

Deep learning prediction of continuous soil–water retention curves in low-plasticity soils

Fatemeh Razani¹ , Ali Reza Bagherieh^{2✉}

1. Department of Civil Engineering, School of Civil Engineering and Architecture, Malayer University, Malayer, Iran. Email: fatemeh.razani@stu.malayeru.ac.ir
2. Corresponding Author, Department of Civil Engineering, School of Civil Engineering and Architecture, Malayer University, Malayer, Iran. Email: bagheri@malayeru.ac.ir

Article Info

Article type:
Research Article

Article history:

Received

2025-10-01

Received in revised form

2025-11-04

Accepted

2025-12-21

Available online

2025-12-26

Keywords:

Soil–Water Retention Curve (SWRC),
Artificial Neural Network (ANN),
Unsaturated Soil,
Artificial Intelligence (AI),
Deep Learning

ABSTRACT

The soil–water retention curve (SWRC), also referred to as the soil–water characteristic curve (SWCC), is a fundamental property of unsaturated soils describing the relationship between water content and matric suction. Its laboratory determination is time-consuming, costly and requires specialized equipment. In many practical situations, particularly in preliminary design or where many soil layers must be characterized, it is not feasible to perform full SWRC testing for every soil. This motivates the development of reliable data-driven models that approximate the SWRC from basic index properties while remaining consistent with the physics of unsaturated soil behavior. The present study has four objectives: (i) to develop a deep-learning model based on a multilayer perceptron (MLP) for predicting the SWRC of low-plasticity soils using only void ratio, Atterberg limits and particle-size distribution; (ii) to incorporate matric suction explicitly as an independent input variable so that the model represents the SWRC as a continuous function of water content with respect to suction rather than at a few discrete suction values; (iii) to train and test the model on a large database of 1,727 laboratory-measured soil samples from the USDA geospatial database to assess its generalization capability; and (iv) to examine, through parametric analyses, the sensitivity of the predicted SWRC to key input variables and to verify that the model reproduces physically meaningful trends.

Cite this article: Razani, Fatemeh., & Bagherieh, Ali Reza. (2025). Deep learning prediction of continuous soil–water retention curves in low-plasticity soils. *Advanced Modeling in Civil Engineering*, 2(2),133-151.

DOI: 10.22126/amcen.2025.13294.1061



© The Author(s).

DOI: 10.22126/amcen.2025.13294.1061

Publisher: Razi University

Introduction

The soil–water retention curve (SWRC), also referred to as the soil–water characteristic curve (SWCC), is a fundamental property of unsaturated soils describing the relationship between water content and matric suction. It plays a central role in understanding soil–water dynamics and hydrological processes such as infiltration, run-off and evaporation, and it enables assessment of the influence of pore-size distribution on water retention at different suction levels. In arid and semi-arid regions, and in engineered earth structures such as embankments and compacted fills, soils commonly remain in an unsaturated state, making the SWRC essential for analyses of slope stability, bearing capacity and swelling behavior.

A variety of experimental methods have been developed to determine the SWRC, including the pressure-plate, filter-paper and centrifuge techniques, each with its own advantages and limitations. Although these methods can provide reliable measurements, they are generally time-consuming, costly and require specialized equipment, which restricts their routine use in many practical projects. To overcome these limitations, pedotransfer functions (PTFs) have been proposed as an indirect means of estimating the SWRC from basic soil properties, offering a faster and more economical alternative to direct testing. Bayesian approaches have also been introduced to reduce uncertainty by combining prior information with limited observed data. More recently, data-driven models, and in particular artificial neural networks (ANNs), have emerged as powerful tools for predicting the SWRC. Both shallow and deep network architectures have been shown to reproduce measured curves with high accuracy when trained on sufficiently large and representative datasets, often outperforming traditional empirical or physically based models. However, many existing ANN-based studies predict water content only at a small number of discrete suction levels, or are calibrated to relatively narrow ranges of soil types. This highlights the need for models that can exploit large databases, handle a wide variety of low-plasticity soils and represent the SWRC as a continuous function of suction, while remaining consistent with the expected physical behavior of unsaturated soils.

Method

The study employed a feed-forward MLP neural network to predict the SWRC using the dataset of Mostafa et al., which comprises 1,727 soil samples representing coarse-grained, fine-grained and organic soils. Only the main drying branch of the SWRC was considered. Eight variables were used as inputs: matric suction, void ratio, liquid limit (LL), plasticity index (PI) and the percentages passing the No. 4, 10, 40 and 200 sieves. The targets were volumetric water contents at suction levels of 0.1, 0.33 and 15 bar. All variables were normalized to the range [0, 1] using min–max normalization, and the dataset was randomly split into training (70%), validation (15%) and testing (15%) subsets. Several network configurations were explored, starting from a single hidden layer and progressively increasing the number of layers and neurons to balance predictive power and generalization.

The final architecture is a deep MLP with four hidden layers and a 10–5–5–10 neuron structure. Training was carried out in MATLAB using the Levenberg–Marquardt (trainlm) algorithm. Model performance was quantified by the coefficient of determination (R^2), mean squared error (MSE) and mean absolute error (MAE), and parametric analyses were performed by varying selected inputs while holding others constant.

Results

The developed deep MLP model reproduced the soil–water retention behavior of low-plasticity soils with high accuracy. The selected four-hidden-layer architecture (10–5–5–10) achieved high R^2 values and low MSE and MAE for the training, validation and testing subsets, indicating a close agreement between predicted and measured water contents. Scatter plots of predicted versus measured values showed that data points clustered tightly around the 1:1 line, confirming good generalization. The ability of the model to generate continuous SWRCs was assessed by fixing the physical soil properties and varying matric suction over a wide range. For representative soils, the predicted curves were smooth and monotonically decreasing, and the measured data points lay on or very close to the predicted curves, demonstrating that the network can interpolate effectively between training suction levels.

Parametric analyses confirmed that the model captures the expected qualitative trends of unsaturated soil behavior. Increasing porosity led to a systematic upward shift of the SWRC, reflecting greater water-holding capacity at a given suction, whereas decreasing porosity shifted the curve downward. Making the soil finer, by increasing the percentage passing the finer sieves, also resulted in higher predicted water contents at the same suction. Likewise, increases in LL and PI produced higher SWRCs, consistent with the greater affinity of more plastic soils for water. In all cases, the predicted curves remained physically plausible and free from oscillations or non-monotonic segments.

Conclusions

The proposed deep-learning framework provides an accurate, stable and physically meaningful representation of the SWRC for a wide range of low-plasticity soils using only basic physical and geotechnical properties. By treating matric suction as an explicit input, the model represents the SWRC as a continuous function of water content with respect to suction, avoiding the need to train separate networks for individual suction levels or soil types. Within its intended domain, it offers a practical and cost-effective alternative to laboratory SWRC determination for applications such as slope stability assessment, embankment design and analysis of compacted fills. The main limitations are the focus on single porosity low-plasticity soils and the consideration of only the main drying branch of the SWRC; extension to highly plastic or strongly structured soils and to problems where hysteresis is significant is left for future work.

Author Contributions

All authors participated in writing and revising the article.

Conflict of Interest

Authors declared no conflict of interest.



