

## Evaluation of Artificial Neural Network and regression models in prediction of soil organic carbon (Case study: The Pakal Catchment, Markazi province)

Amir Moradinejad<sup>1\*</sup>, Saied Khosrobeig<sup>2</sup>

1- Assistant Professor, Soil Conservation and Watershed Management Research Department, Markazi Agricultural and Natural Resources Research and Education Center, Arak, Agricultural Research Education and Extension Organization (AREEO), Iran

2- PhD in Watershed Management and Head of Technical and Engineering Department of the General Department of Natural Resources of Markazi Province, Iran

\* Corresponding author: amir\_24619@yahoo.com

(Received: 15 November 2022

Revised: 10 December 2022

Accepted: 18 December 2022)

### Extended Abstract

**Introduction:** Organic carbon is one of the most important components of soil ecosystems, and changes in its amount and composition have fundamental effects on the processes that occur in each system. Soil is a source for carbon storage and deposition in connection with the atmosphere. Since pastures have a great capacity for carbon sequestration and are broad in arid and semi-arid areas of Iran, the study of organic carbon content and spatial changes in these ecosystems are important. In developing countries such as Iran, which are facing a soil erosion crisis, this issue can lead to the creation of a solution that aims at soil conservation, optimal utilization of land, as well as reforming and reviving destroyed pastures. Considering the role of organic carbon in soil management and stability, preventing soil erosion, monitoring the amount of carbon dioxide in the air, and predicting soil organic carbon on a regional, national and global scale are of particular importance.

**Materials and methods:** The study area of this project is the Pakel catchment from the sub-basins of the Qara Chai River. This catchment is located in the southwest of Shazand city, at a distance of 43 kilometers from the city of Arak. Random-systematic sampling was done in 60 points from the soil depth of 0-30 cm. Soil properties such as apparent specific gravity by cylinder method, pH and EC were measured after the preparation of saturated soil. Organic matter were measured using cold method based on oxidation of organic carbon. Then, soil properties were used to model soil organic carbon. For this purpose, statistical regression and artificial neural network (ANN) were used.

**Discussion and results:** The amount of organic carbon in the soil is affected by the physical and chemical properties of the soil. It is therefore necessary to use calculation methods with optimal accuracy in estimating this complex and important parameter. It is possible to compare different models using RMSE,  $R^2$  and CE indices. Paying attention to the index values shows the relative advantage of the models. The general results of the research show that in natural areas where the problem of sampling and the costs of their analysis are at a high level, it is possible to use artificial intelligence methods with the help of data to estimate soil organic carbon. It is expected that in future studies, in order to create a more reliable model that predicts more variability of the amount of soil organic carbon, denser sampling and integration of physiographic and soil variables affecting organic carbon will lead to satisfactory results. Due to the complexity of soil organic carbon relationships and soil physical and chemical properties, it is better to ignore complex analyses that include various coefficients for adjusting the mathematical formulas of models and use artificial intelligence methods which have high flexibility.

**Conclusion:** The results showed that the ANN with RMSE=0.043 and CE=0.87 compared to the regression model with RMSE=0.08 and CE=0.51 is better in estimating organic carbon. The comparison between the regression and neural network models showed that the values estimated by the neural network are more accurate than the regression method. It is suggested to carry out periodic carbon deposition monitoring studies in the study area in order to check the temporal changes of carbon deposition in the intended land uses.

**Keywords:** soil properties, modeling, efficiency coefficient, soil carbon.

**Citation:** Moradinejad, A., & Khosrobeig, S. (2022). Evaluation of Artificial Neural Network and regression models in prediction of soil organic carbon (Case study: The Pakal Catchment, Markazi province). *Integrated Watershed Management*, 2(3), 95-110. doi: 10.22034/iwm.2022.1972720.1050

#### Copyrights:

Copyright for this article is retained by the author(s), with publication rights granted to Integrated Watershed Management. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



## ارزیابی مدل‌های شبکه عصبی مصنوعی و رگرسیونی در برآورد کربن آلی خاک (منطقه

### مورد مطالعه: حوزه آبخیز پاکل، استان مرکزی)

امیر مرادی نژاد<sup>۱\*</sup>، سعید خسروبیگی<sup>۲</sup>

۱- استادیار مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان مرکزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، ایران

۲- دکتری آبخیزداری و رئیس بخش فنی و مهندسی اداره کل منابع طبیعی استان مرکزی، ایران

