

Evaluation of soil water integral energy estimation using linear and non-linear models

Mojtaba Alimohammadi¹, Davoud Zarehaghi^{2*}, Mohammadreza Neyshabouri³, Mohammadali Ghorbani⁴

¹ Ph.D. candidate, Department of Soil Engineering and Sciences, University of Tabriz, Tabriz, Iran

² Associate Professor, Department of Soil Engineering and Sciences, University of Tabriz, Tabriz, Iran

³ Professor, Department of Soil Engineering and Sciences, University of Tabriz, Tabriz, Iran

⁴ Professor, Department of Water Engineering and Sciences, University of Tabriz, Tabriz, Iran

Extended Abstract

Introduction

Soil moisture or water content, and the fraction of that water available to plants, are among the most critical aspects of soil water management. The concept of plant-available water was first introduced nearly a century ago by Veihmeyer and Hendrickson (1927), derived from the difference between Field Capacity (FC) and Permanent Wilting Point (PWP). The concepts of the Unrestricted Water Content Range and the Minimum Restricted Water Content Range were proposed by DaSilva et al. (1994). In this framework, in addition to the two moisture limits (FC and PWP), soil aeration and the effect of soil penetration resistance on water availability to the plant are considered using simple relationships. A limitation or defect of the LLWR concept is that it treats the boundary values for aeration porosity, penetration resistance, and soil water potential as abrupt or discontinuous in restricting water availability. In an effort to overcome the shortcomings of these preceding concepts, Minasny and McBratney (2003) proposed the Soil Water Integral Energy (IE) as a criterion for estimating plant-available water in soil, replacing the focus on soil moisture content. Soil water integral energy is a measure of the energy required to extract water from the soil over a specified range of soil water content. Under this concept: firstly, the plant-available water is not solely confined to the PWP and FC range; secondly, the effect of rapid drainage at high moisture contents, which reduces the opportunity for soil water supply to the plant, is taken into account; and thirdly, the limitation imposed by soil hydraulic conductivity at low moisture contents on water flow towards the root and subsequent absorption is incorporated. They utilized various weighting functions across a wide range of soil water potentials, encompassing the potential effect of all limiting physical characteristics on soil water availability. The most significant limitation in employing this index is the time-consuming and costly process of obtaining the soil moisture characteristic curve, the soil penetration resistance curve, and the accuracy or reliability of the coefficients used in defining the proposed weighting functions. Furthermore, in addition to time and expense, errors present in soil sampling and measurement can impose constraints on the application of IE (Integral Energy).

Materials and Methods

The study area includes a part of the Tabriz plain. For estimation of IE using the deep learning method, Artificial Neural Network (ANN), and Multiple Linear Regression (MLR), Mathematica Wolfram software version 14.1.0 was utilized. The input features for all three models (MLR, ANN, and Deep ANN) were identical. The data were randomly divided into two groups: training (67 data points) and testing (30 data points). The input features for the models included: 1- Percentage of water-stable aggregates 2- Soil bulk density 3- Porosity 4- Saturated hydraulic conductivity of the soil 5- Percentage of soil texture particles 6- Equivalent calcium carbonate 7- Penetration resistance at saturated moisture 8- Saturated moisture.

Results and Discussion

The created models were evaluated using the evaluation statistics of the coefficient of determination R^2 , the adjusted coefficient of determination R^2_{adj} , the root mean square error RMSE, the relative error RMSEr, the model efficiency coefficient NSE, and the average percentage of relative error RME. The results showed that the deep learning method with the highest adjusted coefficient of determination (training: 0.998, test: 0.661) and the lowest root mean square error (training: 15.943, test: 118.593), the artificial neural network method (training: 0.945, test: 0.514) and root mean square error (training: 45.347, test: 139.267), and the linear multivariate regression method (training: 0.544, test: 0.317) and root mean square error (training: 126.955, test: 239.264), respectively, provide the best estimate of the IE index.

Conclusion

This study underscores the importance of soil water management and the precise assessment of Plant Available Water (PAW). Given the limitations of traditional concepts like PAW and LLWR, particularly their reliance on discontinuous boundaries, the newer soil water Integral Energy (IE) criterion is adopted as a more accurate measure for estimating plant water availability in soil. The results demonstrated that IE can be effectively and accurately estimated in the studied area (the Tabriz plain) using deep learning techniques (Artificial Neural Networks), relying on a comprehensive set of key soil properties, including the percentage of water-stable aggregates, bulk density, porosity, and saturated hydraulic conductivity. These findings pave the way

for applying advanced, data-driven modeling approaches to optimize soil water resource management in arid and semi-arid regions.

Keywords: Water availability for plants, estimation methods, modeling, Lake Urmia.

Article Type: Research Article

Acknowledgement

The authors of this research express their deepest appreciation and sincere gratitude to the esteemed professors of the relevant faculties at the University of Tabriz. Their continuous academic support, strategic insights, and meticulous supervision throughout all stages, from the initial design to the final drafting of this study, have played an irreplaceable role in achieving the precise current results. We are indebted to their illuminating guidance and profound expertise, which extended beyond typical research limitations.

Conflicts of interest

The authors of this article declare that they have no conflict of interest regarding the writing and publication of the materials and results of this research.

Data Availability Statement:

All information and results are presented within the text of the article.

Authors' contribution

Mojtaba Alimohammadi: Conceptualization, methodology, formal analysis and investigation, visualization, resources, writing-original draft preparation; **Davoud Zarehaghi:** Conceptualization, supervision, formal analysis and investigation, manuscript editing; **Mohammadreza Neyshabouri:** Conceptualization, methodology, formal analysis and investigation, resources, manuscript editing; **Mohammadali Ghorbani:** Conceptualization, methodology, formal analysis and investigation, manuscript editing

*Corresponding Author, E-mail: Davoud Zarehaghi, davoudhaghi@tabrizu.ac.ir

Citation: Alimohammadi, M., Zarehaghi, D., Neyshabouri, MR., Ghorbani, MA. (2026). Evaluation of soil water integral energy estimation using linear and non-linear models. *Water and Soil Management and Modeling*. 6(1),317 -331.

doi: 10.22098/mmws.2025.18678.1711

Received: 27 October 2025, Received in revised form: 01 December 2025, Accepted: 01 December 2025, Published online: 21 March 2026

Water and Soil Management and Modeling, Year 2026, Vol. 6, No. 1, pp. 317-331

Publisher: University of Mohaghegh Ardabili

© Author(s)





ارزیابی برآورد انرژی انتگرالی آب خاک با استفاده از مدل های خطی و غیرخطی

مجتبی علی محمدی^۱، داود زارع حقی^{۲*}، محمدرضا نیشابوری^۳، محمدعلی قربانی^۴

^۱ دانشجوی دکتری، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۲ دانشیار، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۳ استاد، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۴ استاد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

چکیده

مشخص کردن فراهمی آب برای گیاهان در انواع خاک ها از چالش های مهم مدیریت آبیاری در کشاورزی است. تعیین فراهمی آب خاک با استفاده از مفاهیم مختلفی همچون آب قابل استفاده (AWC)، دامنه آب (رطوبت) با حداقل محدودیت (LLWR)، گنجایش انتگرالی آب خاک و انرژی انتگرالی آب خاک (IE) پیشنهاد گردیده است. شاخص انرژی انتگرالی آب خاک (IE) نسبت به سایر معیارها بهتر است زیرا مستقیماً نیروی نگهدارندگی آب خاک را اندازه گیری می کند و نه صرفاً حجم آب موجود در خاک. باوجوداین مزیت، اما به علت وقت گیر بودن و هزینه بر بودن، اندازه گیری مستقیم آن عملاً مقرون به صرفه نبوده و در عرصه میدانی کاربرد چندانی نداشته است. در این پژوهش سه روش رگرسیون چندمتغیره خطی (MLR)، شبکه عصبی مصنوعی (ANN) و یادگیری عمیق (DL) برای ایجاد و ارزیابی توابع انتقالی در برآورد IE بکار گرفته شد. برای این منظور از داده های خاک در ۹۷ مکان از اراضی زراعی و مرتعی حاشیه ای دریاچه ارومیه استفاده شد. درصد خاکدانه های پایدار در آب، جرم مخصوص ظاهری، تخلخل کل، هدایت هیدرولیکی اشباع، درصد ذرات شن، رس و سیلت، مقاومت فروری در رطوبت اشباع، درصد کربنات کلسیم معادل و رطوبت اشباع خاک به عنوان ورودی مدل ها مورد استفاده قرار گرفت. مدل های ایجاد شده با استفاده از آماره های ارزیابی مانند ضریب تبیین R^2 ، ضریب تعیین تعدیل شده $R^2_{adjusted}$ ، جذر میانگین مربعات خطا RMSE، خطای نسبی RMSEr، ضریب کارایی مدل NSE، میانگین درصد خطای نسبی RME ارزیابی شد. نتایج نشان داد که روش یادگیری عمیق با بیشترین ضریب تبیین تعدیل شده (آموزش: ۰/۹۹۸، آزمون: ۰/۶۶۱) و کمترین مقدار جذر میانگین مربعات خطا (آموزش: ۱۵/۹۴۳، آزمون: ۱۱۸/۵۹۳) روش شبکه عصبی مصنوعی (آموزش: ۰/۹۴۵، آزمون: ۰/۵۱۴) و جذر میانگین مربعات خطا (آموزش: ۴۵/۳۴۷، آزمون: ۱۳۹/۲۶۷) و روش رگرسیون چندمتغیره خطی (آموزش: ۰/۵۴۴، آزمون: ۰/۳۱۷) و جذر میانگین مربعات خطا (آموزش: ۱۲۶/۹۵۵، آزمون: ۲۶۴/۲۳۹) به ترتیب بهترین برآورد را از شاخص IE ارائه می دهند.