پیش بینی پیوسته منحنی نگهداشت آب-خاک در خاک های با پلاستیسیته کم با استفاده از یادگیری عمیق

فاطمه رازانی^۱، علیرضا باقریه^۲

۱. گروه مهندسی عمران، دانشکده عمران و معماری، دانشگاه ملایر، ملایر، ایران. رایانامه: fatemeh.razani@stu.malayeru.ac.ir
۲. نویسنده مسئول گروه مهندسی عمران، دانشکده عمران و معماری، دانشگاه ملایر، ملایر، ایران. رایانامه: bagheri@malayeru.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	
تاریخ دریافت: ۱۴۰۴/۰۷/۰۹	
تاریخ بازنگری: ۱۴۰۴/۰۸/۱۳	
تاریخ پذیرش: ۱۴۰۴/۰۹/۳۰	
تاریخ انتشار: ۱۴۰۴/۱۰/۰۵	
کلیدواژه ها: منحنی نگهداشت آب-خاک، شبکه عصبی مصنوعی، خاک غیراشباع، هوش مصنوعی، یادگیری عمیق	منحنی نگهداشت آب-خاک از مهم ترین ویژگی های مورد استفاده در تحلیل رفتار مکانیکی و هیدرولیکی خاک های غیراشباع است، اما اندازه گیری آزمایشگاهی آن فرآیندی زمان بر و پرهزینه بوده و به تجهیزات تخصصی نیاز دارد؛ از این رو، روش های هوش مصنوعی به عنوان جایگزینی کارآمد برای آزمایش های مرسوم مورد توجه قرار گرفته اند. در این پژوهش، با بهره گیری از یادگیری عمیق، مدلی برای پیش بینی منحنی نگهداشت آب-خاک در خاک های با پلاستیسیته ی کم ارائه شده است. پایگاه داده ی مورد استفاده شامل اطلاعات ۱۷۲۷ نمونه از پایگاه اطلاعات جغرافیایی خاک ایالات متحده است. ورودی های مدل، مکش، تخلخل، حد روانی (LL)، شاخص خمیری (PI) و درصد عبوری از الک های شماره ۴، ۱۰، ۴۰ و ۲۰۰ بوده و خروجی شبکه، رطوبت حجمی خاک است. برای این منظور، یک شبکه ی عصبی عمیق پرسپترون چندلایه با چهار لایه ی پنهان و معماری ۱۰×۵×۵×۱۰ آموزش داده شد. نتایج نشان می دهد که مدل توسعه یافته می تواند میزان رطوبت خاک را در مقادیر مختلف مکش، تنها بر اساس ویژگی های فیزیکی خاک، با دقت مناسب پیش بینی کند و روندهای فیزیکی مورد انتظار را در تحلیل های پارامتریک بازتولید نماید. برخلاف بسیاری از مطالعات پیشین که رطوبت را فقط در چند سطح گسسته ی مکش تخمین می زنند، در این تحقیق مکش به عنوان یک ورودی مستقل در نظر گرفته شده است؛ از این رو مدل قادر است منحنی نگهداشت آب-خاک را برای هر نوع خاک به صورت تابعی پیوسته از رطوبت بر حسب مکش تولید کند. این رویکرد می تواند در پروژه های ژئوتکنیکی مرتبط با خاک های غیراشباع، به ویژه زمانی که دستیابی سریع و قابل اعتماد به منحنی SWRC مورد نیاز است، به کار گرفته شود.

استناد: رازانی، فاطمه؛ باقریه، علیرضا. (۱۴۰۴). پیش بینی پیوسته منحنی نگهداشت آب-خاک در خاک های با پلاستیسیته کم با استفاده از یادگیری عمیق. *مجله مدل سازی پیشرفته در مهندسی عمران*، ۲(۲)، ۱۵۱-۱۳۳. DOI: 10.22126/amcen.2025.13294.1061



۱. مقدمه

منحنی نگهداشت آب-خاک (Soil-Water Retention Curve: SWRC)، که با عنوان منحنی مشخصه آب-خاک (Soil-Water Characteristic Curve: SWCC) نیز شناخته می‌شود، یکی از ویژگی‌های بنیادی خاک‌های غیراشباع است؛ این منحنی برای توصیف رفتار مکانیکی خاک‌های غیر اشباع و درک دینامیک آب در خاک و پدیده‌های هیدرولوژیکی مختلف مانند نفوذ، رواناب، تبخیر و فرآیندهای تبادل انرژی اهمیت ویژه‌ای دارد [۱،۲،۳]. دستیابی به این منحنی همچنین امکان ارزیابی اثر توزیع اندازه حفرات خاک بر میزان نگهداشت آب در سطوح مختلف مکش را فراهم می‌سازد [۴]. اقلیم‌های گرم و خشک در بسیاری از نقاط جهان گسترده‌اند و همین شرایط سبب می‌شود بخش قابل توجهی از لایه‌های سطحی خاک در وضعیت غیراشباع قرار گیرند. همچنین بررسی پدیده‌هایی نظیر پایداری شیب‌ها، ظرفیت باربری و رفتار خاک‌های متورم مستلزم مطالعه شرایط غیراشباع و تعیین مکش متناظر با هر میزان رطوبت است [۵،۶].

روش‌های آزمایش متعددی برای تعیین منحنی نگهداشت آب-خاک توسعه یافته‌اند که هر یک دارای مزایا و محدودیت‌هایی هستند. روش صفحه فشار با وجود دقت مناسب تا حدود ۱۵۰۰ کیلوپاسکال، زمان‌بر بوده و تنها مقادیر گسسته‌ای از منحنی را ارائه می‌کند [۶]. روش کاغذ صافی امکان اندازه‌گیری طیف وسیعی از مکش‌ها را فراهم می‌سازد، اما نیازمند کالیبراسیون دقیق و زمان تعادل طولانی است [۷]. روش سانتیفریوژ از نظر سرعت برتری دارد و برای مکش‌های بالا مناسب است، هرچند احتمال فشرده‌شدن نمونه و بروز خطا، به‌ویژه در خاک‌های شنی، وجود دارد [۸].

توابع پدوترانسفر (PTFs) به‌عنوان رویکردی غیرمستقیم برای برآورد SWRC، بر پایه ویژگی‌های قابل‌اندازه‌گیری خاک توسعه می‌یابند و نسبت به آزمایش‌های مستقیم سریع‌تر و کم‌هزینه‌تر هستند؛ با این حال، دقت آن‌ها به نوع خاک وابسته بوده و معمولاً نیازمند کالیبراسیون مجدد، به‌ویژه در نواحی خشک، هستند [۱]. چارچوب بی‌زین نیز با ترکیب دانش اولیه و داده‌های محدود، عدم قطعیت پیش‌بینی را کاهش می‌دهد، اما اجرای آن مستلزم دانش اولیه معتبر و توان محاسباتی نسبتاً بالا است [۹].

در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN) به‌عنوان ابزاری کارآمد برای پیش‌بینی منحنی نگهداشت آب-خاک معرفی شده‌اند و با بهره‌گیری از داده‌های آموزشی قادر به برآورد دقیق SWRC، به‌ویژه در ناحیه خشک‌شدن، هستند [۱۰]. این مدل‌ها در قالب ساختارهای کم‌عمق و عمیق (SNN و DNN) توسعه یافته‌اند و از پرکاربردترین رویکردهای هوش مصنوعی در این حوزه محسوب می‌شوند [۱۱،۱۲].

مدل‌های شبکه عصبی مصنوعی (ANN) و انواع عمیق‌تر آن (DNN) دقت بالایی در پیش‌بینی منحنی نگهداشت آب-خاک نشان داده‌اند، به‌طوری‌که در برخی مطالعات مقادیر بالای ضریب تعیین گزارش شده است [۱۱]. با این حال، عملکرد این مدل‌ها به کیفیت داده‌ها و ساختار شبکه وابسته بوده و نتایج می‌تواند بین مطالعات متفاوت باشد. مقایسه با روش‌هایی مانند ماشین بردار پشتیبان نشان می‌دهد که این مدل‌ها، به‌ویژه برای خاک‌های شنی-لوم، شبیه‌سازی دقیقی ارائه می‌کنند و در مجموع اغلب به شرط دسترسی به داده‌های آموزشی مناسب، نسبت به مدل‌های تجربی سنتی عملکرد بهتری دارند [۱۰،۱۲].

در یک پژوهش، عملکرد روش‌های یادگیری ماشین در توسعه توابع پدوترانسفر برای برآورد ویژگی‌های هیدرولیکی خاک بررسی شد. نتایج نشان داد که مدل ماشین بردار پشتیبان (SVM) با تعداد پارامتر کمتر، دقت بالاتری نسبت به شبکه عصبی مصنوعی (ANN) ارائه می‌دهد، به‌ویژه در مقادیر پایین‌تر پتانسیل ماتریک، و به‌عنوان گزینه‌ای قابل‌اعتماد برای مدل‌سازی روابط آب-خاک معرفی شد [۱۳]. پژوهش دیگری با به‌کارگیری شبکه عصبی پیش‌خور چندلایه (MLP) در محیط MATLAB به پیش‌بینی منحنی نگهداشت آب خاک (SWRC) پرداخت. ورودی‌های مدل شامل درصد ماسه، درصد رس، چگالی حجمی و مواد آلی بود. نتایج نشان داد الگوریتم تنظیم بیزی نسبت به توقف زودهنگام عملکرد بهتری دارد و استفاده از تابع انتقال سیگموئید لگاریتمی دقت پیش‌بینی را افزایش می‌دهد. همچنین بهترین مدل پیش‌بینی محتوای آب دارای دو لایه پنهان با ۸ و ۱۴ نرون بود. افزون بر این، ترکیب شبکه‌های عصبی با پارامترهای فرکتالی، به‌ویژه پارامترهای مرتبط با توزیع اندازه ذرات، باعث کاهش معنی‌دار خطا و افزایش قابلیت اطمینان مدل‌ها شد [۱۴].