\*نویسنده مسئول: amir\_24619@yahoo.com

تاریخ پذیرش: ۱۴۰۱/۰۹/۲۷

تاریخ بازنگری: ۱۴۰۱/۰۹/۱۹

تاریخ دریافت: ۱۴۰۱/۰۸/۲۴

#### چکیده

با توجه به نقش کربن آلی در مدیریت و پایداری خاک، جلوگیری از فرسایش خاک و پایش میزان دی‌اکسید کربن هوا، پیش‌بینی کربن آلی خاک در مقیاس منطقه‌ای، ملی و جهانی از اهمیت خاصی برخوردار است. در این تحقیق به منظور برآورد کربن آلی خاک از مدل‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره استفاده شد. برای این منظور در ابتدا، ۶۰ نمونه خاک از حوزه آبخیز پاکل اراک از عمق ۰ تا ۳۰ سانتی‌متری برداشت شد. سپس خصوصیات خاک شامل نیتروژن، رس، سیلت، کربن آلی، اسیدیته، هدایت الکتریکی و وزن مخصوص ظاهری خاک اندازه‌گیری گردید. به منظور ارزیابی کارکرد مدل‌های مورد استفاده از مجذور میانگین مربعات خطا و ضریب کارایی استفاده گردید. نتایج نشان داد که شبکه عصبی مصنوعی با مجذور میانگین مربعات  $RMSE=0/043$  و ضریب کارایی  $CE=0/87$  نسبت به مدل رگرسیونی با مجذور میانگین مربعات  $RMSE=0/08$  و ضریب کارایی  $CE=0/51$  کارایی بهتری در برآورد کربن آلی داشت. مقایسه بین مدل‌های رگرسیونی و شبکه عصبی نشان داد که مقادیر برآورد شده به وسیله شبکه عصبی دارای دقت بیشتری نسبت به روش رگرسیونی است. روش‌های آماری و نتایج شبکه‌های عصبی برتری مدل‌های شبکه عصبی را در برآورد کربن آلی بیان می‌کند. نتایج کلی پژوهش نشان می‌دهد که در عرصه‌های طبیعی که مشکلات خاص نمونه‌برداری، هزینه‌های تجزیه و آنالیز نمونه‌ها در سطح زیاد وجود دارد، می‌توان از روش‌های هوش مصنوعی و به کمک داده‌های زود یافت برای تخمین کربن آلی خاک سود جست. انجام مطالعات دوره‌ای پایش ترسیب کربن در منطقه مورد مطالعه به منظور بررسی تغییرات زمانی ترسیب کربن در کاربری‌های مورد نظر پیشنهاد می‌شود.

واژه‌های کلیدی: خصوصیات خاک، مدل‌سازی، ضریب کارایی، کربن خاک.

استناد: مرادی نژاد، ا. و خسروبیگی، س. (۱۴۰۱). ارزیابی مدل‌های شبکه عصبی مصنوعی و رگرسیونی در برآورد کربن آلی خاک (منطقه مورد مطالعه: حوزه آبخیز پاکل، استان مرکزی). مدیریت جامع حوزه‌های آبخیز، (۳)، ۹۵-۱۱۰.

#### حق چاپ:



حق چاپ برای نویسنده (گان) این مقاله محفوظ است. بر اساس قوانین انتشارات با دسترسی آزاد، تمام مطالعات چاپ شده در این نشریه به صورت آزاد در وبسایت نشریه برای عموم بدون پرداخت هزینه قابل دسترس است.

## مقدمه

کربن آلی از مهم‌ترین مؤلفه‌های اکوسیستم‌های خاکی است و تغییر در فراوانی و ترکیب آن اثرات اساسی روی فرآیندهایی خاک دارد (Crowther Thomas *et al.*, 2013). مدیریت دقیق خاک برای اهداف مختلف، مستلزم شناخت دقیق و کمی خصوصیات و فرآیندهای آن است. مقدار کربن آلی خاک از خصوصیات مهم در تعیین کیفیت خاک است و به‌عنوان یکی از شاخص‌های اولیه کیفیت خاک، در کشاورزی، محیط‌زیست و مرتع در نظر گرفته می‌شود (Broge *et al.*, 2005). با توجه به اینکه مراتع قابلیت زیادی برای ترسیب کربن داشته و در نواحی خشک و نیمه‌خشک ایران از وسعت بالایی برخوردار هستند، مطالعه محتوای کربن آلی و تغییرات مکانی آن در اکوسیستم‌های مزبور حائز اهمیت است. این موضوع می‌تواند در کشورهای در حال توسعه‌ای همچون ایران که با بحران فرسایش خاک مواجه هستند، کمک به ایجاد راه‌کاری شود که حفاظت اراضی، بهره‌وری بهینه از اراضی و همچنین اصلاح و احیای مراتع تخریب یافته را به دنبال داشته باشد. خاک منبعی برای ذخیره و ترسیب کربن در ارتباط با اتمسفر است. ظرفیت بالای خاک برای ترسیب و یا رهاسازی کربن باعث می‌شود تا این سیستم نقش مهمی در کنترل میزان دی‌اکسید کربن اتمسفر داشته باشد (Follett *et al.*, 2001). یکی از دقیق‌ترین و مرسوم‌ترین روش‌های ارزیابی کربن آلی خاک، پایش زمینی و نمونه‌برداری مستقیم خاک و آنالیزهای آزمایشگاهی است (Bird *et al.*, 2013). اندک تغییری در کربن آلی خاک می‌تواند مقدار دی‌اکسید کربن اتمسفر را به شدت تحت تأثیر قرار داده و به تبع آن روی اقلیم تأثیرگذار باشد (Chen *et al.*, 2019). بررسی توزیع مکانی مقدار کربن آلی خاک، اساسی‌ترین قدم در سیاست‌گذاری اقلیم و مدیریت خاک، افزایش تولید غذای بشر (Taghizadeh-*et al.*, 2017) و تهیه داده‌های استاندارد