واژه های کلیدی: فراهمی آب برای گیاهان، روش های برآورد، مدل سازی، دریاچه ارومیه.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: داود زارع حقی، davoudhaghi@tabrizu.ac.

استناد: علی محمدی، مجتبی، زارع حقی، داود، نیشابوری، محمدرضا و قربانی، محمدعلی (۱۴۰۵). ارزیابی برآورد انرژی انتگرالی آب خاک با استفاده از مدل های خطی و غیرخطی. *مدل سازی و مدیریت آب و خاک*، ۶ (۱)، ۳۳۱-۳۱۷.

doi: 10.22098/mmws.2025.18678.1711

تاریخ دریافت: ۱۴۰۴/۰۸/۰۵، تاریخ بازنگری: ۱۴۰۴/۰۹/۱۰، تاریخ پذیرش: ۱۴۰۴/۰۹/۱۰، تاریخ انتشار: ۱۴۰۵/۰۱/۰۱

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۵، دوره ۶، شماره ۱، صفحه ۳۱۷ تا ۳۳۱

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

رطوبت یا آب خاک و این که چه جزئی از آن می تواند در دسترس گیاه باشد از مهم ترین موضوعات مدیریت آب خاک است. مفهوم آب قابل استفاده گیاه^۱ نزدیک به یک قرن پیش توسط (VIEhmyer and Hendrickson, 1927) ارائه شد که از تفاضل دو حد ظرفیت مزرعه ای^۲ و نقطه پژمردگی دائم^۳ به دست می آید. مفهوم دامنه رطوبتی بدون محدودیت^۴ و دامنه رطوبتی با حداقل محدودیت^۵ توسط (DaSilva et al. 1994) پیشنهاد و در آن علاوه بر دو حد رطوبتی FC و PWP، تهویه خاک و اثر مقاومت فروروی خاک هم روی فراهمی آب برای گیاه با روابط ساده در نظر گرفته شد. محدودیت یا نقص LLWR این است که مرز مقادیر محدودکننده تخلخل تهویه ای، مقاومت فروروی و پتانسیل آب خاک را ناگهانی یا منقطع در نظر می گیرد.

در راستای رفع ایرادات مفاهیم فوق (Minasny and McBratney, 2003) بجای رطوبت خاک، انرژی انتگرالی آب خاک^۶ را به عنوان معیاری جهت برآورد آب قابل استفاده گیاه در خاک ارائه نمودند. انرژی انتگرالی آب خاک معیاری برای سنجش میزان انرژی مورد نیاز برای برداشتن آب از خاک در یک بازه مشخص از محتوای آب خاک است. در مفهوم مذکور اولاً آب قابل استفاده خاک برای گیاه صرفاً منحصر به دامنه PWP و FC نیست، ثانیاً اثر زهکشی سریع در رطوبت های بالا که فرصت فراهمی آب خاک برای گیاه را کم می کند در نظر گرفته می شود و ثالثاً محدودکنندگی هدایت هیدرولیکی خاک در رطوبت های پایین روی جریان آب به سمت ریشه و در نهایت جذب آب دخالت داده می شود. آن ها از توابع وزنی مختلف در دامنه وسیعی از پتانسیل های آب خاک که اثر بالقوه همه ویژگی های فیزیکی محدودکننده را در فراهمی آب خاک شامل می شود استفاده کردند. مهم ترین محدودیت در به کارگیری این شاخص، زمان بر و پرهزینه بودن به دست آوردن منحنی رطوبتی خاک، منحنی مقاومت فروروی خاک و درستی یا اطمینان به ضرایبی است که در ایجاد توابع وزنی بکار رفته پیشنهاد شده اند. همچنین، علاوه بر وقت و هزینه، خطاهایی که در نمونه برداری ها و اندازه گیری وجود دارد، می تواند در به کارگیری IE محدودیت ایجاد کند. (Asgarzadeh et al. 2011) به مقایسه انرژی انتگرالی (IE) با PAW و LLWR^۷ برای کمی سازی در دسترس بودن آب خاک برای گیاه، با استفاده از دوازده نمونه خاک از استان

همدان پرداختند، نتایج نشان داد که مقادیر IE بین روش های مختلف تفاوت معنی داری دارند و وابستگی قوی به شاخص دکستر در محدوده خشک و همچنین افزایش نیاز به انرژی برای جذب آب در خاک های رسی دارد که در نهایت IE را به عنوان یک شاخص مفید مکمل برای ارزیابی کیفیت فیزیکی خاک معرفی می کند.

در مورد امکان برآورد IE به صورت غیرمستقیم از طریق توابع انتقالی (PTF) با به کارگیری الگوریتم های مختلف تحقیقاتی وجود ندارد، در زمینه مدل سازی پارامترهای مربوط به آب خاک، تحقیقات گسترده ای انجام شده است. (Ahmadi et al. 2019) به مقایسه کارایی توابع رگرسیونی و شبکه های عصبی مصنوعی برای برآورد رطوبت های ظرفیت زراعی (FC) و نقطه پژمردگی دائم (PWP) خاک پرداخت. هدف اصلی، بررسی تأثیر استفاده از ابعاد فرکتالی ذرات اولیه، خاکدانه ها و منافذ برافزایش دقت این برآوردها بود. برای این منظور، ۹۰ نمونه خاک از سه منطقه استان اردبیل جمع آوری شد. نتایج نشان داد که در روش شبکه عصبی مصنوعی^۸، استفاده از ابعاد فرکتالی منجر به افزایش دقت توابع برای برآورد رطوبت های PWP و FC شد. استفاده از ابعاد فرکتالی خاکدانه ها در بهبود دقت مدل های ANN برای برآورد FC مؤثر بود، هرچند تأثیر قابل توجهی بر دقت برآورد PWP نداشت. (Niu et al. 2019) با موضوع مقایسه رگرسیون خطی چندگانه، شبکه عصبی مصنوعی، ماشین یادگیری افراطی^۹ و ماشین بردار پشتیبان^{۱۰} در بررسی عملکرد مخزن برقی آبی سدها پژوهشی را انجام دادند. نتایج این پژوهش نشان داد که الگوریتم های هوش مصنوعی به ترتیب شامل یادگیری ماشین، ماشین بردار و شبکه عصبی مصنوعی عملکرد بهتری در برآورد دارند. (Kazemi et al. 2022) در پژوهشی به بررسی عملکرد شبکه های عصبی مصنوعی، روش مدیریت گروهی چندهدفه داده ها^{۱۱} و رگرسیون خطی چندمتغیره^{۱۲} برای برآورد دامنه رطوبتی با حداقل محدودیت^{۱۳} پرداختند. ۱۱ ویژگی خاک در ۱۸۸ نمونه خاک به عنوان متغیرهای مستقل برای برآورد استفاده شد. آنان اظهار داشتند که ANN به عنوان دقیق ترین و مطمئن ترین ابزار برای پیش بینی دامنه رطوبتی با حداقل محدودیت است. (Yong et al. 2023) در پژوهشی باهدف مطالعه عملکرد ۴ الگوریتم آموزشی شبکه عصبی مصنوعی

⁸ Artificial Neural Networks (ANN).