معماری نهایی شبکه را تحت تأثیر قرار دهد و این انتخاب معمولاً تابع دسترس‌پذیری داده‌ها و حوزه کاربردی مدل است [۱۸، ۱۹]. از سوی دیگر، پارامترهای مشتق‌شده از توزیع اندازه ذرات خاک (GSD) به‌طور گسترده در مدل‌سازی منحنی نگهداشت آب-خاک (SWRC) به‌کار رفته‌اند، زیرا GSD ارتباط مستقیمی با توزیع اندازه حفرات (PSD) دارد که کنترل‌کننده اصلی ظرفیت نگهداشت آب و رفتار مؤینگی خاک است. شباهت شکل منحنی تجمعی PSD با منحنی SWRC نیز بیانگر توان بالای این پارامترها در پیش‌بینی رفتار رطوبتی خاک است [۲۰].

علاوه بر استفاده از تابع خطا مانند میانگین مربعات خطا (MSE)، در مرحله آموزش، به‌کارگیری شاخص‌های ارزیابی عملکرد برای سنجش کارایی مدل در مرحله آزمون و هنگام مواجهه با داده‌های جدید ضروری است. از جمله شاخص‌های رایج شبکه‌های عصبی می‌توان به ضریب تعیین (R^2)، که میزان همبستگی و تطابق بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد، و ریشه میانگین مربعات خطا (RMSE)، که میزان پراکندگی خطاها و اختلاف بین خروجی مدل و داده‌های مشاهده‌شده را بیان می‌کند، اشاره کرد [۲۱].

در سال‌های اخیر، مطالعاتی انجام شده‌اند که در آن‌ها مکش به‌صورت یک ورودی مشخص‌شده توسط کاربر (User-Defined Suction: UDS) در فرآیند آموزش شبکه‌های عصبی لحاظ شده است؛ با این حال، این رویکردها با چالش‌هایی همراه بوده‌اند که از جمله مهم‌ترین آن‌ها می‌توان به تضمین یکنوایی و رفتار فیزیکی منحنی نگهداشت آب-خاک اشاره کرد. برای مواجهه با این چالش‌ها، در برخی پژوهش‌ها از راهکارهایی نظیر شبکه‌های عصبی آگاه از فیزیک (Physics-informed Neural Networks) استفاده شده است. به‌عنوان نمونه، می‌توان به پژوهش نوروزی و همکاران [۲۲] اشاره کرد که با وجود مزایای قابل‌توجه، این روش‌ها همچنان با محدودیت‌ها و پیچیدگی‌های محاسباتی خاص خود همراه هستند.

یکی دیگر از نکات مهم در حوزه پیش‌بینی منحنی نگهداشت آب-خاک، محدودیت پایگاه‌های داده موجود برای آموزش مدل‌هاست؛ این محدودیت هم از نظر تنوع نمونه‌های خاک و هم از نظر تعداد نقاط آزمایشگاهی در دسترس برای هر نمونه مشاهده می‌شود.

در پژوهشی دیگر، روش‌های مختلف یادگیری ماشین از جمله درخت‌های گروهی، ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای پیش‌بینی رطوبت حجمی خاک در چهار سطح مکش ماتریک به‌کار گرفته شد. نتایج نشان داد مدل‌های ANN عملکرد بهتری نسبت به سایر روش‌ها دارند. در ادامه، یک مدل ANN چندخروجی برای پیش‌بینی هم‌زمان همه سطوح مکش توسعه یافت که از نظر دقت و کارایی محاسباتی بر مدل‌های جداگانه برتری داشت. بهترین ساختار، شبکه‌ای با یک لایه مخفی و ۲۰۰ نورون بود. تحلیل اهمیت متغیرها نشان داد درصد عبور از الک شماره ۲۰۰، ظرفیت تبادل کاتیونی، حد روانی، درصد عبور از الک شماره ۱۰ و شاخص خمیری بیشترین تأثیر را دارند و اثر آن‌ها در مکش‌های پایین‌تر و نزدیک به اشباع قوی‌تر است. همچنین، آموزش مدل با متغیرهای مهم نیز نتایج قابل قبولی ارائه داد، هرچند استفاده از همه متغیرها دقت اندکی بالاتر داشت [۱۵].

شبکه‌های عصبی مصنوعی (ANN) به‌عنوان ابزارهایی کارآمد برای پیش‌بینی منحنی نگهداشت آب-خاک (SWRC) شناخته می‌شوند که در این میان، پرسپترون چندلایه (MLP) پرکاربردترین مدل است، هرچند مدل‌هایی مانند RBF، ماشین یادگیری حدی (ELM) و شبکه‌های پیش‌خور آبخاری نیز استفاده شده‌اند [۱۶]. دقت و پایداری این مدل‌ها به انتخاب مناسب متغیرهای ورودی و خروجی و طراحی ساختار شبکه، از جمله تعداد لایه‌ها و نورون‌ها، توابع فعال‌سازی و روش‌های بهینه‌سازی، وابسته است و این طراحی اغلب به‌صورت تجربی یا با الگوریتم‌های خودکار مانند Hyperband انجام می‌شود [۱۷]. در مدل‌سازی SWRC با ANN، سه رویکرد اصلی شامل مکش تعریف‌شده توسط توسعه‌دهنده (DDS)، مکش تعریف‌شده توسط کاربر (UDS) و رویکرد مبتنی بر معادلات پارامتریک پیوسته (PCE) گزارش شده‌اند که هر یک بسته به کاربرد، توازن متفاوتی میان دقت، انعطاف‌پذیری و پیچیدگی محاسباتی فراهم می‌کنند. انتخاب مناسب پارامترهای ورودی در شبکه‌های عصبی تأثیر تعیین‌کننده‌ای بر دقت و کارایی پیش‌بینی مدل دارد، به‌گونه‌ای که افزایش همبستگی میان ورودی‌ها و خروجی‌ها منجر به بهبود توان پیش‌بینی شبکه می‌شود. علاوه بر این، نوع و تعداد ورودی‌ها می‌تواند فرآیند بهینه‌سازی و حتی

ویژگی‌های ورودی مدل شامل خواص ژئوتکنیکی و فیزیکی خاک، مانند درصد عبوری از الک‌های ۴، ۱۰، ۴۰ و ۲۰۰، تخلخل، حد روانی (LL) و شاخص خمیری (PI) می‌باشد. به‌منظور نمایش توزیع داده‌های هر ویژگی و ارزیابی بصری نحوه پراکندگی آن‌ها، هیستوگرام مربوط به برخی متغیرها در شکل ۱ (قسمت‌های الف تا ح) ترسیم شده است. این هیستوگرام‌ها نمایی کلی از پراکندگی داده‌ها در مجموعه آموزشی ارائه می‌کنند. مقادیر هدف، میزان رطوبت حجمی خاک است.