برای مدل‌سازی اکوسیستم است (Mahmoudzadeh *et al.*, 2020). پیلوری و همکاران (Pilevari *et al.*, 2010) در تحقیقی تحت عنوان مقایسه مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در پیش‌بینی کربن آلی خاک به کمک داده‌های آنالیز سطح زمین به این نتیجه دست یافتند که مدل شبکه-عصبی مصنوعی نسبت به آنالیز رگرسیون خطی چندمتغیره به‌عنوان ابزار قدرتمندتری در پیش‌بینی کربن آلی عمل می‌کند. پارسافر و معروفی (Parsafar *and Marofi*, 2011) نیز در مطالعه برآورد دمای عمق-های مختلف خاک از دمای هوا با به‌کارگیری روابط رگرسیونی، شبکه عصبی و شبکه عصبی-فازی، مدل شبکه عصبی-فازی را به‌عنوان مدلی با دقت بالا نسبت به سایر شبکه عصبی و رگرسیونی معرفی کردند. هلنبرگ و همکاران (Holmberg *et al.*, 2006) از مدل شبکه عصبی مصنوعی برای پیش‌بینی میزان کربن آلی، نیتروژن و فسفر استفاده کردند. پارساورمان و همکاران (Parasurman *et al.*, 2006) برای برآورد هدایت آبی اشباع در مقیاس مزرعه‌ای، دو مدل شبکه عصبی مصنوعی طراحی نمودند. پارامترهای ورودی در مدل اول درصد رس، سیلت و شن بود و در مدل دوم علاوه بر سه ویژگی یادشده، جرم ویژه ظاهری اضافه شد. نتایج این پژوهش نشان داد که شبکه‌های عصبی مصنوعی طراحی شده عملکرد بهتری در برآورد هدایت آبی اشباع داشته‌اند. مردون و همکاران (Merdun *et al.*, 2006) از مدل‌های رگرسیونی و شبکه عصبی مصنوعی برای تعیین هدایت هیدرولیکی اشباع استفاده کردند، نتایج این پژوهش نشان داد که مدل‌های شبکه عصبی مصنوعی، برآورد بهتری از هدایت هیدرولیکی اشباع نسبت به رگرسیونی داشته‌اند. طیف وسیعی از الگوریتم‌های ماشین یادگیری برای پیش‌بینی کربن آلی خاک در مقیاس منطقه‌ای و ملی استفاده شده است. به‌عنوان مثال، وانگ و همکاران (Wang *et al.*, 2018) در لیائونینگ چین توزیع مکانی کربن آلی خاک

توزیع مکانی ویژگی‌های خاک را با استفاده از متغیرهای محیطی و تجزیه و تحلیل‌های آماری چندمتغیره در منطقه نیمه‌خشک بروجن مورد بررسی قرار دادند. به‌طور کلی نتایج ایشان بیانگر این بود که عوامل محیطی مانند مورفولوژی تپه‌ها و کلیه متغیرهای سنجش از دور تا حد زیادی می‌توانند تغییرپذیری کربن آلی خاک را در منطقه مورد مطالعه توضیح دهند. خاموشی و همکاران (Khamoshi *et al.*, 2019) با استفاده از مدل جنگل تصادفی، نقشه رقومی پراکنش کربن آلی را در خاک‌های زراعی دشت قزوین تهیه کردند. نتایج اعتبارسنجی در سه عمق خاک نشان داد که دقت پیش‌بینی مدل‌سازی برای کربن با استفاده از جنگل تصادفی نتایج بهتری می‌دهد. ایشان همچنین بیان کردند در صورتی که مدل جنگل تصادفی با متغیرهای محیطی مناسب آموزش داده شود می‌توان آن را به‌عنوان یک الگوریتم یادگیرنده مؤثر در نقشه برداری رقومی کربن آلی خاک به کار برد. پهلوان‌راد و همکاران (Pahlavan-Rad *et al.*, 2018) طی پژوهشی غلظت کربن آلی خاک را در منطقه زهک در شرق ایران مورد مطالعه قرار دادند. در این مطالعه، توزیع کربن آلی خاک با استفاده از نقشه برداری رقومی خاک در منطقه - ای با مساحت ۴۱۰۰۰ هکتار و تعداد ۴۱۷ نمونه خاک از عمق ۳۰ سانتی‌متری مورد بررسی قرار گرفت و از رویکرد جنگل تصادفی نیز برای مدل‌سازی استفاده شد. مقدار دو آماره ارزیابی صحت مدل MAE و RMSE به ترتیب برابر ۰/۱۶ و ۰/۲۱ به دقت آمد. نتایج این تحقیق نشان داد که نقشه پیش‌بینی شده با واقعیت‌های منطقه مورد مطالعه سازگاری دارد. ژانگ و همکاران (Zhang *et al.*, 2017) در خصوص پیش‌بینی کربن آلی خاک به دو روش جنگل تصادفی و رگرسیون خطی نیز برتری روش جنگل تصادفی را نسبت به روش رگرسیون خطی نشان دادند و بیان داشتند که برتری مدل جنگل تصادفی نسبت به مدل‌های خطی در پیش‌بینی کربن آلی خاک مربوط به روابط غیرخطی است که بین کربن آلی خاک و متغیرهای پیش‌بینی