⁹ Extreme Learning Machine

¹⁰ Support Vector Machine

¹¹ Multi-objective Group Method of Data Handling (mGMDH)

¹² Multiple Linear Regression (MLR)

¹³ Limiting Lowest Water Retention (LLWR)

¹ Plant Available Water (PAW)

² Field Capacity (FC)

³ permanent wilting point (PWP)

⁴ Non limiting water range ()

⁵ Least limiting water range (LLWR)

⁶ Water Integral Energy (IE)

⁷ Integral water capacity

خاک‌های لسی شمال ایران با استفاده از مدل‌های یادگیری ماشینی بر اساس ۴۵ نمونه و ویژگی‌های فیزیکی-شیمیایی آن‌ها پژوهشی را انجام دادند. پس از بهینه‌سازی پارامترها، مدل جنگل تصادفی^۹ با بهترین عملکرد (RMSE=15)، ($R^2=0.42$) و بالاترین پایداری و کمترین نوسان) به‌عنوان بهترین مدل شناخته شد. مدل XGBoost¹⁰ در رتبه دوم قرار گرفت و مدل درخت تصمیم^{۱۱} ضعیف‌ترین بود. تحلیل حساسیت نشان داد که کربن آلی مهم‌ترین عامل تأثیرگذار بر آب‌گیری خاک بوده است.

یادگیری عمیق زیرمجموعه پیشرفته‌ای از شبکه‌های عصبی مصنوعی است که بر اساس ساختار و عملکرد نورون‌های سیستم عصبی انسان طراحی شده‌اند که به‌عنوان هوش مصنوعی نیز شناخته می‌شود. اساس کار شبکه عصبی مصنوعی با زیرمجموعه‌های خود (یادگیری ماشین و یادگیری عمیق) تجزیه و تحلیل اطلاعات دریافتی از محیط و یادگیری از آن و تولید خروجی بر اساس آن است. نشان داده شده است که نسخه یادگیری عمیق در مقایسه با شبکه عصبی معمولی قابلیت و توانمندی بالاتری در یادگیری انواع داده یا اطلاعات و تصحیح خطا در حین آموزش دارد.

هدف از پژوهش حاضر، برآورد انرژی انتگرالی آب خاک (IE) به روش رگرسیون چندمتغیره، شبکه عصبی مصنوعی و روش یادگیری عمیق است. در ضمن بررسی کارایی سه روش فوق‌الذکر نیز انجام شد.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه شامل بخشی از دشت تبریز به مساحت حدود ۳۰ هزار هکتار با مختصات جغرافیایی $37^{\circ} 53' 38''$ الی $38^{\circ} 5' 15''$ شمالی $48^{\circ} 48' 04''$ الی $45^{\circ} 7' 11''$ شرقی بود. شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه را نشان می‌دهد. ارتفاع این منطقه بین ۱۲۹۲ تا ۱۴۴۳ متر از سطح دریا متغیر است. این ناحیه عمدتاً برای کشت آبی یونجه، گندم و جو مورد استفاده قرار می‌گیرد و در بخش‌های مورد کشت، شوری خاک عاملی محدودکننده محسوب نمی‌شود. محدوده مطالعاتی برگرفته از (Seifi et al, 2020) است. بر اساس طبقه‌بندی (۲۰۱۰) USDA، رده‌های خاک در این منطقه شامل Entisols، Inceptisols و Mollisols است. این منطقه دارای اقلیم نیمه‌خشک بوده و میانگین بارش سالانه آن حدود ۲۸۷/۹

شامل، نزول گرادیان با تکانه^۱، شبه نیوتن^۲، تنظیم بیزی^۳ و لونبرگ - مارکوارت^۴ برای برآورد ضرایب معادله هدایت هیدرولیکی ون گنوختن - معلم توسط توابع انتقالی^۵ استفاده کردند. در آن پژوهش تعداد ۸۶ نمونه خاک از پایگاه داده UNSODA استخراج شد. نتایج آن‌ها نشان داد که الگوریتم تنظیم بیزی به داده‌های ناهمگن نسبت سایر الگوریتم‌های آموزشی پایدار و قوی‌تر است. (Etminan et al. (2023) با هدف استفاده از مدل HYDRUS و الگوریتم DREAM (یک روش نمونه‌برداری زنجیره‌ای مارکف)، تأثیر عدم قطعیت داده‌ها و پارامترهای هیدرولیکی بر دقت برآورد رطوبت خاک بررسی شد. نتایج نشان داد که عدم قطعیت بر هدایت هیدرولیکی اشباع بیشتر از پارامترهای دیگر بوده و در امتداد پروفیل خاک، عدم قطعیت مدل و پارامترها منجر به کاهش عملکرد مدل HYDRUS شده است. به‌طور کلی، الگوریتم DREAM روشی کارآمد برای ارزیابی تأثیر عدم قطعیت‌ها بر عملکرد مدل‌های هیدرولیکی است. (Vawda et al. (2024) پژوهشی پیرامون مقایسه کاربرد شبکه‌های عصبی مصنوعی و شبکه‌های عصبی کانولوشنال^۶ در برآورد زیست‌توده چمن در فصل خشک انجام دادند. به‌طور کلی، یافته‌های این مطالعه نشان داد که شبکه‌های عصبی کانولوشنال در برآورد زیست‌توده چمن در فصل خشک بهتر از ANN عمل می‌کند. (Khashei Siuki et al. (2024) در پژوهشی، عملکرد دو الگوریتم فرابتکاری تکامل تفاضلی^۷ و بهینه‌ساز ازدحام ذرات^۸ در برآورد پارامترهای هیدرولیکی منحنی رطوبتی خاک بر مبنای مدل‌های ون گنوختن و بروکز-کوری در چهار کلاس بافتی خاک شامل لوم رس شنی، لوم شنی، لوم و سیلت لوم بررسی شد. داده‌های رطوبتی از ۲۰ نقطه نمونه‌برداری و در دامنه مکش صفر تا ۱۵۰۰ سانتی‌متر آب به دست آمد. برای مقایسه نتایج، از نرم‌افزار RETC با روش محلی غیرخطی حداقل مربعات و شاخص‌های آماری RMSE و R^2 استفاده شد. نتایج نشان داد که الگوریتم تکامل تفاضلی در هر دو مدل کمترین مقدار RMSE را در تمامی کلاس‌های بافتی ارائه داد، درحالی‌که بالاترین مقدار RMSE و پایین‌ترین مقدار R^2 مربوط به نرم‌افزار RETC بود. بر این اساس، الگوریتم‌های فرابتکاری به دلیل کارایی بالا در مسائل چندمتغیره با روابط نمایی، گزینه‌ای مناسب برای برآورد پارامترهای هیدرولیکی منحنی رطوبتی خاک محسوب می‌شوند. (Behbahanian et al. (2025) باهدف تخمین آب‌گیری

⁷ Differential evolution algorithm (DE)

⁸ Particle swarm optimization (PSO)

⁹ Random Forest Model

¹⁰ eXtreme Gradient Boosting

¹¹ Decision Tree Model

¹ Gradient Descent with Momentum

² Quasi-Newton


³ Bayesian Regularization

⁴ Levenberg-Marquardt

⁵ Pedotransfer Functions (PTF)

⁶ Convolutional Neural Networks

میلی متر است. میانگین دمای تابستان و زمستان به ترتیب ۱۸ و ۶/۹ درجه سانتی گراد هست. رژیم دما و رطوبت خاک در این منطقه به ترتیب مزیک^۱ و زریک^۲ است (Seifi et al. 2020).



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه
Figure 1- Geographical location of the study area

درجه، قطر میله ۲ میلی متر و سرعت فروروی ۲ میلی متر در دقیقه در نمونه های خاک اشباع اندازه گیری شد؛ و محاسبه تخلخل کل (n) از روی داده های جرم مخصوص ظاهری (D_b) و حقیقی (D_p) زیر در نمونه های به هم نخورده اندازه گیری شد.