پایگاه داده‌ی اولیه برای هر نمونه‌ی خاک شامل چهار مقدار رطوبت حجمی در چهار سطح مکش بود؛ رطوبت در حالت تقریباً اشباع و رطوبت متناظر با مکش‌های ۰.۱، ۰.۳۳ و ۱۵ بار. در فرایند توسعه مدل‌های یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر شبکه عصبی، یکی از چالش‌های اصلی محدودیت حجم و تنوع داده‌های واقعی است. با توجه به اینکه شبکه‌های عصبی معمولاً برای دستیابی به عملکرد قابل‌قبول به مجموعه‌داده‌های بزرگ و دارای برچسب نیاز دارند، استفاده از داده‌های مصنوعی (Synthetic Data) به‌عنوان یک راهکار در بسیاری از پژوهش‌های مهندسی پیشنهاد شده و به‌کار گرفته می‌شود. داده‌های مصنوعی در شرایطی مورد استفاده قرار می‌گیرند که داده‌های واقعی کمیاب باشند، جمع‌آوری آن‌ها هزینه‌بر یا زمان‌بر باشد، یا لزوم پوشش بازه گسترده‌تری از شرایط ورودی برای آموزش بهتر مدل احساس شود. تولید این نوع داده‌ها از طریق روش‌هایی مانند شبیه‌سازی، مدل‌سازی، درون‌یابی و یا ترکیب مدل‌های فیزیکی با روش‌های آماری انجام می‌شود و هدف اصلی آن افزایش چگالی داده در نواحی کم‌نمونه و فراهم کردن امکان آموزش پایدارتر شبکه است. به‌عنوان یک مثال از کاربردهای ژئوتکنیکی می‌توان به پژوهش شوکت و همکاران [۲۳] در زمینه آزمایش نفوذ مخروطی اشاره کرد. در پروژه‌های فراساحلی که داده CPT واقعی محدود است، نویسندگان با ترکیب داده‌های لرزه‌ای و توپوگرافی بستر دریا پروفیل‌های مصنوعی CPT تولید کردند و شبکه عصبی را برای پیش‌بینی مقاومت خاک آموزش دادند. در پژوهش حاضر نیز با توجه به محدودیت داده‌های واقعی موجود و همچنین نیاز به پوشش‌دهی پیوسته بازه‌های مختلف مکش برای پیش‌بینی منحنی نگهداشت آب-خاک (SWRC)، استفاده از داده‌های مصنوعی در کنار داده‌های واقعی مدنظر قرار گرفته است. این داده‌ها به‌گونه‌ای

پایگاه داده مورد استفاده در پژوهش حاضر، یک پایگاه داده جامع است که توسط اداره کشاورزی ایالات متحده آمریکا (USDA) برای خاک‌های با خصوصیات خمیری کم گردآوری شده و از گستردگی قابل‌توجهی در این گروه از خاک‌ها برخوردار است. برخلاف پژوهش اخیر مصطفی و همکاران [۱۵] که با استفاده از همین پایگاه داده، سه شبکه عصبی مجزا را برای سه سطح مکش آموزش داده‌اند، در پژوهش حاضر مکش به‌عنوان یک متغیر مستقل در فرایند آموزش شبکه لحاظ شده است. از این‌رو، نقطه‌قوت اصلی پژوهش حاضر را می‌توان در توسعه شبکه‌ای دانست که مکش را به‌عنوان متغیر ورودی می‌پذیرد و هم‌زمان از یک پایگاه داده قوی و معتبر بهره می‌برد. هدف اصلی این تحقیق توسعه یک شبکه عصبی عمیق (DNN) است که با استفاده از ویژگی‌هایی شامل درصد عبوری الک‌های اصلی، حدود ات‌برگ و تخلخل، منحنی نگهداشت آب-خاک را به‌صورت یک تابع پیوسته از مکش برای خاک‌های با پلاستیسیته کم بازتولید نماید و بدین‌ترتیب، نیاز به انجام آزمایش‌های زمان‌بر و پرهزینه را در بسیاری از کاربردهای مهندسی ژئوتکنیک کاهش دهد.


۲. روش پژوهش

در این مطالعه، برای آموزش و ارزیابی مدل شبکه عصبی پرسپترون چندلایه (MLP) به‌منظور پیش‌بینی منحنی نگهداشت آب-خاک، از پایگاه داده ارائه‌شده توسط مصطفی و همکاران [۱۵] استفاده شد. این پایگاه داده شامل ۱۷۲۷ نمونه خاک استخراج‌شده از پایگاه اطلاعات جغرافیایی خاک ایالات متحده آمریکا (SSURGO) می‌باشد. داده‌ها در قالب فایل‌های GIS و با استفاده از نرم‌افزار ArcMap 10.8.1 پردازش شده‌اند. نمونه‌ها از مناطق مختلف ایالات متحده و شامل خاک‌هایی با بافت درشت‌دانه، ریزدانه و آلی هستند. علت انتخاب این پایگاه داده، تنوع بالای نمونه‌ها، کیفیت اندازه‌گیری‌ها، و تمرکز آن بر خاک‌های کم‌پلاستیسیته است که دقیقاً با هدف پژوهش حاضر منطبق می‌باشد. همچنین، این داده‌ها قبلاً در مدل‌سازی‌های شبکه عصبی مصنوعی نیز استفاده شده‌اند.

شناسه ها برای تخصیص داده ها به مجموعه های مربوطه استفاده شد.

این روش تضمین می کند که هر داده در تمام دفعات اجرای مدل، همواره در همان مجموعه ی اولیه باقی بماند و بین مجموعه های آموزش، آزمون و اعتبارسنجی جابجا نشود. این رویکرد از بروز نشت داده (Data Leakage) جلوگیری کرده و اعتبار نتایج ارزیابی مدل را افزایش می دهد. همچنین، استفاده از این ساختار باعث شد که نتایج حاصل از تکرارهای مختلف آموزش شبکه، قابل مقایسه و سازگار باشند.

برای مدل سازی، از شبکه عصبی پرسپترون چندلایه (MLP) در محیط نرم افزار MATLAB استفاده شد. انتخاب معماری بهینه شبکه با روش سعی و خطا و بر اساس ارزیابی عملکرد ساختارهای مختلف انجام گرفت. در ابتدا، شبکه های دارای یک لایه پنهان و تعداد کم نورون بررسی شدند و به تدریج با افزایش تعداد نورون ها، تأثیر آن بر دقت مدل ارزیابی گردید. سپس شبکه های دارای دو، سه و نهایتاً چهار لایه پنهان با آرایش های متنوع آموزش داده شدند. طرح شماتیک معماری شبکه بهینه در شکل ۲ ارائه شده است. این شبکه پرسپترون چندلایه به دلیل داشتن بیش از یک لایه پنهان، به عنوان یک شبکه عصبی عمیق در نظر گرفته می شود. ورودی شبکه شامل هشت متغیر است که نخستین آن مکش و سایر متغیرها عبارتند از: تخلخل (e)، حد روانی (LL)، شاخص خمیری (PI) و درصد عبوری از الک های شماره ۴، ۱۰، ۴۰ و ۲۰۰. خروجی شبکه نیز رطوبت حجمی خاک می باشد.



(الف) درصد عبوری از الک شماره ۴

تولید می شوند که ضمن حفظ منطق فیزیکی رفتار خاک، امکان آموزش شبکه در شرایط متنوع تر را فراهم کرده و از بروز رفتارهای غیرواقعی در خروجی مدل جلوگیری کنند.


به منظور افزایش تراکم نقاط روی منحنی و بهبود فرایند آموزش شبکه، برای هر خاک تعدادی «نقطه ی مجازی» در بازه ی مکش بین اشباع و ۱۵ بار به داده ها افزوده شد. در مدل ون گنوختن تابع زیر برای محتوای آب به صورت تابعی از مکش استفاده شده است:

$$\theta(h) = \theta_r + \frac{\theta_s - \theta_r}{[1 + (\alpha|h|)^n]^m} \quad (1)$$


$$m = \frac{1}{n} \quad (2)$$

که در رابطه فوق: θ_h مقدار رطوبت حجمی در مکش ماتریسی؛ θ_s رطوبت حجمی اشباع؛ θ_r رطوبت باقیمانده؛ α, n, m ثوابت مصالح هستند. ابتدا با استفاده از چهار نقطه ی اندازه گیری شده، ثوابت مدل ون گنوختن برای همان نمونه از طریق برازش منحنی تعیین گردید و سپس با قرار دادن مقادیر میانی مکش در رابطه ی رطوبت متناظر پیش بینی شد. این نقاط مصنوعی به عنوان داده های تکمیلی به پایگاه داده اضافه شدند تا شبکه ی عصبی شکل پیوسته ی منحنی نگهداشت آب-خاک را بهتر فرا گیرد.