را در پنج عمق با استفاده از مدل رگرسیون درختی بررسی کرده‌اند. اسکندری و همکاران (Eskandari *et al.*, 2018) در بررسی توزیع مکانی کربن آلی خاک در شهرستان مریوان به این نتیجه رسیدند که پارامترهای توپوگرافی از طریق عوامل فرسایش و رسوب، حفظ پوشش گیاهی، عمق توسعه ریشه، زهکشی خاک همگی بر روی مقدار تجزیه کربن آلی خاک و نیز پوشش گیاهی اثر دارند و توزیع مکانی و تشکیل خاک را تحت تأثیر قرار می‌دهد. محمودزاده و همکاران (Mahmoudzadeh *et al.*, 2020) در تحقیقی به رقومی‌سازی کربن آلی خاک با شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در استان کردستان پرداختند. نتایج پژوهش آن‌ها نشان داد که پراکنش کربن آلی بیش‌تر تحت تأثیر عوامل توپوگرافی و اقلیم است. همچنین در مناطقی که به هر دلیل امکان نمونه برداری در کل منطقه وجود ندارد، می‌توان از طریق متغیرهای کمکی مانند پارامترهای توپوگرافی، اقلیمی و پوشش گیاهی و با روش‌های نوین داده‌کاوی برای برآورد کربن آلی خاک بهره گرفت. متین‌فر و همکاران (Matinfar *et al.*, 2018) در تحقیقی به ارزیابی روش‌های یادگیری ماشین در نقشه برداری رقومی کربن آلی خاک‌های زراعی بخشی از دشت خرم‌آباد پرداختند. نتایج آن‌ها نشان داد که در مجموع مدل‌های با رویکرد غیرخطی صحت بالاتری نسبت به مدل‌های خطی در مدل‌سازی تغییرات مکانی کربن آلی خاک دارند. در روش‌های مرسوم نقشه برداری خاک بدون در نظر گرفتن تغییرات مکانی کربن آلی خاک، میانگین کربن آلی خاک در هر واحد نقشه خاک گزارش می‌شود که این نحوه مطالعه تغییرات مکانی به دلیل عدم ارائه تغییرات پیوستگی مکانی این ویژگی نیازمند بهره‌گیری از روش‌های نوینی است که قادر باشند تغییرات مکانی خصوصیات خاک را در نظر گرفته و موجب صرفه‌جویی در زمان و هزینه مطالعات تهیه نقشه ویژگی‌های خاک شوند (Somarathna *et al.*, 2017). زراعت‌پیشه و همکاران (Zeraatpisheh *et al.*, 2019) در مطالعه‌ای

است. در ایران بیشتر مطالعات صورت گرفته در زمینه برآورد ماده آلی خاک از مدل‌های تجربی و نیمه‌تجربی استفاده شده است. حال آنکه به دلیل محدود بودن اطلاعات پیرامون مواد آلی و دشواری و هزینه‌های زیاد حاصل از آزمایش شیمیایی این فاکتور، پیش‌بینی کربن آلی خاک به‌عنوان عاملی مهم در کاربری‌های مختلف خاک ضروری به نظر می‌رسد. به دلیل پیچیدگی روابط کربن آلی و خصوصیات فیزیکی و شیمیایی خاک، بهتر است برای تحلیل از روش‌های هوش مصنوعی که از قدرت انعطاف‌پذیری بالایی برخوردار است استفاده شود. مدل‌های ریاضی به خاطر داشتن ضرایب گوناگون در تنظیم معادلات، برای تحلیل بسیار پیچیده می‌باشند. روش‌های هوش مصنوعی مانند شبکه عصبی مصنوعی است که مزیت اصلی آن‌ها سرعت بالا و دقت مطلوب در پیش‌بینی متغیرهای پیچیده با نگاشت خطی و غیرخطی است. اصولاً روش‌های هوش مصنوعی در حل مسائل پیچیده که مدل‌های تجربی یا نیمه‌تجربی در حل آن کارایی مناسب نداشته باشند، بسیار کارا هستند. در کشور ایران با وجود وسعت زیاد مراتع و توانایی عظیم در ترسیب کربن و با توجه به نقش کربن آلی خاک در پایداری و کیفیت خاک و جلوگیری از فرسایش، تا به حال تحقیقات کاربردی محدودی در زمینه تخمین کربن آلی خاک در حوزه‌های آبخیز انجام شده است. لذا این مطالعه به‌منظور مقایسه مدل شبکه عصبی مصنوعی پرسپترون چندلایه و رگرسیون چندمتغیره برای تخمین کربن آلی خاک با استفاده از داده‌های زودیافت خاک و همچنین تعیین مهم‌ترین فاکتورهای مؤثر بر مقدار کربن آلی ذره‌های خاک در حوزه آبخیز پاکل شازند در استان مرکزی انجام گرفته است.