۳-۲- انرژی انتگرالی آب

انرژی انتگرالی آب خاک (IE) در هر دامنه رطوبتی ($0/3$ ، $0/1$ ، $0/7$ ، 1 ، 3 ، 7 ، 10 و 15 بار) حاصل انتگرال قدر مطلق شیب منحنی رطوبتی خاک ($C(h)$) در همان دامنه است و مقدار آن برحسب ژول بر کیلوگرم با استفاده از رابطه ارائه شده توسط Asgarzadeh et al, (2011) و (Minasny and McBratney, 2003) محاسبه شد.

$$EI = \frac{1}{10W} \int_{h_i}^{h_f} (\prod_{i=1}^m \omega_i(h)) C(h) dh \quad (1)$$

که در آن:

h_i و h_f به ترتیب مکش در نقطه شروع و نقطه پایانی جذب بالقوه آب توسط گیاه برحسب cm و عدد ۱۰ نیز جهت تبدیل واحد از (سانتی متر) به ژول بر کیلوگرم است. W: مقدار رطوبت حجمی در دامنه مکش های h_f و h_i .

ω_i : توابع وزن دهی (بدون بعد و جهت وزن دهی به محدودیت های فیزیکی مختلف به عنوان تابعی از مکش خاک)

۲-۲- اندازه گیری های ویژگی های خاک

نمونه های خاک به هم خورده (با حداقل دست خورده گی و احتیاط کامل) به مقدار حدود ۳ کیلوگرم و نمونه های خاک به هم نخورده با استفاده از استوانه های فلزی به قطر و ارتفاع ۵ سانتی متر از عمق ۱۰-۰ سانتی متری خاک در ۹۷ نقطه به طور تصادفی از کاربری های کشاورزی، مرتعی برداشته شد. نمونه های به هم خورده در آزمایشگاه هوا خشک شد، سپس بخشی از آن از الک ۲ میلی متر به منظور اندازه گیری مقادیر: توزیع اندازه ذرات (شن، سیلت و رس) به روش هیدرومتری (Or and Gee, 2002)، جرم مخصوص حقیقی به روش پیکنومتر (Blake, 1986)، کرنبات کلسیم معادل به روش کلسیمتری توسط اسید HCL یک نرمال (Nelson, 1982)، عبور داده شد. بخش دیگر نمونه های به هم خورده خاک از الک ۴/۷۵ میلی متر به منظور اندازه گیری درصد خاکدانه های پایدار در آب^۳ عبور داده شد. ویژگی های جرم مخصوص (Kemper and Rosenau, 1986)، ویژگی های جرم مخصوص ظاهری به روش استوانه (Hartge and Blake, 1986)، هدایت هیدرولیکی اشباع خاک K_s به روش بار افتان یا بار ثابت بسته به نوع بافت خاک (Klute, 1986)، منحنی مشخصه رطوبتی خاک (DaSilva and Kay, 1997) و مقاومت فروروی خاک (Herrick and. Jones, 2002) با استفاده از دستگاه فروسنج مخروطی دیجیتالی به قطر مخروط ۵ میلی متر، زاویه مخروط ۳۰

³ Water-Stable Aggregates percentage (WSA)

¹ mesic

² xeric

C(h): مقدار گنجایش رطوبت نقطه‌ای (cm^{-1}) یا قدر مطلق شیب منحنی مشخصه رطوبتی خاک ($|d\theta/dh|$) است. dh : تفاضل پتانسیل ماتریک در محدوده رطوبتی.

۴-۲- برآورد IE

در برآورد IE با روش یادگیری عمیق، شبکه عصبی مصنوعی و رگرسیون چندمتغیره خطی از نرم‌افزار Mathematica Wolfram نسخه ۱۴.۱.۰ استفاده شد. ویژگی‌های ورودی مدل در هر سه مدل (رگرسیون چندمتغیره، شبکه عصبی مصنوعی و شبکه عصبی مصنوعی عمیق) یکسان بود. داده‌ها به‌طور تصادفی به دو گروه آموزشی (۶۷ داده) و آزمونی (۳۰ داده) تقسیم شدند. ویژگی‌های ورودی مدل شامل: ۱- درصد خاکدانه‌های پایدار در آب ۲- جرم مخصوص ظاهری خاک. ۳- تخلخل. ۴- هدایت هیدرولیکی اشباع خاک. ۵- درصد ذرات بافت خاک ۶- کربنات کلسیم معادل ۷- مقاومت فروروی در رطوبت اشباع ۸- رطوبت اشباع.

به‌منظور برآورد و مقایسه عملکرد سه مدل برآورد انرژی انتگرالی آب خاک، سه سناریو مختلف تعریف شد. سپس محاسبات واسنجی بر روی ۷۰٪ از داده‌ها و محاسبات صحت سنجی بر روی ۳۰٪ از داده‌های باقیمانده با استفاده از نرم‌افزار Mathematica Wolfram نسخه ۱۴.۱.۱ انجام شد.

۱-۴-۲- رگرسیون

در این پژوهش برای برآورد از روش رگرسیون گام‌به‌گام رنج استفاده شد برای تعیین عدم وجود هم‌راستایی چندگانه یا وجود رابطه خطی بین متغیرهای مستقل از آزمون بارتلت استفاده شد (Ahmadi et al, 2019). یکی از اهداف مهم در تجزیه رگرسیون، برآورد ویژگی‌های ناشناخته تابع است. برای مثال در مورد دو متغیر، بین نقاط داده‌ها می‌توان خطوط زیادی ترسیم نمود، ولی تنها یکی از این خطوط به بهترین شکل ارتباط بین دو متغیر را نشان می‌دهد و آن خطی است که ویژگی‌های آن بر مبنای روش کم‌ترین مربعات خطا به دست می‌آید. درواقع با این روش، خطی که حداقل خطای ممکن را در برآورد متغیر وابسته با استفاده از گزینش متغیرهای مستقل دارد انتخاب می‌شود (Rezaei and Soltani, 1998).

۲-۴-۲- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی بر اساس اصول ساختار و عملکرد نورون‌های مغز انسان ساخته شده‌اند. همچنین به‌عنوان هوش مصنوعی نیز شناخته می‌شود. لایه ورودی یک شبکه عصبی

مصنوعی که اولین لایه است، ورودی‌ها را از منابع خارجی دریافت کرده و به لایه پنهان که لایه دوم است می‌رساند. هر نورون در لایه پنهان اطلاعاتی را از نورون‌های لایه قبلی دریافت می‌کند، وزن کلی را محاسبه می‌کند و سپس آن را به نورون‌های لایه بعدی منتقل می‌کند. این اتصالات وزن دارند، به این معنی که تأثیرات ورودی از لایه قبلی با دادن وزن مجزا به هر ورودی کم‌وبیش بهینه می‌شود. سپس این وزنه‌ها در طول فرایند سعی و خطا برای افزایش عملکرد مدل تنظیم می‌شوند. یادگیری عمیق و یادگیری ماشینی هر دو زیرمجموعه شبکه‌های عصبی مصنوعی هستند. (Karimizadeh, 2021)

در این پژوهش کد یک شبکه عصبی با استفاده از NetChain زبان نرم‌افزار Wolfram Mathematica تعریف شد که مجموعه‌ای از لایه‌ها را به هم متصل می‌کند که در آن خروجی یک لایه به‌عنوان ورودی به لایه بعدی عمل می‌کند. این شبکه بردارهای ورودی ۱۰ بعدی را دریافت کرده و آن‌ها را از طریق چندین لایه، از جمله لایه‌های نرمال‌سازی دسته‌ای که داده‌ها را در هر دسته نرمال‌سازی می‌کنند تا پایداری و سرعت آموزش را بهبود بخشند، پردازش می‌کند. لایه‌های خطی، تبدیل‌های آفین را با اندازه‌های خروجی مشخص (۳، ۱۳۶، ۹۰۰ و ۱) اعمال می‌کنند. علاوه بر این، یک لایه dropout این لایه در طول آموزش به‌صورت تصادفی برخی از نورون‌ها (واحد‌های عصبی) را غیرفعال می‌کند. این کار از بیش‌برازش^۱ جلوگیری می‌کند، به این معنی که مدل به‌جای یادگیری جزئیات غیرضروری داده‌های آموزشی، الگوهای کلی را یاد می‌گیرد. قبل از لایه خروجی نهایی گنجانده شده است تا نورون‌ها را به‌طور تصادفی در طول آموزش غیرفعال کند که به جلوگیری از بیش‌برازش کمک می‌کند.