به منظور آموزش و ارزیابی عملکرد شبکه عصبی طراحی شده، داده های موجود به سه دسته اصلی شامل مجموعه آموزش (Training)، مجموعه اعتبارسنجی (Validation) و مجموعه آزمون (Testing) تقسیم شدند. این تقسیم بندی با نسبت های ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای آزمون انجام گرفت. برای جلوگیری از تداخل داده ها در مراحل مختلف آموزش و ارزیابی و به منظور افزایش تکرارپذیری نتایج، تقسیم بندی داده ها به صورت تصادفی کنترل شده (Random but Fixed) انجام شد. به این منظور، شناسه (Index) داده های اختصاص یافته به هر یک از این سه مجموعه، تنها یک بار و در ابتدای فرایند مدل سازی تولید گردید و به صورت یک متغیر در فضای کاری نرم افزار متلب (MATLAB Workspace) ذخیره شد. در دفعات بعدی اجرای کد، با استفاده از شرط بررسی وجود این متغیر، از همان




(ه) حد روانی




(ب) درصد عبوری از الک شماره ۱۰




(و) شاخص خمیری



(ج) درصد عبوری از الک شماره ۴۰



(ز) تخلخل




(د) درصد عبوری از الک شماره ۲۰۰

ارزیابی دقت مدل، از سه شاخص آماری شامل ضریب تعیین (R^2)، میانگین مربعات خطا^۱ و میانگین قدرمطلق خطا^۲ استفاده گردید.

۳. یافته‌های پژوهش


در این تحقیق، به منظور پیش‌بینی منحنی نگهداشت آب- خاک برای انواع مختلف خاک، از شبکه عصبی پرسپترون چندلایه (MLP) استفاده شد. برخلاف بسیاری از مطالعات پیشین که معمولاً برای هر نوع خاک یا هر مجموعه داده و حتی برای هر سطح مکش، نیاز به طراحی و آموزش شبکه عصبی مجزا بود، در این پژوهش تلاش شد محدودیت‌های موجود برطرف شود؛ بدین صورت که مکش به عنوان یکی از متغیرهای ورودی شبکه در نظر گرفته شد. سایر ورودی‌های شبکه شامل تخلخل (e)، حد روانی (LL)، شاخص خمیری (PI) و درصد عبوری از الک‌های شماره ۴، ۱۰، ۴۰ و ۲۰۰ می‌باشند که تأثیر مستقیم بر منحنی نگهداشت آب خاک دارند و عملکرد مناسبی در پیش‌بینی $SWRC$ برای چندین نوع خاک مختلف ارائه می‌کنند. همان‌گونه که ذکر شد، به دلیل کم بودن تعداد نقاط داده برای هر خاک در پایگاه داده و به منظور دستیابی به منحنی‌های نگهداشت آب- خاک با روند یکنوازی کاهشی بر حسب مکش، از داده‌های درون‌یابی شده توسط مدل و نگرختن به عنوان داده‌های مجازی استفاده شد. در این بخش، پیش از ارائه و تحلیل نتایج آموزش شبکه‌هایی که در آن‌ها از داده‌های مجازی استفاده شده است، دو نمونه از منحنی‌های نگهداشت در حالتی که از داده‌های مجازی استفاده نشده‌اند، در شکل ۳ ترسیم شده‌اند.

همان‌گونه که ملاحظه می‌شود، علیرغم انطباق مناسب منحنی‌های پیش‌بینی شده با نقاط اندازه‌گیری شده، منحنی‌های نگهداشت در این دو نمونه دارای رفتار یکنوا نیستند. به‌طور خاص، در قسمت (الف) مشاهده می‌شود که برای نمونه ۲۱۷ از پایگاه داده، پس از یک روند ابتدایی کاهشی، روندی افزایشی در رطوبت رخ داده و پس از رسیدن به یک مقدار بیشینه، میزان رطوبت مجدداً کاهش می‌یابد. چنین رفتاری با فیزیک مسئله سازگار نبوده و از این‌رو، در



(ج) رطوبت در حالت اشباع

شکل ۱ هیستوگرام توزیع ویژگی‌های ورودی مورد استفاده در مدل سازی (الف) درصد عبوری از الک شماره ۴ (#4)، (ب) درصد عبوری از الک شماره ۱۰ (#10)، (پ) درصد عبوری از الک شماره ۴۰ (#40)، (ت) درصد عبوری از الک شماره ۲۰۰ (#200)، (ث) حد روانی (LL)، (ج) شاخص خمیری (PI)، (چ) رطوبت در حالت اشباع (w satiated)، (ح) تخلخل (e)




شکل ۲. طرح شمایک معماری شبکه DNN بهینه با چهار لایه پنهان

پس از ارزیابی طیف گسترده‌ای از معماری‌های شبکه با تعداد لایه‌های مختلف، مناسب‌ترین معماری شامل چهار لایه پنهان با چینش نرونی $10 \times 5 \times 5 \times 10$ بود. برای آموزش شبکه از الگوریتم Levenberg-Marquardt (trainlm) استفاده شد که دارای نرخ همگرایی بالا و دقت مناسب در مسائل مهندسی است. به‌منظور

¹ MSE

² MAE




(ب) خاک شماره ۱۵۱ پایگاه داده

شکل ۳. منحنی نگهداشت آب-خاک پیش‌بینی‌شده توسط شبکه عصبی در حالت عدم استفاده از نقاط داده مجازی (الف) خاک شماره ۲۱۷ پایگاه داده (ب) خاک شماره ۱۵۱ پایگاه داده


همان‌طور که در بخش روش تحقیق ذکر شد، شبکه‌های عصبی با معماری‌های مختلف آزمون شدند و به تدریج تعداد نورون‌ها و لایه‌ها افزایش یافت تا شبکه‌ای با کارایی مطلوب به دست آید. شاخص‌های عملکرد شبکه‌های مختلف در جدول ۱ ارائه شده است. نتایج نشان دادند که مدل پیشنهادی دقت مناسبی در پیش‌بینی داده‌های مربوط به آموزش، اعتبارسنجی و آزمون دارد. در انتخاب معماری بهینه شبکه عصبی، علاوه بر شاخص‌های آماری مانند ضریب تعیین (R^2)، میانگین مربعات خطا (MSE) و میانگین قدر مطلق خطا (MAE)، عملکرد شبکه در تحلیل‌های پارامتریک نیز مورد توجه قرار گرفت. به این منظور، معماری‌ای انتخاب شد که ضمن داشتن خطای پیش‌بینی معقول، روند منطقی و قابل قبولی در تحلیل‌های پارامتریک ارائه دهد و توانایی مناسبی در بازتولید منحنی نگهداشت آب-خاک در برابر مکش داشته باشد. به عنوان مثال، شبکه آموزش‌دیده باید خروجی‌هایی تولید کند که در اثر افزایش مکش، افزایش رطوبت رخ ندهد.

پژوهش حاضر به منظور رفع این نقیصه، استفاده از داده‌های مجازی درون‌یابی‌شده در دستور کار قرار گرفت.


پژوهش‌ها نشان داده‌اند که مدل ون‌گنوختن برای شبیه‌سازی منحنی نگهداشت آب خاک‌های دارای ساختار تخلخل ساده، به‌ویژه خاک‌های با منحنی نگهداشت S شکل، مناسب است و دقت قابل قبولی برای پیش‌بینی منحنی نگهداشت آب خاک در انواع مختلف خاک دارد [۲۴]. با این حال، این مدل و مدل‌های مشابه آن، توزیع حفرات خاک را به صورت تک‌وجهی (unimodal) فرض می‌کنند و این موضوع، کاربرد آن‌ها را در خاک‌های دارای تخلخل دوگانه، که دارای توزیع حفرات دووجهی (bimodal) هستند، محدود می‌سازد [۲۵]. افزون بر این، داده‌های موجود در پایگاه داده استفاده‌شده در پژوهش حاضر نیز بر خاک‌های دارای تخلخل دوگانه متمرکز نیست؛ بنابراین، شبکه عصبی آموزش‌دیده در این تحقیق برای کاربرد در خاک‌های دارای ساختار تخلخل دوگانه با محدودیت مواجه خواهد بود.




(الف) خاک شماره ۲۱۷ پایگاه داده



(الف) آزمون



(ب) صحت سنجی




(ج) آموزش

همان‌طور که در جدول ۱ مشاهده می‌شود، شبکه با معماری چهارلایه $(10 \times 5 \times 5 \times 10)$ عملکرد مناسبی از خود نشان داده و دارای بهترین مقادیر R^2 ، MSE و MAE بوده است. بنابراین، این شبکه چهارلایه به‌عنوان معماری بهینه انتخاب شد.


