <https://doi.org/10.22055/agen.2023.43838.1667>
148. Ramesh, A., Pavlov, M., Goh, G., Gray, S., Voss, C., Radford, A., Chen, M., Sutskever, I., 2021, Zero-Shot Text-to-Image Generation. *Proceedings of the 38th International Conference on Machine Learning (ICML)*, pp.8821–8831.
149. Rezaei, M., Mousavi, S, R., Rahmani, A., 2023. Incorporating machine learning models and remote sensing to assess the spatial distribution of saturated hydraulic conductivity in a light-textured soil. *Computers and Electronics in Agriculture*, 209,107821.
<https://doi.org/10.1016/j.compag.2023.107821>
150. Romero-Ruiz, A., O'Leary, D., Daly, E., 2024. An agrogeophysical modelling framework for the detection of soil compaction spatial variability due to grazing using field-scale electromagnetic induction data. *Soil Use and Management*, 40, e13039.
<https://doi.org/10.1111/sum.13039>
151. Russell, S. J., Norvig, P., 2010, *Artificial Intelligence: A modern approach*. 3rd ed. Upper Saddle River, NJ: Prentice Hall.
152. Russell, S. J., Norvig, P., 2016. *Artificial intelligence: a modern approach*. Pearson, Ed 3rd.
153. Saadatpour, M., Afshar, A., Afshar, M, H., 2011. Fuzzy pattern recognition method for assessing soil erosion. *Environmental Monitoring and Assessment*, 180, pp. 385–397.
<https://doi.org/10.1007/s10661-010-1794-8>
154. Sakizadeh, M., Mirzaei, R., Ghorbani, H., 2017. Support vector machine and artificial neural network to model soil pollution: (a case study in Semnan province, Iran). *Neural Comput & Applic*, 28, pp. 3229–3238. <https://doi.org/10.1007/s00521-016-2231-x>
155. Sandén, T., Trajanov, A., Spiegel, H., 2019. Development of an agricultural primary productivity decision support model: a case study in France. *Frontiers in Environmental Science*, 7, 58. <https://doi.org/10.3389/fenvs.2019.00058>
156. Sarangi, A., Madramootoo, C, A., Cox, C., 2004. A decision support system for soil and water conservation measures on agricultural watersheds. *Land Degradation & Development*, 15, pp. 49–63. <https://doi.org/10.1002/ldr.589>
157. Schaap, M. G., F. J. Leij, and M. T. Van Genuchten. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal*, 62, pp. 847–855.
158. Schröder, J. J., Schulte, R, P, O., Creamer, R, E., 2016. The elusive role of soil quality in nutrient cycling: a review. *Soil Use and Management*, 32, pp. 476–486.
<https://doi.org/10.1111/sum.12288>

159. Schweizer, S. A., Hoeschen, C., Schlüter, S., Kögel-Knabner, I., Mueller, C. W., 2018. Rapid soil formation after glacial retreat shaped by spatial patterns of organic matter accrual in microaggregates. *Global Change Biology*, 24, pp. 1637–1650.
<https://doi.org/10.1111/gcb.14014>
160. Schwenke, G., Beange, L., Cameron, J., Bell, M., Harden, S., 2019. What soil information do crop advisors use to develop nitrogen fertilizer recommendations for grain growers in New South Wales, Australia. *Soil Use and Management*, 35, pp. 85–93.
<https://doi.org/10.1111/sum.12469>
161. Sedaghat, A., Shabanpour, M., Noroozi, A., Fallah Nosratabad, A., Bayat, H. 2022, The use of spectral indices to estimate soil surface moisture using machine learning algorithms. *Iranian Journal of Soil and Water Research*, 52(12), pp. 3001-3018. (In Persian)
<https://doi.org/10.22059/ijswr.2022.333856.669130>
162. Sharififar, A., Sarmadian, F., Malone, B. P., Minasny, B., 2019. Addressing the issue of digital mapping of soil classes with imbalanced class observations. *Geoderma*, 350, pp. 84–92. **<https://doi.org/10.1016/j.geoderma.2019.05.016>**
163. Shen, Z., Ramirez-Lopez, L., Behrens, T., 2022. Deep transfer learning of global spectra for local soil carbon monitoring. *ISPRS Journal of Photogrammetry and Remote Sensing*, 188, pp.190–200. **<https://doi.org/10.1016/j.isprsjprs.2022.04.009>**
164. Shen, Z., Viscarra Rossel, R. A., 2021. Automated spectroscopic modelling with optimised convolutional neural networks. *Scientific Reports*, 11, 208.