۳-۴-۲- یادگیری عمیق

یادگیری عمیق زیرمجموعه پیشرفته‌ای از شبکه‌های عصبی مصنوعی است که بر اساس ساختار و عملکرد نورون‌های سیستم عصبی انسان طراحی شده‌اند که به‌عنوان هوش مصنوعی نیز شناخته می‌شود. اساس کار شبکه عصبی مصنوعی با زیرمجموعه‌های خود (یادگیری ماشینی و یادگیری عمیق) تجزیه و تحلیل اطلاعات دریافتی از محیط و یادگیری از آن و تولید خروجی بر اساس آن است. نشان داده شده است که نسخه یادگیری عمیق در مقایسه با شبکه عصبی معمولی قابلیت و توانمندی بالاتری در یادگیری انواع داده یا اطلاعات و تصحیح خطا در حین آموزش دارد. (Karimizadeh, 2021)

^۱ overfitting

وابسته نداشته باشند. به همین دلیل ممکن است در مدل های پیچیده تر، R^2 به طور کاذب بالا برود و باعث شود مدل بیش از حد برازش شود. (Karimizadeh, 2021)

جذر میانگین مربعات خطا و خطای نسبی: یکی از رایج ترین معیارهای مورد استفاده برای محاسبه خطا و ارزیابی کیفیت پیش بینی مدل است. عدد این آماره هر چه قدر کوچک تر باشد نشان دهنده دقت مدل است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \bar{y})^2}{n}} \quad (4)$$

در رابطه فوق n حجم نمونه بکار رفته است.

$$RMSEr = \frac{RMSE}{\bar{y}} \quad (5)$$

ضریب نش - ساتکلیف یا (ضریب کارایی مدل) از $-\infty$ تا یک قابل تغییر است که عدد یک بیانگر بهترین مدل (برآورد بدون خطا) است. (Nash, 1970)

$$NSE = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (6)$$

ضریب مذکور تمایل مدل را به بیش - برآوردی یا کم - برآوردی نشان می دهد. مقدار مثبت و منفی ضریب نشان دهنده تمایل مدل به ترتیب برای کم برآوردی و بیش برآوردی است.

$$RME = \left(\frac{1}{n} \right) \left(\sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \quad (7)$$

میانگین خطای نسبی^۱ معیاری برای ارزیابی دقت برآورد است. این آماره می توان عدد مثبت یا منفی باشد که در شرایط منفی کم برآوردی و در حالت مثبت نشان از بیش برآوردی مدل دارد.

۳- نتایج و بحث

برآورد مقادیر انرژی انتگرالی آب خاک با استفاده از مدل های رگرسیون چندمتغیره خطی (MLR)، شبکه عصبی مصنوعی و یادگیری عمیق انجام شد و دقت روش های یاد شده در مرحله صحت سنجی بر اساس معیارهای آماری (روابط ۳ تا ۸) محاسبه شده و در جدول ۳ و ۴ ارائه شده است.

۳-۱- ویژگی های آماری متغیرهای مستقل و وابسته اندازه گیری شده

در جدول ۱ ویژگی های آماری متغیرهای مستقل و وابسته اندازه گیری شده بر روی ۹۷ نمونه خاک نشان داده شده است. در

در این پژوهش مدل یادگیری عمیق توسط کد یک شبکه عصبی را با استفاده از NetGraph زبان نرم افزاری Mathematica و Wolfram تعریف شد. این زبان نرم افزاری با مشخص کردن صریح اتصالات بین لایه ها، امکان معماری های انعطاف پذیر و غیرخطی را فراهم کرد. شبکه با یک BatchNormalizationLayer شروع شد تا ورودی ۱۰ بعدی را نرمال سازی کند. ورودی نرمال شده سپس با اعمال فعال سازی های غیرخطی (LogisticSigmoid، Tanh) مختلف به سه شاخه موازی تقسیم شد و خروجی های این شاخه ها با استفاده از چندین گره TotalLayer که ورودی ها را جمع می کنند و یک CatenateLayer که آن ها را به هم پیوند می دهد، ترکیب شد و به طور مؤثر اطلاعات را به روش های مختلف ادغام کرد. سپس این اطلاعات ادغام شده از یک LinearLayer نهایی با یک واحد خروجی عبور کرد و پیش بینی شبکه تولید شد. این طراحی برای کارهایی که نیاز به تشخیص الگوی پیچیده با یک خروجی واحد دارند، مناسب است.

۳-۲- معیارهای ارزیابی

ارزیابی موفقیت تحقیق در برآورد IE بر اساس سنجش معیارهای درستی برآورد به شرح زیر است:

ضریب تبیین و ضریب تعیین تعدیل شده: معیاری بدون بعد که معمولاً بین ۰ تا ۱ متغیر بوده و برای ارزیابی دقت مدل انتخاب شده به کار می رود که از رابطه (Gujarati et al, 2003) زیر محاسبه شد.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (2)$$

در این رابطه، y_i مقدار محاسباتی، $\hat{y}$ مقدار پیش بینی شده توسط مدل، $\bar{y}$ میانگین مقادیر مشاهده ای هستند.

$$R^2_{Adjusted} = 1 - \left[\frac{(1 - R^2)(n - 1)}{n - k - 1} \right] \quad (3)$$

در این فرمول n حجم نمونه و k تعداد متغیرهای پیش بینی کننده رفتار متغیر پیش بینی شده است. در این پژوهش بجای استفاده از ضریب تبیین (R^2) از ضریب تبیین تعدیل شده (R^2_{adj}) استفاده شده چراکه R^2_{adj} با در نظر گرفتن تعداد متغیرهای مستقل، معیاری دقیق تر برای ارزیابی تناسب مدل و مقایسه مدل های مختلف ارائه می دهد. ضریب تبیین همیشه با افزایش تعداد متغیرهای مستقل در مدل، افزایش می یابد، حتی اگر این متغیرها ارتباطی با متغیر

¹ relative mean error

تغییرات نسبتاً بالا دلالت بر قابلیت توابع انتقالی ایجاد شده در برآورد دارد (Bayat et al. 2011). نمونه خاک از ۱۰ کلاس بافتی هستند (شکل ۱).

تفسیر این جدول نکته موردتوجه میزان پراکندگی داده‌ها است. ضریب تغییرات و انحراف استاندارد مهم‌ترین پارامتری است که می‌تواند میزان پراکندگی داده‌ها را نشان دهد. با توجه به این که هدف این پژوهش مدل‌سازی انرژی انتگرالی آب است. دامنه


جدول ۱ - ویژگی‌های آماری متغیرهای مستقل و وابسته اندازه‌گیری شده بر روی ۹۷ نمونه خاک.

Table 1 - Statistical characteristics of independent and dependent variables measured on 97 soil samples

داده‌های آزمونی					داده‌های آموزشی					Unit	Parameter
Coefficient of Variation (CV)	Standard Deviation (SD)	Average	max	min	Coefficient of Variation (CV)	Standard Deviation (SD)	Average	max	min		
0.50	25.61	51.64	95.53	2.55	0.51	25.99	51.03	99.51	5.62	%	WSA
0.11	0.13	1.26	1.51	0.97	0.12	0.16	1.38	1.87	0.93	gr cm ⁻³	D _b
0.10	0.05	0.52	0.63	0.43	0.13	0.06	0.48	0.65	0.29	cm ³ cm ⁻³	n
1.65	34.73	21.11	138.65	0.11	1.64	21.68	13.21	168.11	0.54	mmh ⁻¹	K _s
0.68	8.61	12.59	36.77	0.92	0.5	19.21	38.76	86.06	4.41	%	Sand
0.32	10.69	33.75	56.23	10.78	0.43	11.38	26.49	49.23	5.14	%	Clay
0.14	7.33	53.66	75.63	41.60	0.34	11.99	34.76	61.65	8.81	%	Silt
0.31	0.13	0.43	0.63	0.19	0.31	0.19	0.62	1	0.14	MPa	PR _s
0.85	6.15	7.23	20.02	0.29	0.84	5.8	6.91	19.04	0.26	%	CCE
0.10	0.05	0.55	0.68	0.41	0.12	0.06	0.48	0.63	0.32		θ _{vs}
0.56	237.46	425.65	1044.50	12.19	0.46	205.7	446.19	998.4	10.57	JKg ⁻¹	IE

WAS : درصد خاکدانه‌های پایدار در آب. D_b: جرم مخصوص ظاهری خاک. n: تخلخل خاک. K_s: هدایت هیدرولیکی اشباع خاک. Silt, Clay, Sand: درصد ذرات شن، رس و سیلت. PR_s: مقاومت فروروی در

رطوبت اشباع. CCE: درصد کربنات کلسیم معادل. θ_{vs}: رطوبت حجمی اشباع. IE: انرژی انتگرالی آب خاک.