شکل ۴ عملکرد شبکه عصبی با معماری منتخب را در پیش‌بینی مقادیر رطوبت حجمی برای مجموعه‌های داده آموزش، اعتبارسنجی و آزمون نشان می‌دهد. در این شکل، محور افقی مقادیر واقعی و محور عمودی مقادیر پیش‌بینی شده توسط شبکه را نمایش می‌دهد. همان‌طور که مشاهده می‌شود، تمامی نقاط داده حول خط $x = y$ قرار گرفته‌اند، که نشان‌دهنده نزدیکی مقادیر پیش‌بینی شده به مقادیر اندازه‌گیری شده و پراکندگی بسیار محدود داده‌ها است.

جدول ۱. مقادیر شاخص‌های آماری شامل ضریب تعیین (R^2)، میانگین مربعات خطا (MSE) و میانگین قدر مطلق خطا (MAE) برای ارزیابی عملکرد مدل شبکه عصبی در سه مجموعه داده‌ی آموزش، اعتبارسنجی و آزمون.


معماری شبکه	پارامتر	R^2	MSE	MAE
شبکه تک لایه (70)	آموزش	0.986	0.313	0.352
	صحت	0.984	0.384	0.384
	سنجی	0.986	0.331	0.365
	آزمون	0.996	0.087	0.177
شبکه دو لایه (20×60)	آموزش	0.994	0.134	0.198
	صحت	0.996	0.098	0.189
	سنجی	0.998	0.035	0.111
	آزمون	0.996	0.084	0.139
شبکه سه لایه (20×10×10)	آموزش	0.997	0.072	0.130
	صحت	0.991	0.209	0.285
	سنجی	0.989	0.269	0.309
	آزمون	0.992	0.193	0.289




(الف) تاثیر تخلخل در خاک شماره ۱



(ب) تاثیر حدروانی در خاک شماره ۱




(ج) تاثیر شاخص خمیری در خاک شماره ۱




(د) ترکیب سه مجموعه

شکل ۴. عملکرد شبکه عصبی در مقایسه‌ای بین مقادیر اندازه‌گیری شده و پیش‌بینی‌شده منحنی SWRC مربوط به داده‌های (الف) آزمون، (ب) صحت سنجی و (پ) آموزش (ت) ترکیب سه مجموعه آزمون، صحت سنجی و آموزش با استفاده از شبکه عصبی پرسپترون چندلایه.


به‌منظور ارزیابی عملکرد مدل شبکه عصبی، منحنی نگهداشت آب-خاک (SWRC) به‌صورت یک تابع پیوسته از مکش رسم گردید. در این فرآیند، کلیه ویژگی‌های فیزیکی خاک ثابت در نظر گرفته شد و تنها مقدار مکش، به‌عنوان یکی از متغیرهای ورودی، به‌صورت افزایشی تغییر داده شد، سپس درصد رطوبت حجمی متناظر با هر مقدار مکش توسط مدل پیش‌بینی و ثبت گردید. نتیجه این فرآیند، ترسیم منحنی‌هایی مشابه شکل‌های ۵ و ۶ است. به‌عنوان نمونه، در شکل ۵ یکی از نمونه‌های خاک موجود در پایگاه داده اولیه انتخاب شده است. این خاک دارای ویژگی‌هایی است که در جدول شماره ۲ ارائه شده و شامل هشت متغیر ورودی می‌باشد.



(ب) تاثیر حد روانی در خاک شماره ۲



(ج) تاثیر شاخص خمیری در خاک شماره ۲




(د) تاثیر دانه بندی در خاک شماره ۱

شکل ۵. مقایسه منحنی نگهداشت آب-خاک (SWRC) واقعی و پیش‌بینی شده توسط شبکه عصبی برای نمونه خاک شماره ۱. (الف) دانه بندی، (ب) تخلخل (e)، (پ) حد روانی (LL)، (ت) شاخص خمیری (PI).

جدول ۲- خصوصیات فیزیکی خاک‌های استفاده شده در تحلیل پارامتری


Soil No.	e	LL	PI	Passing #4	Passing #10	Passing #40	Passing #200
1	0.44	21	6	66	43	35	11
2	0.89	22	9	100	100	94	32



(الف) تاثیر تخلخل در خاک شماره ۲

رفتار قابل اعتماد مدل در پاسخ به تغییرات پارامترها است که در ادامه نوشتار توضیح بیشتری در این خصوص ارائه شده است. علاوه بر مقایسه داده‌های آزمایشگاهی با پیش‌بینی شبکه عصبی که با منحنی‌های آبی رنگ نمایش داده شده‌اند، تحلیل پارامتریک نیز انجام گرفته است. در این تحلیل، تمامی ویژگی‌های خاک ثابت نگه داشته شده و تنها یکی از خصوصیات فیزیکی آن تغییر داده شده است تا تأثیر آن بر منحنی نگهداشت آب خاک ارزیابی شود؛ برای مثال، در شکل ۵-الف مشاهده می‌شود که تخلخل اولیه نمونه برابر با ۰/۸۹ بوده است و در تحلیل پارامتریک، دو مقدار ۱ و ۰/۸۰ به‌عنوان مقادیر متغیر برای تخلخل در ورودی شبکه عصبی در نظر گرفته شده‌اند. همان‌طور که مشخص است، منحنی مربوط به نمونه با تخلخل بیشتر ($e=1$) در بالای منحنی اصلی قرار گرفته و منحنی مربوط به تخلخل کمتر ($e=0/80$) پایین‌تر از داده اصلی قرار گرفته است. علت این تغییر را بدین صورت بیان کرد که با افزایش تخلخل، فضای حفره‌ای بیشتری در دسترس قرار می‌گیرد و در نتیجه، به ازای هر مقدار مکش، رطوبت نگه‌داشته‌شده بیشتر خواهد بود.

این تحلیل پارامتریک نشان می‌دهد که روند حاصل از پیش‌بینی شبکه با درک فیزیکی از مسئله هم‌خوانی دارد. این امر نشان‌دهنده قابلیت تعمیم مدل شبکه عصبی است؛ به این معنا که شبکه نه تنها باید بتواند روند داده‌های آموزش‌دیده را پیش‌بینی کند، بلکه باید در مواجهه با تغییرات متغیرهای ورودی نیز رفتاری مطابق با اصول فیزیکی سیستم از خود نشان دهد. روند مشابهی در شکل ۶-الف نیز مشاهده می‌شود، به گونه‌ای که افزایش تخلخل باعث جابه‌جایی منحنی SWRC به سمت بالا شده است. دانه‌بندی خاک یکی از عوامل تأثیرگذار بر منحنی نگهداشت آب-خاک (SWRC) محسوب می‌شود، زیرا اندازه و توزیع ذرات خاک نقش مهمی در تعیین توزیع منافذ و ظرفیت نگهداشت آب ایفا می‌کنند. به‌طور کلی، خاک‌هایی که درصد بالاتری از ذرات ریز مانند رس و سیلت دارند، تمایل بیشتری به نگهداری آب در مقادیر مختلف مکش نشان می‌دهند، در حالی که خاک‌های دانه‌درشت، مانند ماسه، آب را سریع‌تر از دست می‌دهند و منحنی SWRC آنها در سطوح پایین‌تری قرار می‌گیرد.



(د) تأثیر دانه‌بندی در خاک شماره ۲

شکل ۶. مقایسه منحنی نگهداشت آب-خاک (SWRC) واقعی و پیش‌بینی‌شده توسط شبکه عصبی برای نمونه خاک شماره ۲. (الف) دانه‌بندی، (ب) تخلخل (e)، (پ) حد روانی (LL)، (ت) شاخص خمیری (PI).