<https://doi.org/10.1038/s41598-020-80486-9>
165. Shortliffe, E. H., 1976. *Computer-based medical consultations: MYCIN*. New York, Elsevier.
166. Sihang, V. P., Angelaki, A., Kumar, V., Sepahvand, A., Golia, E., 2019. Modelling of infiltration using artificial intelligence techniques in semi-arid Iran. *Hydrological Sciences Journal*, 64(13), 1647-1558. **<https://doi.org/10.1080/02626667.2019.1659965>**
167. Sikora, F. J., Howe, P., Reid, D., Morgan, D., Zimmer, E., 2011. Adopting a robotic ph instrument for soil and soil-buffer ph measurements in a soil test laboratory. *Communications in Soil Science and Plant Analysis*, 42, pp. 617–632.
<https://doi.org/10.1080/00103624.2011.550371>
168. Skidmore, A. K., Ryan, P. J., Dawes, W., Short, D., O'LOUGHLIN, E., 1991. Use of an expert system to map forest soils from a geographical information system. *International Journal of Geographical Information Systems*, 5, pp. 431–445.
<https://doi.org/10.1080/02693799108927867>
169. Smaling, E. M. A., Fresco, L. O., 1993. A decision-support model for monitoring nutrient balances under agricultural land use (NUTMON). *Geoderma*, 60, pp. 235–256.
170. Smith, A. G., Petersen, J., Selvan, R., Rasmussen, C. R., 2020. Segmentation of roots in soil with U-Net. *Plant Methods*, 16, 13.
171. Soltaninejad, M., Sturrock, C. J., Griffiths, M., Pridmore, T. P., Pound, M. P., 2020. Three-dimensional root ct segmentation using multiresolution encoder-decoder networks. *IEEE Transactions on Image Processing*, 29, pp. 6667–6679.
<https://doi.org/10.1109/TIP.2020.2992893>
172. Steffens, M., Rogge, D. M., Mueller, C. W., 2017. Identification of distinct functional microstructural domains controlling c storage in soil. *Environmental Science & Technology*, 51, pp. 12182–12189. **<https://doi.org/10.1021/acs.est.7b03715>**
173. Steinruecken, C., Smith, E., Janz, D., Lloyd, J., Ghahramani, Z., 2019. The automatic statistician, in *automated machine learning: methods, systems, challenges*. Edited by Hutter, F., Kotthoff, L., Vanschoren, J., pp. 161–173. Springer International Publishing.
174. Taghizadeh Mehrjerdi, R., Amirian Chekan, A., Sarmadian, F. 2015. 3D digital mapping of soil cation exchange capacity in dorud, lorestan province. *Water and Soil*, 28(5), pp. 998-1010 (In Persian) **<https://doi.org/10.22067/jsw.v0i0.27761>**
175. Tamari, S., Wösten, J. H. M., Ruiz-Suarez, J. C., 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society of America Journal*, 60, pp. 1732–1741.
176. Turing, A. M., 1950, Computing machinery and intelligence. *Mind*, 59(236), pp. 433–460.

177. Twarakavi, N, K, C., Simunek, J., Schaap, M, G., 2009. Development of pedotransfer functions for estimation of soil hydraulic parameters using support vector machines. *Soil Science Society of America Journal*, 73, pp. 1443–1452.
<https://doi.org/10.2136/sssaj2008.0021>
178. Van Alphen, B, J., Stoorvogel, J, J., 2000. A functional approach to soil characterization in support of precision agriculture. *Soil Science Society of America Journal*, 64, pp. 1706–1713. **<https://doi.org/10.2136/sssaj2000.6451706x>**
179. Van der Westhuizen, S., Heuvelink, G, B, M., Hofmeyr, D, P., 2023. Multivariate random forest for digital soil mapping. *Geoderma*, 431, 116365.
<https://doi.org/10.1016/j.geoderma.2023.116365>
180. Van Leeuwen, J, P., Creamer, R, E., Cluzeau, D., 2019. Modeling of soil functions for assessing soil quality: soil biodiversity and habitat provisioning. *Frontiers in Environmental Science*, 7, 113. **<https://doi.org/10.3389/fenvs.2019.00113>**
181. Van Looy, K., Bouma, J., Herbst, M., 2017. Pedotransfer functions in earth system science: challenges and perspectives. *Reviews of Geophysics*, 55, pp. 1199–1256.
<http://dx.doi.org/10.1002/2017RG000581>
182. Vereecken, H., Weynants, M., Javaux, M., Pachepsky, Y., Schaap, M, G., Van Genuchten, M, T 2010. Using pedotransfer functions to estimate the van genuchten–mualem soil hydraulic properties: a review. *Vadose Zone Journal*, 9, pp. 795–820.
<https://doi.org/10.2136/vzj2010.0045>
183. Vincent, S., Lemerrier, B., Berthier, L., Walter, C., 2018. Spatial disaggregation of complex soil map units at the regional scale based on soil-landscape relationships. *Geoderma*, 311, pp. 130–142. **<https://doi.org/10.1016/j.geoderma.2016.06.006>**
184. Viscarra Rossel, R, A., Adamchuk, V, I., Sudduth, K, A., McKenzie, N, J., Lobsey, C., 2011. Proximal soil sensing: an effective approach for soil measurements in space and time. *Advances in Agronomy*, 113, pp. 243–291.