شکل ۲ - توزیع بافت خاک ۹۷ نمونه خاک مورد مطالعه

Figure 2 - Soil texture distribution of the 97 studied soil samples

درصد شن، مقاومت فروروی در رطوبت اشباع و کربنات کلسیم معادل است. تأثیر مثبت و معنی‌دار درصد خاکدانه‌های پایدار در آب، رس خاک رطوبت اشباع خاک در مقابل تأثیر منفی و معنی‌دار هدایت هیدرولیکی اشباع، شن، کربنات کلسیم معادل بیانگر اهمیت ساختمان خاک در شاخص IE است. هرچه ساختمان (کیفیت فیزیکی خاک) بهتر باشد شاخص IE نیز عدد بزرگ‌تری است. این مشاهدات در پژوهش (Asgarzadeh et al. 2010) و (Zangiabadi et al. 2016) نیز گزارش شده است. اثر منفی و غیر معنی‌دار جرم مخصوص ظاهری خاک بیانگر این است که

ضریب همبستگی بین متغیرهای به‌کاررفته در جدول ۲ نشان می‌دهد که در غالب موارد همبستگی بالا و معنی‌داری بین ویژگی‌های خاک وجود دارد. درصد خاکدانه‌های پایدار در آب، درصد رس و رطوبت اشباع خاک بیشترین همبستگی مثبت معنی‌دار و در مقابل هدایت هیدرولیکی اشباع، درصد شن و کربنات کلسیم معادل بیشترین همبستگی منفی معنی‌دار را در انرژی انتگرالی آب خاک دارد. در مورد IE خاک نیز بیشترین همبستگی مثبت معنی‌دار مربوط به درصد خاکدانه‌های پایدار در آب، تخلخل، درصد سیلت، رطوبت اشباع خاک است. بیشترین همبستگی منفی معنی‌دار نیز مربوط به جرم مخصوص ظاهری،

کاهش جرم مخصوص ظاهری منجر به افزایش کیفیت فیزیکی خاک و کاهش اثر محدودیت جذب آب می گردد.

جدول ۲ - ضرایب همبستگی پیرسون بین متغیرهای ورودی و خروجی.

Table 2 - Pearson correlation coefficients between input and output variables.

	WSA	D _b	n	K _s	Sand	Clay	Silt	PR _s	CCE	θ _{vs}
WSA	1									
D _b	-0.320**	1								
n	0.320**	-1**	1							
K _s	-0.092	0.257*	-0.257*	1						
Sand	-0.199	0.670**	-0.670**	0.133	1					
Clay	0.279**	-0.380**	0.380**	-0.139	-0.767**	1				
Silt	0.062	-0.677**	0.677**	-0.081	-0.843**	0.301**	1			
PR _s	-0.235*	0.810**	-0.810**	0.184	0.757**	-0.471**	-0.730**	1		
CCE	-0.929**	0.271**	-0.271**	0.068	0.197	-0.321**	-0.024	0.197	1	
θ _{vs}	0.296**	-0.708**	0.708**	-0.198	-0.757**	0.543**	0.670**	-0.732**	-0.304**	1
IE	0.356**	-0.168	0.168	-0.322**	-0.251*	0.250*	0.164	-0.062	-0.201*	0.257*

* معنی دار در سطح احتمال ۱٪ و ** معنی دار در سطح احتمال ۵٪

WAS: درصد خاکدانه های پایدار در آب. D_b: جرم مخصوص ظاهری خاک. n: تخلخل خاک. K_s: هدایت هیدرولیکی اشباع خاک. Sand, Clay, Silt: درصد ذرات شن، رس و سیلت. PR_s: مقاومت فروروی در رطوبت اشباع. CCE: درصد کرنش کلسیم معادل. θ_{vs}: رطوبت حجمی اشباع. IE: انرژی انتگرالی آب خاک.

۲-۳- توسعه توابع انتقالی

۱-۲-۳- توسعه توابع انتقالی برای شاخص IE

در جدول ۳ آماره های ارزیابی روش های رگرسیون چندمتغیره خطی، شبکه عصبی مصنوعی و یادگیری عمیق برای IE در مرحله آموزش نشان می دهد که روش یادگیری عمیق با بالاترین ضریب تبیین، ضریب تعیین تعدیل شده و ضریب کارایی مدل در کنار کمترین جذر میانگین مربعات خطا، خطای نسبی و ضریب جرم مقدار باقیمانده دقیق ترین برآورد را در پیش بینی IE داشته است.

R²adj در دسته داده آموزش برای مدل رگرسیونی برابر ۰/۵۵۴، شبکه عصبی مصنوعی برابر ۰/۹۴۵ و برای مدل یادگیری عمیق برابر ۰/۹۹۸ است. ضریب تبیین تعدیل شده بالاتر نشان از کارایی بالای مدل یادگیری عمیق نسبت به سایر مدل ها است. جذر میانگین مربعات خطا و خطای نسبی (RMSE و RMSEr) در مدل یادگیری عمیق نسبت به مدل رگرسیونی و شبکه عصبی


مصنوعی کمترین میزان را دارد که نشان از خطای کمتر مدل یادگیری عمیق است. ضریب کارایی مدل (NSE) برای مدل یادگیری عمیق برابر ۰/۹۹۴، مدل شبکه عصبی مصنوعی برابر ۰/۹۹۲ و مدل رگرسیونی برابر ۰/۵۱۲ است. میانگین خطای نسبی (RME) برای مدل یادگیری عمیق برابر ۰/۰۲۹، مدل شبکه عصبی مصنوعی برابر ۰/۰۶۱ و مدل رگرسیونی برابر ۰/۲۲۰ است. نتیجه اینکه بالاترین دقت در برآورد مربوط به مدل یادگیری عمیق است.

شکل ۳ نمودارهای پراکنش برای مدل رگرسیونی، شبکه عصبی مصنوعی و یادگیری عمیق را در داده های آموزش مدل نشان می دهد. در هر سه نمودار خط قرمز رنگ خط برازش است و هرچه نقاط داده به این خط نزدیک تر باشند، دقت آن مدل افزایش خواهد یافت. مقایسه نمودار نشان می دهد که نمودار یادگیری عمیق بیشترین دقت را داشته است.

جدول ۳ - آماره ارزیابی روش های رگرسیون چندمتغیره خطی، شبکه عصبی مصنوعی و یادگیری عمیق برای IE در مرحله آموزش

Table 3 - Evaluation statistics of linear multiple regression, artificial neural network, and deep learning methods for IE in the training phase.

Parameter	R ² adj	RMSE	RMSEr	NSE	RME
Unit		JKg ⁻¹	JKg ⁻¹		JKg ⁻¹
REG	0.544	126.955	0.285	0.512	0.220
ANN	0.945	45.347	0.104	0.922	0.061
DNN	0.998	15.943	0.035	0.994	0.029
REG: مدل رگرسیون تعداد (متغیرهای ورودی ۱۰)، ANN: مدل شبکه عصبی مصنوعی، DNN: مدل یادگیری عمیق					



شکل ۳- نمودارهای مقادیر اندازه‌گیری و برآورد شده IE در هر سه مدل مورد مطالعه در داده‌های آموزش
Figure 3 - Graphs of the measured and estimated IE values in all three models studied in the training data

نسبی دقیق‌ترین برآورد را در پیش‌بینی IE داشته است. عملکرد فوق‌العاده DNN در آموزش (جدول ۳) در برابر عملکرد متوسط آن در آزمون (جدول ۴) به‌طور قاطع نشان می‌دهد که مدل یادگیری عمیق دچار بیش‌برازش شده است و در تعمیم نتایج به داده‌های جدید نیاز به بهینه‌سازی بیشتر دارد. برای بهبود این مدل، باید از مجموعه داده زود یافت دیگری نیز استفاده گردد تا نمایانگر واقعی‌تر محیط عملیاتی مدل باشد.