همان‌طور که در شکل‌های ۵ و ۶ مشاهده می‌شود، منحنی نگهداشت آب-خاک (SWRC) یک منحنی یکنوازی نزولی است. منحنی آبی‌رنگ ترسیم‌شده پیش‌بینی شبکه عصبی به ازای ویژگی‌های اصلی خاک مربوطه مطابق جدول ۲ می‌باشد؛ نقاط بنفش رنگ نشان‌دهنده داده‌های واقعی اندازه‌گیری‌شده برای آن خاک هستند و مشاهده می‌شود که به‌درستی بر روی منحنی قرار گرفته‌اند؛ بدین ترتیب، صحت عملکرد شبکه در پیش‌بینی داده‌های آزمایشگاهی تایید می‌گردد. همچنین، رطوبت بصورت تابعی پیوسته و همواره نزولی از مکش حاصل شده است که از لحاظ شکل کلی، منطبق بر رفتار منطقی منحنی SWRC بوده و فاقد پراکندگی غیرمنتظره است. لازم به ذکر است که نمونه‌های خاک جدول ۲ به‌صورت تصادفی از داده‌گاه اولیه انتخاب شده‌اند. همچنین، منحنی‌های قرمز و سبز رنگ نشان می‌دهند که در صورت افزایش یا کاهش مقادیر پارامترهای ورودی، منحنی حاصل به شکلی منطقی و قابل انتظار تغییر می‌کند؛ این موضوع بیانگر

نتایج حاصل حاکی از آن است که شبکه عصبی طراحی شده قادر به پیش بینی دقیق منحنی نگهداشت آب-خاک برای خاکهای عمدتاً دارای خاصیت خمیری کم است و محدودیت نیاز به طراحی شبکه جداگانه برای هر مقدار مکش را برطرف کرده است. با توجه به دشواری های آزمایشگاهی تعیین منحنی SWRC، از جمله نیاز به تجهیزات خاص، زمان طولانی برای رسیدن به تعادل مکش و هزینه بالا، استفاده از شبکه عصبی مصنوعی می تواند یک روش کارآمد و سریع برای تخمین اولیه این منحنی باشد. این رویکرد می تواند در مطالعات ژئوتکنیکی که با خاک های غیر اشباع سروکار دارند، زمان، هزینه و پیچیدگی فرآیند مدل سازی را کاهش دهد.

۴. نتیجه گیری

هدف اصلی این پژوهش، پیش بینی منحنی نگهداشت آب-خاک (SWRC) برای خاک های با پلاستیسیته کم، تنها بر پایه ویژگی های فیزیکی و ژئوتکنیکی خاک و بدون اتکا به آزمایش های زمان بر و پرهزینه آزمایشگاهی بود. برای این منظور، از یک شبکه عصبی عمیق (DNN) با ساختار پرسپترون چندلایه استفاده شد که در آن، مکش به عنوان یکی از ورودی های اصلی مدل در نظر گرفته شد؛ بدین ترتیب، برخلاف بسیاری از مطالعات پیشین که شبکه صرفاً در چند مقدار گسسته مکش آموزش داده می شود، مدل پیشنهادی قادر است رطوبت خاک را در بازه ای پیوسته از مقادیر مکش پیش بینی کرده و عملاً منحنی SWRC را به صورت یک تابع پیوسته از مکش تولید نماید.

پس از ارزیابی معماری های مختلف، ساختار بهینه شبکه با چهار لایه پنهان و آرایش $10 \times 5 \times 5 \times 10$ انتخاب شد. نتایج حاصل از آموزش، اعتبارسنجی و آزمون نشان داد که این معماری، دقت مناسبی در پیش بینی مقادیر رطوبت برای طیف گسترده ای از خاک ها دارد و شاخص های آماری نظیر R^2 ، MSE و MAE، عملکرد قابل قبول مدل را تأیید می کنند؛ علاوه بر این، تحلیل های پارامتریک نشان داد که مدل آموزش دیده، روندهای فیزیکی مورد انتظار را به خوبی بازتولید می کند؛ به گونه ای که افزایش تخلخل به جابه جایی منحنی SWRC به سمت رطوبت های بالاتر و تغییر دانه بندی به سمت ریزدانه تر شدن خاک، به افزایش ظرفیت

برای بررسی اثر دانه بندی بر منحنی نگهداشت آب-خاک، داده های درصد عبوری از الک های شماره ۴، ۱۰، ۴۰ و ۲۰۰ به عنوان ورودی شبکه عصبی استفاده شده اند. یکی از رویکردهای تحلیل این تأثیر، تغییر درصد عبوری از یک الک مشخص است در حالی که درصد های عبوری از سایر الک ها ثابت نگه داشته می شوند. این تغییر باعث می شود منحنی دانه بندی در یک نقطه مشخص (مثلاً عبوری از الک شماره ۴۰ افزایش یا کاهش یابد و در نتیجه شکل کلی منحنی دانه بندی تغییر کند، که ممکن است وضعیت خاک را از حالت مناسب به حالت بددانه بندی (نامناسب) تبدیل نماید.

به منظور حفظ شکل کلی منحنی دانه بندی و در عین حال بررسی اثر تغییرات دانه بندی، تصمیم گرفته شد که فرم اصلی منحنی ثابت باقی بماند. برای این منظور، ترتیبی اتخاذ گردید تا منحنی دانه بندی با حفظ فرم اولیه خود، به طور یکنواخت به سمت بالا (ریزدانه تر شدن خاک) یا پایین (درشت دانه تر شدن خاک) منتقل شود. این کار با تغییر درصد عبوری از چهار الک مورد بررسی به گونه ای انجام شد که مقادیر همه الک ها در یک ضریب ثابت ضرب گردید. نتیجه این فرآیند، منحنی دانه بندی ای است که شکل اصلی خود را حفظ کرده و تنها به صورت عمودی جابجا شده است، به طوری که خاک یا ریزدانه تر و یا درشت دانه تر از حالت اولیه می شود.

در بخش های «ج» و «د» در شکل های ۵ و ۶، اثر پارامترهای اتربرگ شامل حد روانی (LL) و شاخص خمیری (PI) بر منحنی نگهداشت آب-خاک مورد بررسی قرار گرفته است. با افزایش مقادیر LL و PI، خاصیت خمیری خاک افزایش یافته و تمایل خاک به نگهداشت آب نیز بیشتر می شود. بنابراین، خاک های با خمیری بالاتر، منحنی SWRC بالاتری نسبت به خاک های با خمیری کمتر نشان می دهند. همان طور که مشاهده می شود، پیش بینی های شبکه عصبی با این رفتار فیزیکی همخوانی دارد و نشان می دهد مدل آموزش دیده توانسته رفتار مورد انتظار خاک را به طور صحیح بازنمایی کند. این مشاهده نیز نشان دهنده قابلیت تعمیم مدل در مواجهه با تغییرات این پارامترها است.