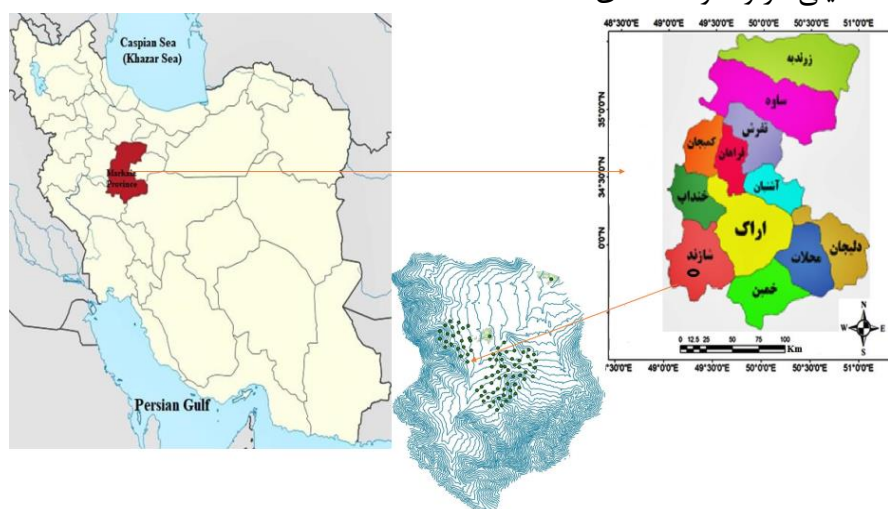
کننده وجود دارد. کرکج و همکاران (Karkaj *et al.*, 2017)، در مطالعه خود، ارتباط ذخیره کربن آلی با برخی ویژگی‌های خاک در مراتع آذربایجان شرقی را بررسی کردند. نتایج آن‌ها نشان داد که ذرات ریز سیلت و رس با ضریب تحلیل مسیر به ترتیب ۰/۱۷۵ و ۰/۲۲۳ ظرفیت و پتانسیل بالایی در ذخیره کربن آلی خاک دارند. خورده‌بین و همکاران (Khordehbin *et al.*, 2020) در پیش‌بینی ذخیره کربن آلی خاک در بخشی از اراضی شهرستان بهبهان از متغیرهای کمکی از جمله اجزای سرزمین، داده‌های حاصل از سنجش‌ازدور و نقشه کاربری اراضی استفاده کردند. نتایج آن‌ها نشان داد که مدل جنگل تصادفی با بالاترین ضریب تبیین ( $R^2=0/96$ ) و کمترین مجذور میانگین مربعات خطا ( $RMSE=2/32$ ) کارایی بهتری در پیش‌بینی ذخیره کربن آلی خاک را نشان داده است. راعی و همکاران (Raei *et al.*, 2020) در تحقیقی به ارزیابی کارایی برخی روش‌های هوش مصنوعی<sup>۱</sup> در مدل‌سازی فرسایش‌پذیری بادی خاک، در بخشی از اراضی شرق دریاچه ارومیه پرداختند. این پژوهش با هدف مقایسه کارایی چهار روش مختلف شامل رگرسیون خطی چندمتغیره، شبکه عصبی مصنوعی، شبکه عصبی مصنوعی هیبرید شده با الگوریتم ژنتیک و شبکه عصبی هیبرید شده با الگوریتم بهینه‌سازی وال در مدل‌سازی فرسایش‌پذیری بادی در بخشی از اراضی انجام شد. برای این منظور، ۹۶ نمونه خاک به روش تصادفی نظارت‌شده جمع‌آوری و ۳۲ ویژگی مختلف فیزیکی و شیمیایی آن‌ها در آزمایشگاه تعیین شدند. نتایج نشان داد که مدل شبکه عصبی هیبرید شده با الگوریتم بهینه‌سازی وال با توجه به کمترین مقادیر میانگین خطا ( $0/11$ ) و جذر میانگین مربعات خطا ( $2/9$ ) و بیشترین مقادیر ضریب تبیین ( $0/87$ ) و ضریب کارایی نش-سانتکلیف ( $0/87$ ) از کارایی مطلوب‌تری در پیش-بینی فرسایش‌پذیری بادی خاک‌های منطقه برخوردار