شکل ۴ نمودارهای پراکنش برای مدل رگرسیون، شبکه عصبی مصنوعی و یادگیری عمیق را در داده‌های آزمون مدل نشان می‌دهد. مقایسه نمودار نشان می‌دهد که نمودار یادگیری عمیق بیشترین دقت را داشته است.


در جدول ۴ آماره‌های ارزیابی روش‌های رگرسیون چندمتغیره خطی، شبکه عصبی مصنوعی و یادگیری عمیق برای IE در مرحله آزمون نشان داده شده است.

در مقایسه آماره‌های ارزیابی مدل یادگیری عمیق ($R^2_{adj}=0/661$ ، $RMSE=118/593$ ، $RMSEr=0/261$)، مدل شبکه عصبی مصنوعی ($R^2_{adj}=0/514$ ، $RMSE=139/267$ ، $RMSEr=0/298$) و مدل رگرسیون ($R^2_{adj}=0/317$ ، $RMSE=264/239$ ، $RMSEr=0/464$)، بیشترین ضریب تبیین تعدیل‌شده و ضریب کارایی مدل در کنار کمترین جذر میانگین مربعات خطا، جذر میانگین مربعات خطای نسبی و میانگین خطای

جدول ۴ - آماره ارزیابی روش های رگرسیون چندمتغیره خطی، شبکه عصبی مصنوعی و یادگیری عمیق IE در مرحله آزمون
Table 4 - Evaluation statistics of the multiple linear regression, artificial neural network, and deep learning IE methods in the testing phase

Parameter	R ² adj	RMSE	RMSEr	NSE	RME
Unit		JKg ⁻¹	JKg ⁻¹		JKg ⁻¹
REG	0.317	264.239	0.464	-0.281	0.514
ANN	0.514	139.267	0.298	0.644	0.249
DNN	0.661	118.593	0.261	0.742	0.210

مدل رگرسیون تعداد (متغیرهای ورودی ۱۰)، ANN: مدل شبکه عصبی مصنوعی، مدل DNN: یادگیری عمیق



شکل ۴- نمودارهای مقادیر اندازه گیری و برآورد شده IE در هر سه مدل مورد مطالعه در داده های آزمونی
Figure 4 - Graphs of the measured and estimated IE values in all three models studied in the test data.

۴- نتیجه‌گیری

این تحقیق مؤثر بودن استفاده از روش یادگیری عمیق را نسبت به روش‌های رگرسیون چندمتغیره خطی و شبکه عصبی مصنوعی نشان داد. روش یادگیری عمیق با کمترین هزینه و زمان، برآورد بهتری از خصوصیات موردنظر ارائه نمود. نتایج حاصل از بررسی عملکرد یادگیری عمیق، شبکه عصبی مصنوعی و رگرسیون چندمتغیره خطی در کنار یکدیگر نشان داد یادگیری عمیق از اعتبار و اطمینان بالاتری در برآورد IE در مقایسه با شبکه عصبی و رگرسیون چندمتغیره خطی برخوردار است. مزیت اصلی این روش کشف روابط غیرخطی و پیچیده بین پارامترهای ورودی و پارامتر خروجی است که روش‌های آماری مرسوم در مدل‌سازی آن‌ها با مشکل مواجه می‌شوند. محدودیت اصلی این روش که عملکرد آن را تحت تأثیر قرار می‌دهد استفاده از داده‌های ورودی است که هر چه قدر بتواند صحت برآورد را افزایش دهد بهتر است لذا به پژوهشگران توصیه می‌شود که از سایر پارامترها نظیر ماده آلی و... به عنوان ورودی مدل استفاده کنند.

سیاسگذاری

بدین وسیله از اساتید محترم خود در دانشگاه تبریز تشکر و قدردانی می‌شود.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

مشارکت نویسندگان

مجتبی علی محمدی: مفهوم‌سازی، روش کار، تجزیه و تحلیل و بررسی، تهیه نقشه‌ها، منابع، نگارش پیش‌نویس اصلی؛ داود زارع حقی: مفهوم‌سازی، راهنمایی، تجزیه و تحلیل و بررسی، ویرایش و بازبینی مقاله؛ محمدرضا نیشابوری: مفهوم‌سازی، روش کار،

range and integral water capacity. Plant Soil, 335, 229–244. doi:10.1007/s11104-010-0410-6.

Asgarzadeh, H., Mosaddeghi, M.R., Mahboubi, A.A., Nosrati, A., & Dexter, A.R. (2011). Integral energy of conventional available water, least limiting water range and integral water capacity for better characterization of water availability and soil physical quality. Geoderma, 166, 34–42. doi: 10.1016/j.geoderma.2011.06.009.

Bayat, H., Neyshabouri, M.R., Mohammadi, K., & Nariman-Zadeh, N. (2011). Estimating water

تجزیه و تحلیل و بررسی، منابع، ویرایش و بازبینی مقاله؛ محمدعلی قربانی: مفهوم‌سازی، روش کار، تجزیه و تحلیل و بررسی، ویرایش و بازبینی مقاله.

منابع

احمدی، عباس، علی محمدی، مجتبی و اصغری، شکر اله (۱۳۹۸). ارائه توابع انتقالی برای برآورد رطوبت FC و PWP با بکارگیری ابعاد فرکتالی. پژوهش‌های فرسایش محیطی. ۹ (۲): ۵۲–۳۷. doi: 20.1001.1.22517812.1398.9.2.1.7

اطمینان، سمانه، جلالی، وحید رضا، محمودآبادی، مجید، خاشعی سیوکی، عباس و پور رضا بیلندی، محسن. (۱۴۰۱). ارزیابی عدم قطعیت پارامترهای هیدرولیکی مدل HYDRUS با استفاده از روش DREAM. مدل‌سازی و مدیریت آب‌و خاک، ۳ (۴)، ۱–۱۵. doi: 10.22098/mmws.2022.11659.1152

خاشعی سیوکی، عباس، اطمینان، سمانه، شهیدی، علی، پور رضا بیلندی، محسن و جلالی، وحید رضا. (۱۴۰۳). عملکرد الگوریتم تفاضلی در برآورد پارامترهای هیدرولیکی خاک. مدل‌سازی و مدیریت آب‌و خاک، ۴ (۱)، ۳۶–۵۱. doi: 10.22098/mmws.2023.12101.1202

خان احمدی، هما، تقفیان، بهرام. دانشکارآراسته، پیمان (۱۴۰۰). پیش‌بینی تغییرات مساحت دریاچه بختگان و طشک با استفاده از تصاویر ماهواره‌ای و عوامل اقلیمی. تحقیقات منابع آب ایران، ۱۷ (۱): ۱۶۵–۱۵۱. doi: 20.1001.1.17352347.1400.17.1.9.0

رضایی، عبدالمجید، سلطانی افشین (۱۳۷۷). مقدمه‌ای بر تحلیل رگرسیون کاربردی. انتشارات دانشگاه صنعتی اصفهان، ۳۰۱ صفحه. <https://www.gisoom.com/book/1137080>

زنگی‌آبادی، مهدی، گرجی اناری، منوچهر، شرفا، مهدی، خاوری خراسانی، سعید، سعادت، سعید (۱۳۹۵). رابطه شاخص گنجایش انتگرالی آب با برخی ویژگی‌های فیزیکی خاک در استان خراسان - رضوی. آب‌و خاک، ۳۰ (۴): ۱۱۹–۱۰۷. doi:10.22067/jsw.v30i4.47544

کرمی‌زاده، ساسان، عرب‌سرخی، ابوذر (۱۴۰۰). اصول و مبانی یادگیری عمیق، تهران. نشر آوای قلم، ۳۵۴ صفحه. <https://www.gisoom.com/book/11707428>

محمدیان بهبهانی، علی، حیدری، کهزاد و حسینعلی زاده، محسن. (۱۴۰۴). مدل‌سازی آب‌گریزی خاک‌های لسی شمال ایران با الگوریتم‌های یادگیری ماشین. مدل‌سازی و مدیریت آب‌و خاک. doi: 10.22098/mmws.2025.17919.1633