<https://doi.org/10.1016/B978-0-12-386473-4.00005-1>
185. Viscarra Rossel, R, A., Behrens, T., 2010. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma*, 158, pp. 46–54.
<https://doi.org/10.1016/j.geoderma.2009.12.025>
186. Wadoux, A, M, J, -C., 2023. Interpretable spectroscopic modelling of soil with machine learning. *European Journal of Soil Science*, 74: e13370.
<https://doi.org/10.1111/ejss.13370>
187. Wadoux, A, M, J, -C., 2025. Artificial intelligence in soil science. *European Journal of Soil Science*, 76, e70080. **<https://doi.org/10.1111/ejss.70080>**
188. Wadoux, A, M, J, -C., McBratney, A, B., 2021. Digital soil science and beyond. *Soil Science Society of America Journal*, 85, pp. 1313–1331.
<https://doi.org/10.1002/saj2.20296>
189. Wadoux, A, M, J, -C., Saby, N., Martin, M, P., 2023. Shapley values reveal the drivers of soil organic carbon stock prediction. *Soil*, 9, pp. 21–38. <https://doi.org/10.5194/soil-9-21-2023>, 2023. **<https://doi.org/10.5194/soil-9-21-2023>**
190. Wadoux, A, M, J, -C., Samuel-Rosa, A., Poggio, L., Mulder, V, L., 2020. A note on knowledge discovery and machine learning in digital soil mapping. *European Journal of Soil Science*, 71, pp. 133–136. **<https://doi.org/10.1111/ejss.12909>**
191. Wall, D, P., Delgado, A., O'Sullivan, L., 2020. A decision support model for assessing the water regulation and purification potential of agricultural soils across Europe. *Frontiers in Sustainable Food Systems*, 4, 115. **<https://doi.org/10.3389/fsufs.2020.00115>**
192. Wang, J., Ding, J., Yu, D., 2020. Machine learning-based detection of soil salinity in an arid desert region, northwest china: a comparison between landsat-8 oli and sentinel-2 MSI. *Science of the Total Environment*, 707, 136092.
<https://doi.org/10.1016/j.scitotenv.2019.136092>
193. Wang, Y., Zhou, J., Ma, R., Zhu, G., Zhang, Y., 2022. Development of a new pedotransfer function addressing limitations in soil hydraulic models and observations. *Water Resources Research*, 58, e2021WR031406.

194. Weizenbaum, J., 1966. ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), pp. 36–45.
195. Wieland, R., Ukawa, C., Joschko, M., 2021. Use of deep learning for structural analysis of computer tomography images of soil samples. *Royal Society Open Science*, 8, 201275. <https://doi.org/10.1098/rsos.201275>
196. Xu, S., Zhao, Y., Wang, M., Shi, X., 2022. a comparison of machine learning algorithms for mapping soil iron parameters indicative of pedogenic processes by hyperspectral imaging of intact soil profiles. *European Journal of Soil Science*, 73, e13204. <https://doi.org/10.1111/ejss.13204>
197. Young, M, D., Ros, G, H., de Vries, W., 2021. A decision support framework assessing management impacts on crop yield, soil carbon changes and nitrogen losses to the environment. *European Journal of Soil Science*, 72, pp. 1590–1606. <https://doi.org/10.1111/ejss.13024>
198. Zhang, M., Shi, W., Xu, Z., 2020. Systematic comparison of five machine-learning models in classification and interpolation of soil particle size fractions using different transformed data. *Hydrology and Earth System Sciences*, 24, pp. 2505–2526. <https://doi.org/10.5194/hess-24-2505-2020>
199. Zhang, T., Berndtsson, R., 1991. Analysis of soil water dynamics in time and space by use of pattern recognition. *Water Resources Research*, 27, pp.1623–1636. <https://doi.org/10.1029/91WR00436>
200. Zhang, W., Zhu, L., Zhuang, Q., Chen, D., Sun, T., 2023. Mapping cropland soil nutrients contents based on multi-spectral remote sensing and machine learning. *Agriculture*, 13, 1592. <https://doi.org/10.3390/agriculture13081592>
201. Zhou, Y., 2022, Digital twin for soil: A new paradigm for soil monitoring and sustainable land management. *Geoderma*, 423, 115964.
202. Zwetsloot, M, J., van Leeuwen, J., Hemerik, L., 2021. Soil multifunctionality: synergies and trade-offs across European climatic zones and land uses. *European Journal of Soil Science*, 72, pp. 1640–1654. <https://doi.org/10.1111/ejss.13051>