## مواد و روش‌ها

### موقعیت منطقه مورد مطالعه

حوزه آبخیز پاکل از زیر حوزه‌های آبخیز رودخانه قره چای است. این حوضه با مساحت ۳۴۳۷/۲۷ هکتار در حاشیه شهر آستانه و در محدوده ۳۳ درجه و ۴۹ دقیقه تا ۳۳ درجه و ۵۳ دقیقه عرض جغرافیایی و ۴۹ درجه و ۱۷ دقیقه تا ۴۹ درجه و ۲۲ دقیقه طول جغرافیایی واقع شده است (شکل ۱). این منطقه دارای ارتفاع متوسط حدود ۲۲۲۵ متر از سطح دریا، متوسط بارندگی سالانه ۴۵۶ میلی‌متر و متوسط دمای سالانه

آن ۱۱/۳ درجه سانتی‌گراد است. این حوزه آبخیز در جنوب غربی شهرستان شازند، با فاصله ۴۳ کیلومتری از شهر اراک و در مجاورت شهر آستانه قرار دارد. در این منطقه عملیات آبخیزداری شامل بذرکاری، بانکت-بندی، احداث بند خاکی، تورکینست، بندهای گابیونی و احداث بند خشکه‌چین انجام شده است، لذا با توجه به اینکه در طرح تحقیقاتی هدف بررسی تأثیر عملیات بیومکانیکی آبخیزداری بر ترسیب کربن بوده است، این منطقه انتخاب شد.



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه به همراه نقاط نمونه‌برداری شده

Figure 1- Geographical location of the study area along with the sampled points

## روش تحقیق

### روش نمونه‌برداری میدانی

پس از شناسایی مقدماتی و تعیین حدود منطقه دو سایت مطالعاتی به نام‌های سرسختی و پاکل انتخاب و در هر سایت دو کاربری مرتع، عملیات بیومکانیکی آبخیزداری (احداث بانکت و بادام‌کاری)، مشخص شد. روش نمونه‌برداری به صورت تصادفی-سیستماتیک بود. با توجه به توپوگرافی، شیب، نوع خاک و پوشش گیاهی، ترانسکت‌هایی به طول ۱۰۰ متر و به صورت تصادفی و با فواصل مناسب از هم مستقر شد. در امتداد هر ترانسکت حداقل سه پلات مستقر شد. اندازه پلات بر اساس ویژگی‌های پوشش گیاهی تعیین شد که در کاربری مرتع شاهد از پلات ۲\*۲ و در کاربری عملیات

بیومکانیکی آبخیزداری (احداث بانکت و بادام‌کاری) از پلات ۱۰\*۱۰ استفاده شد (Agharaz, 2018). علاوه بر این در کف و پشته بانکت‌ها، ترانسکت‌هایی مستقر و در امتداد هر ترانسکت از سه پلات استفاده شد تا میزان ترسیب کربن آن‌ها به طور مجزا ارزیابی شود. نمونه-برداری زیست‌توده و لاشبرگ در مجاورت پروفیل خاک، در پلات‌های ۱\*۱ متر، انجام شد. در هر پلات، تراکم بوته، ترکیب گونه‌های، درصد تاج پوشش و لاشبرگ تعیین شد. همچنین تعدادی بوته معرف از هر گونه در هر پلات انتخاب و با کل ریشه جمع‌آوری، در آن خشک شده و توزین شد. سپس زیست‌توده تاج پوشش و ریشه محاسبه شد. در گونه‌های درختی و درختچه‌ای حجم تاج پوشش با اندازه‌گیری قطرهای


تعیین درصد ماده خشک و کربن برداشت شد. هم- چنین در ۱۰ درصد پلات‌ها، با حفر پروفیل خاک تا عمق گسترش ریشه‌ها، اندازه‌گیری طول ریشه‌ها و برآورد زیست‌توده زیرزمینی انجام شد (شکل ۲). در مجموع ۶۰ نمونه خاک برداشت شد (Agharaz, 2018). نمونه‌ها در هوای آزاد خشک گردید و بعد از خرد نمودن کلوخه‌ها، جدا کردن ریشه‌ها، سنگ و سایر ناخالصی‌ها، آسیاب و از الک ۲ میلی‌متری (مش ۲۰) عبور داده شد (Hernandez et al., 2004). خصوصیات خاک نیز شامل وزن مخصوص ظاهری به روش استوانه (Blake and Hartge, 1986)، اسیدیته و هدایت الکتریکی آن‌ها پس از تهیه گل اشباع، با دستگاه pH متر و EC متر اندازه‌گیری شدند. بافت خاک به روش هیدرومتری (Gee and Bauder, 1986) و ماده آلی و کربن آلی با استفاده از روش سرد و بر مبنای اکسیداسیون کربن آلی به کمک بیکربنات پتاسیم در محیط کاملاً اسیدی ( $H_2SO_4$ ) اندازه‌گیری شد (Allison, 1975) (شکل ۳).