References

- [1] U. Farooq, M. Ajmal, S. Li, J. Yang, and S. Ullah, "Evaluation of pedotransfer functions to estimate soil water retention curve: a conceptual review," *Water*, vol. 16, no. 17, p. 2547, 2024.
 - [2] S. Norouzi, M. Sadeghi, M. Tuller, H. Ebrahimian, A. Liaghat, S. B. Jones, and L. W. de Jonge, "A novel laboratory method for the retrieval of the soil water retention curve from shortwave infrared reflectance," *Journal of Hydrology*, vol. 626, p. 130284, 2023.
 - [3] K. C. Onyelowe, F. F. Mojtabedi, S. Azizi, H. A. Mahdi, E. R. Sujatha, A. M. Ebid, ... and F. I. Aneke, "Innovative overview of SWRC application in modeling geotechnical engineering problems," *Designs*, vol. 6, no. 5, p. 69, 2022.
 - [4] S. L. Barbour, "Nineteenth Canadian Geotechnical Colloquium: The soil-water characteristic curve: a historical perspective," *Canadian Geotechnical Journal*, vol. 35, no. 5, pp. 873–894, 1998.
 - [5] H. Nowamooz and F. Masrouri, "Influence of suction cycles on the soil fabric of compacted swelling soil," *Comptes Rendus Géoscience*, vol. 342, no. 12, pp. 901–910, 2010.
 - [6] D. G. Fredlund and H. Rahardjo, *Soil Mechanics for Unsaturated Soils*, New York: John Wiley & Sons, 1993.
 - [7] F. Stenke, D. G. Toll, and D. Gallipoli, "Comparison of water retention curves for clayey soils using different measurement techniques," in *Unsaturated Soils 2006*, pp. 1451–1461, 2006.
 - [8] R. M. Reis, F. Saboya, S. Tibana, C. R. Marciano, A. B. Ribeiro, W. N. Sterck, and E. D. Avanzi, "Determination of soil-water retention curve for a young residual soil using a small centrifuge," in *Proceedings of the 18th International Conference on Soil Mechanics and Geotechnical Engineering*, Paris, pp. 1175–1178, 2013.
 - [9] W. Liu, X. Luo, F. Huang, and M. Fu, "Prediction of soil water retention curve using Bayesian updating from limited measurement data," *Applied Mathematical Modelling*, vol. 76, pp. 380–395, 2019.
 - [10] A. Abdallah, "Prediction of the soil water retention curve from basic geotechnical parameters by machine learning techniques," in *International*
- نگهداشت آب در مکش‌های مختلف منجر شده است. اثر پارامترهای حد روانی (LL) و شاخص خمیری (PI) نیز به صورت منطقی در پیش‌بینی‌های مدل منعکس شده و خاک‌های خمیری‌تر، منحنی‌های بالاتری نسبت به خاک‌های کم‌خمیر نشان داده‌اند. به‌طور کلی، می‌توان نتیجه گرفت که استفاده از شبکه عصبی عمیق با در نظر گرفتن مکش به عنوان ورودی، ابزاری دقیق، انعطاف‌پذیر و کارآمد برای برآورد منحنی SWRC در خاک‌های با پلاستیسیته کم فراهم می‌کند. این رویکرد می‌تواند در بسیاری از کاربردهای ژئوتکنیکی که نیازمند شناخت رفتار غیراشباع خاک هستند، از جمله تحلیل پایداری شیب‌ها، طراحی خاکریزها و سازه‌های خاکی متراکم‌شده، ارزیابی نشست و تحلیل تراوش در شرایط غیراشباع، به عنوان جایگزینی سریع و کم‌هزینه برای آزمایش‌های کلاسیک تعیین منحنی نگهداشت آب-خاک مورد استفاده قرار گیرد.
- با وجود این، نتایج این پژوهش دارای محدودیت‌هایی نیز می‌باشد که باید در تفسیر آن‌ها مورد توجه قرار گیرد؛ نخست آن‌که پایگاه داده مورد استفاده عمدتاً شامل خاک‌های با پلاستیسیته پایین است؛ بنابراین، تعمیم نتایج به خاک‌های با پلاستیسیته بالا یا خاک‌های دارای دامنه خمیری زیاد، نیازمند بررسی‌های تکمیلی و کالیبراسیون مجدد مدل است؛ نکته دیگر آن‌که در این تحقیق تنها شاخه اصلی خشک‌سازی منحنی SWRC در نظر گرفته شده و پدیده هیستریزیس به‌طور صریح مدل‌سازی نشده است. در پژوهش‌های آینده، می‌توان با گسترش پایگاه داده، افزودن شاخه ترشوندگی، بررسی خاک‌های با رفتار متورم‌شونده و به‌کارگیری چارچوب‌های پیشرفته‌تری مانند شبکه‌های فیزیک‌محور و تحلیل عدم قطعیت، توان پیش‌بینی و دامنه کاربرد مدل را توسعه داد. همچنین در پژوهش حاضر، برای استخراج نقاط داده مصنوعی از مدل و نگوختن استفاده شد. این مدل با فرض توزیع حفرات تک‌وجهی، هرچند عملکرد مناسبی در شبیه‌سازی منحنی نگهداشت آب خاک‌های با ساختار تخلخل ساده دارد، اما کاربرد آن در خاک‌های دارای تخلخل دوگانه و توزیع حفرات دووجهی محدود است. همچنین، با توجه به عدم تمرکز پایگاه داده مورد استفاده در این پژوهش بر خاک‌های دارای تخلخل دوگانه، شبکه عصبی توسعه‌یافته نیز برای کاربرد در این نوع خاک‌ها با محدودیت همراه است.

- Computational Methods in Engineering, vol. 29, no. 5, pp. 3109–3149, 2022.
- [19] S. Wang, Y. K. Yi, and N. Liu, “The ANN architecture analysis: A case study on daylight, visual, and outdoor thermal metrics of residential buildings in China,” *Buildings*, vol. 13, no. 11, p. 2795, 2023.
- [20] W. S. Sillers, D. G. Fredlund, and N. Zakerzahh, “Mathematical attributes of some soil–water characteristic curve models,” *Geotechnical and Geological Engineering*, vol. 19, no. 3, pp. 243–283, 2001.
- [21] R. D. Alves, G. de F. N. Gitirana Jr, and S. K. Vanapalli, “Advances in the modeling of the soil–water characteristic curve using pore-scale analysis,” *Computers and Geotechnics*, vol. 127, p. 103766, 2020.
- [22] S. Norouzi, C. Pesch, E. Arthur, T. Norgaard, P. Moldrup, M. H. Greve, et al., and L. W. de Jonge, “Physics-informed neural networks for estimating a continuous form of the soil water retention curve from basic soil properties,” *Water Resources Research*, vol. 61, no. 3, e2024WR038149, 2025.
- [23] G. Shoukat, G. Michel, M. Coughlan, A. Malekjafarian, I. Thusyanthan, C. Desmond, and V. Pakrashi, “Generation of synthetic CPTs with access to limited geotechnical data for offshore sites,” *Energies*, vol. 16, no. 9, p. 3817, 2023.
- [24] B. Usowicz, J. Lipiec, and A. Siczek, “Fitting the van Genuchten model to the measured hydraulic parameters in soils of different genesis and texture at the regional scale,” *International Agrophysics*, vol. 38, no. 4, pp. 373–382, 2024.
- [25] J. L. Jensen, P. Schjønning, C. W. Watts, B. T. Christensen, and L. J. Munkholm, “Soil water retention: Uni-modal models of pore-size distribution neglect impacts of soil management,” *Soil Science Society of America Journal*, vol. 83, no. 1, pp. 18–26, 2019.
- Conference on Information Technology in Geo-Engineering, Cham: Springer International Publishing, Sep., pp. 383–392, 2019.
- [11] E. A. C. Albuquerque, L. P. D. F. Borges, A. L. B. Cavalcante, and S. L. Machado, “Prediction of soil water retention curve based on physical characterization parameters using machine learning,” *Soils and Rocks*, vol. 45, no. 3, p. e2022000222, 2022.
- [12] X. Ding and A. El-Zein, “Water retention curves of clayey soils by artificial neural networks with uneven datasets,” in *International Conference of the International Association for Computer Methods and Advances in Geomechanics*, Cham: Springer International Publishing, Jul., pp. 45–52, 2022.
- [13] K. Lamorski, Y. Pachepsky, C. Sławiński, and R. T. Walczak, “Using support vector machines to develop pedotransfer functions for water retention of soils in Poland,” *Soil Science Society of America Journal*, vol. 72, no. 5, pp. 1243–1247, 2008.
- [14] H. Bayat, M. R. Neyshaburi, K. Mohammadi, N. Nariman-Zadeh, M. Irannejad, and A. S. Gregory, “Combination of artificial neural networks and fractal theory to predict soil water retention curve,” *Computers and Electronics in Agriculture*, vol. 92, pp. 92–103, 2013.
- [15] O. Mostafa, M. G. Arab, and K. Hamad, “Prediction of soil-water characteristic curve for low-plasticity soils using multi-output neural network,” *Transportation Infrastructure Geotechnology*, vol. 11, no. 6, pp. 4381–4404, 2024.
- [16] S. A. dos Santos Pereira, G. de F. N. Gitirana Jr, T. A. Mendes, and R. de Aquino Gomes, “Artificial neural networks for the prediction of the soil-water characteristic curve: an overview,” *Soil and Tillage Research*, vol. 248, p. 106466, 2025.
- [17] M. Rastgou, H. Bayat, M. Mansoorizadeh, and A. S. Gregory, “Estimating soil water retention curve by extreme learning machine, radial basis function, M5 tree and modified group method of data handling approaches,” *Water Resources Research*, vol. 58, no. 4, p. e2021WR031059, 2022.
- [18] U. M. R. Paturi, S. Cheruku, and N. S. Reddy, “The role of artificial neural networks in prediction of mechanical and tribological properties of composites—a comprehensive review,” *Archives of*