References

- Ahmadi, A., Alimohammadi, M., & Asghari, S. (2019). Pedotransfer functions for estimating soil moisture content using fractal parameters in Ardabil province. *E.E.R.*, 9(2), 37–52. [In Persian]. doi: 20.1001.1.22517812.1398.9.2.1.7
- Asgarzadeh, H., Mosaddeghi, M.R., Mahboubi, A.A., Nosrati, A., & Dexter, A.R. (2010). Soil water availability for plants as quantified by conventional available water, least limiting water

- retention with pedotransfer functions using multi-objective group method of data handling and ANNs. *Pedosphere*, 21, 107-114. doi:10.1016/S1002-0160(10)60085-9.
- Blake, G. R., & Hartge, K. H. (1986a). Bulk Density. In A. Klute (Ed.), *Methods of Soil Analysis, Part 1- Physical and Mineralogical Methods* (pp. 363-375). ASA-SSSA. <https://www.scrip.org/reference/referencespapers?referenceid=498675>
- Blake, G. R., & Hartge, K. H. (1986b). Particle Density. In A. Klute (Ed.), *Methods of Soil Analysis, Part 1- Physical and Mineralogical Methods* (pp. 377-382). ASA-SSSA. <https://www.scrip.org/reference/referencespapers?referenceid=498675>
- Dadheech, P. (n.d.). Predicting Agriculture Yields Based on Machine Learning Using Regression and Deep Learning. *IEEE Access. Institute of Electrical and Electronics Engineers (IEEE)*. doi:10.1109/ACCESS.2023.3321861.
- DaSilva, A. P., Kay, B. D., & Perfect, E. (1994). Characterization of the least limiting water range of soils. *J. Soil Sci. Soc. Am.*, 58, 1775-1781. doi:10.2136/sssaj1994.03615995005800060028x
- DaSilva, A.P., & Kay, B.D. (1997). Estimating the least limiting water range of soils from properties and management. *Soil Sci. Soc. Am. J.*, 61(3), 877-883. doi:10.2136/sssaj1997.03615995006100030023x
- Etemad, S., Jalali, V., Mahmoudabadi, M., Khashaei Sioqi, A., & Pourreza Belandi, M. (2022). Uncertainty evaluation of the HYDRUS model hydraulic parameters using the DREAM method. *Modeling and Management of Soil and Water*, 3(4), 1-15. [In Persian]. <https://doi.org/10.22098/mmws.2022.11659.1152>.
- Gee, G. W., & Or, D. (2002). Particle-size analysis. In J. H. Dane & G. C. Topp (Eds.), *Methods of Soil Analysis, Part 4 (SSSA Book Series No. 5)*. Soil Sci. Soc. Am. doi: 10.2136/sssabookser5.4.c12.
- Gujarati, D. N. (2003). *Basic Econometrics*. McGraw-Hill/Irwin. <https://www.amazon.com/Basic-Econometrics-Damodar-Gujarati/dp/0072478527>
- Herrick, J.E., & Jones, T.L. (2002). A dynamic cone penetrometer for measuring soil penetration resistance. *Soil Sci. Soc. Am. J.*, 66, 1320-1324. doi:10.2136/sssaj2002.1320.
- Hoc, H.T., Silhavy, R., Prokopova, Z., & Silhavy, P. (2022). Comparing Multiple Linear Regression, Deep Learning and Multiple Perceptron for Functional Points Estimation. *IEEE Access*, 10, 112187-112198. doi:10.1109/ACCESS.2022.3215987.
- Karamizadeh, S., & Arabserkhi, A. (2021). *Principles and foundations of deep learning*. Avaye Galam Publication. (Tehran). [In Persian]. <https://www.gisoom.com/book/11707428>
- Kazemi, Z., Neyshabouri, M.R., Bayat, H., Asgari Lajayer, B., & van Hullebusch, E.D. (2022). Models performance in predicting least limiting water range in northwest of Iran under semiarid and semi-humid climates. *International Journal of Environmental Science and Technology*, 19(9), 8231-8242. doi: 10.1007/s13762-022-03980-9.
- Kemper, W. D., & Rosenau, R. C. (1986). Aggregate stability and size distribution. In A. Klute (Ed.), *Methods of Soil Analysis Part 1, Physical and Mineralogical Methods* (2nd ed., Agron. Monog. N9). American Society of Agronomy, Inc. <https://www.scrip.org/reference/referencespapers?referenceid=2164403>
- KhanAhmadi, H., Saghafian, B., Daneshkar Arasteh, P. (2021). Forecasting changes in the area of Lake Bavanat and Tashk using satellite images and climatic factors. *Iranian Water Resources Research*, 17(1), 151-165. [In Persian]. DOR: 20.1001.1.17352347.1400.17.1.9.0
- Khashaei Sioqi, A., Etemad, S., Shahidi, A., Pourreza Belandi, M., & Jalali, V. (2024). Performance of the differential evolution algorithm in estimating soil hydraulic parameters. *Modeling and Management of Soil and Water*, 4(1), 36-51. [In Persian]. <https://doi.org/10.22098/mmws.2023.12101.1202>.
- Klute, A. (Ed.). (1986). *Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods* (2nd ed.). Agron. Monog. 9. ASA and SSSA. <https://www.wiley.com/en-ae/Methods+of+Soil+Analysis%2C+Part+1%3A+Physical+and+Mineralogical+Methods%2C+2nd+Edition-p-9780891188643>
- Minasny, B., & McBratney, A.B. (2003). Integral energy as a measure of soil-water availability. *Plant Soil*, 249, 253-262. doi:10.1023/A:1022825732324.
- Mohammadian Behbahan, A., Heidari, K., & Hosseinalizadeh, M. (2025). Modeling the hydrophobicity of loess soils in Northern Iran using machine learning algorithms. *Modeling and Management of Soil and Water*. [In Persian]. <https://doi.org/10.22098/mmws.2025.17919.1633>.
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*, 10(3), 282-290. doi: 0022169470902556
- Nelson, R.E. (1982). Carbonate and Gypsum. In A.L. Page, R.H. Miller, & D.R. Keeney (Eds.), *Methods of Soil Analysis part 2* (2nd ed., pp. 181-197). American Society of Agronomy. <https://access.onlinelibrary.wiley.com/doi/book/10.2134/agronmonogr9.2.2ed>
- Niu, W.-J., Feng, Z.-K., Feng, B.-F., Min, Y.-W., Cheng, C.-T., & Zhou, J.-Z. (2019). Comparison

- of Multiple Linear Regression, Artificial Neural Network, Extreme Learning Machine, and Support Vector Machine in Deriving Operation Rule of Hydropower Reservoir. *Water*, 11(1), 88. doi:10.3390/w11010088.
- Rezaei, A., & Soltani, A. (1998). Introduction to applied regression analysis. Isfahan University of Technology Press. [In Persian] .
<https://www.gisoom.com/book/1137080/>
- Seifi, M., Ahmadi, A., Neyshabouri, M.-R., Taghizadeh-Mehrjardi, R., & Bahrami, H.-A. (2020). Remote and Vis-NIR spectra sensing potential for soil salinization estimation in the eastern coast of Urmia hyper saline lake, Iran. *Geoderma*, 380, 114646. <https://doi.org/10.1016/j.geoderma.2020.114646>.
- Vawda, M.I., Lottering, R., Mutanga, O., Peerbhay, K., & Sibanda, M. (2024). Comparing the Utility of Artificial Neural Networks (ANN) and Convolutional Neural Networks (CNN) on Sentinel-2 MSI to Estimate Dry Season Aboveground Grass Biomass. *Sustainability*, 16(3), 1051. doi:10.3390/su16031051.
- Viehmeyer, F.J., & Hendrickson, A.H. (1927). Soil-Moisture conditions in relation to plant growth. *Plant Physiol.*, 2(1), 71-82. doi:10.1104/pp.2.1.71.
- Yong, H., Rastgou, M., & Qianjing, J. (2023). Implementation and efficient evaluation of backpropagation network training algorithms in parametric simulations of soil hydraulic conductivity curve. *Journal of Hydrology*, 636, 131-145. doi: 10.1016/j.jhydrol.2024.131302
- Zangiabadi, M., Gorji Anari, M., Sharfa, M., Khavari Khorasani, S., & Saadat, S. (2016). The relationship between the Integral Water Capacity index and some physical properties of soil in Khorasan-Razavi province. *Soil and Water*, 30(4), 1192–1201. [In Persian] doi:10.22067/jsw.v30i4.47544.