بزرگ و کوچک، ارتفاع و قطر تنه محاسبه و با نمونه- برداری از حجم مشخصی از گیاه، زیست‌توده و کربن در آن‌ها تعیین و به کل گونه و سطح مؤثر پروژه تعمیم داده شد. در داخل هر پلات ابتدا فهرست گونه‌های گیاهی موجود و فراوانی آن‌ها ثبت شد، سپس وزن اندام‌های هوایی گونه (های) غالب بر اساس روش اندازه- گیری مضاعف<sup>۱</sup>، وزن سایر گونه‌ها بر اساس روش قطع و توزین و وزن لاشبرگ بر اساس نمونه‌برداری مستقیم یادداشت شد. هم‌چنین صفات، درصد پوشش گونه‌های غالب و همراه، اندازه‌گیری سطح تاج پوشش (قطرهای بزرگ و کوچک)، تراکم تاج پوشش، ارتفاع گیاه، قطر تنه گیاه، برای همه پلات‌ها انجام شد. در هر پلات یک پروفیل خاک حفر و نمونه‌های خاک از عمق‌های ۰-۱۵-۰ و ۰-۳۰-۱۵، به وزن حدود یک کیلوگرم برداشت شد. علاوه بر این در یک‌چهارم پلات‌ها، با قطع و توزین اندام‌های هوایی، زیست‌توده هوایی گونه‌های غالب تعیین شد و نمونه‌های زیست‌توده و لاشبرگ برای



شکل ۲- مراحل نمونه‌برداری خاک از منطقه مورد مطالعه

Figure 2- The stages of soil sampling from the study area



شکل ۳- انجام آزمایش‌ها برای گرفتن فاکتورهای خاک

Figure 3- Conducting experiments to obtain soil factors

درصد داده‌ها برای آموزش و ۱۵ درصد داده‌ها برای آزمون انتخاب شد.

### نرمال‌سازی داده‌ها

پیش از آموزش شبکه عصبی، داده‌های ورودی به آن نرمال شدند. هدف از نرمال‌سازی این است که داده‌ها به اعدادی بین صفر تا یک تبدیل شوند (Menhaj, 1998). بدین منظور از رابطه (۱) برای نرمال‌سازی استفاده گردید (Raei et al., 2020).

$$Ni = \left( \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) \quad (1)$$

که در آن:  $N_i$  داده نرمال‌سازی شده،  $X_i$  داده اولیه،  $X_{\max}$  بزرگ‌ترین داده و  $X_{\min}$  کوچک‌ترین داده است.

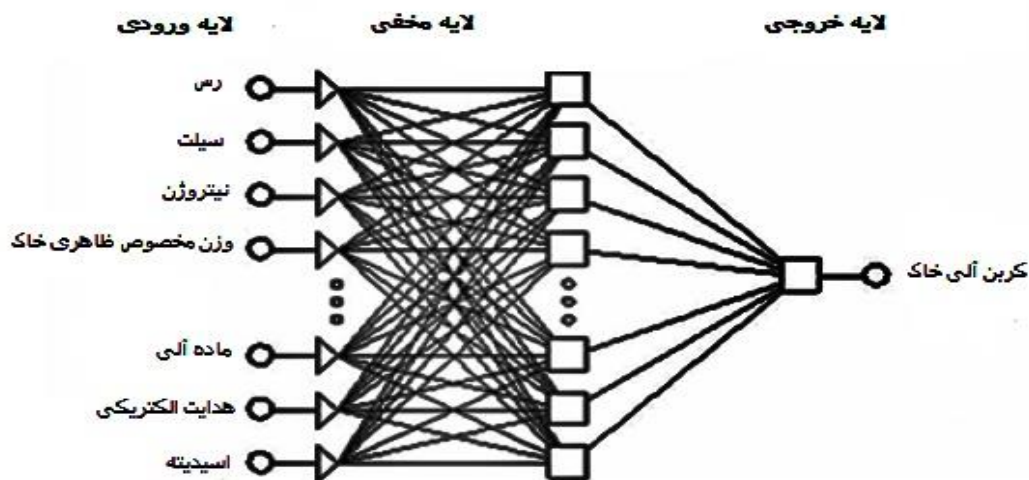
### شبکه عصبی مصنوعی

در پژوهش حاضر، برای مدل‌سازی از شبکه‌های پرسپترون چندلایه با یک شبکه سه‌لایه‌ای پیش‌خور استفاده شد. برای تعمیم‌دهی مناسب شبکه، باید

برای تجزیه و تحلیل اطلاعات ابتدا داده‌های موردنیاز به نرم‌افزار SPSS انتقال داده شد. این اطلاعات دسته‌بندی و با رسم باکس پلات مربوط به داده‌های هر پارامتر، داده‌های پرت شناسایی و حذف شد. سپس برای مدل‌سازی کربن آلی خاک از ویژگی‌های هدایت الکتریکی، اسیدیته، وزن مخصوص ظاهری، درصد رس، درصد سیلت، درصد ماده آلی و درصد نیتروژن استفاده شد. برای این کار از رگرسیون آماری و شبکه عصبی مصنوعی استفاده شد. برای ایجاد شبکه عصبی مصنوعی و شبکه عصبی تطبیقی-فازی از نرم‌افزار MATLAB ۲۰۱۰ و برای رگرسیون آماری از نرم‌افزار SPSS 19 استفاده شد. شبکه عصبی مورد استفاده در این پژوهش از نوع شبکه عصبی پرسپترون چندلایه است. روش ورود داده‌ها بدین گونه بود که به صورت تصادفی ۷۰ درصد نمونه‌ها در شبکه عصبی مصنوعی برای آموزش<sup>۱</sup> مدل، ۱۵ درصد داده‌ها برای انجام فرآیند اعتبارسنجی<sup>۲</sup> مدل و ۱۵ درصد داده‌ها نیز برای آزمون<sup>۳</sup> مدل انتخاب گردید. در رگرسیون چندمتغیره نیز از ۸۵

توزیع خاص فرض می‌شوند (شکل ۴). پارامترهای تنظیم با یک واریانس نامعلوم از این توزیع‌ها مرتبط هستند؛ بنابراین می‌توان با استفاده از تکنیک‌های آماری آن را تخمین زد. یک ویژگی این الگوریتم این است که یک اندازه‌گیری از تعداد وزن‌ها و بایاس‌های مؤثر در شبکه ارائه می‌دهد. به این معنی که در پایان آموزش می‌توان تشخیص داد که چند پارامتر شبکه در آموزش مؤثر بوده‌اند (Schaap, 1996).

به‌گونه‌ای از آموزش بیش‌ازاندازه<sup>۱</sup> جلوگیری نمود. در مطالعه حاضر، برای جلوگیری از آموزش بیش‌ازاندازه در شبکه‌های پرسپترون چندلایه از روش تنظیم خودکار<sup>۲</sup> استفاده شد. در این روش تعیین پارامترهای کارایی به‌صورت اتوماتیک بسیار مطلوب است. یک راه برای رسیدن به این فرآیند استفاده از الگوریتم یادگیری لوبنبرگ مارکوت<sup>۳</sup> است. در این الگوریتم، وزن‌ها و بایاس‌های شبکه، دارای مقادیر تصادفی با یک



شکل ۴- ساختار شبکه عصبی مورد استفاده به منظور مدل‌سازی کربن آلی خاک  
Figure 4- Structure of the neural network used to model soil organic carbon

بین ۱- تا ۱ است و مقدار ۱ و ۱- بیان‌کننده پیش‌بینی بدون خطا است. روابط مربوط به محاسبه نمایه‌های آماری به شرح زیر است. روابط (۲ تا ۴) است.

$$CE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O}_i)} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum (O_i - P_i)^2}{n}} \quad (3)$$

$$R^2 = \frac{\sum_{i=1}^N (O_i - \bar{O}_m)(P_i - \bar{P}_m)}{(\sum_{i=1}^N ((O_i - \bar{O}_m)^2)^{0.5} (\sum_{i=1}^N ((P_i - \bar{P}_m)^2)^{0.5})} \quad (4)$$

که در این روابط:  $O_i$  مقدار مشاهده‌شده،  $P_i$  مقدار پیش‌بینی‌شده،  $N$  تعداد داده‌های مشاهداتی،  $\bar{O}_m$

### معیارهای ارزیابی

به‌منظور ارزیابی نتایج مدل شبکه عصبی مصنوعی و برآوردهای رگرسیونی از مجذور میانگین مربعات خطا<sup>۴</sup> (RMSE)، ضریب کارایی<sup>۵</sup> (CE) و ضریب تبیین<sup>۶</sup> ( $R^2$ ) استفاده گردید. مقدار مجذور میانگین مربعات خطا بین صفر و یک قرار دارد و مقدار آن هرچه به صفر نزدیک‌تر باشد نشان‌دهنده دقت بالای پیش‌بینی است. شاخص پراکندگی برحسب درصد است؛ و بیان‌گر درصد پراکندگی داده‌های پیش‌بینی‌شده نسبت به مقادیر واقعی است که مقدار صفر بیان‌کننده عدم پراکندگی در پیش‌بینی است. همچنین مقدار ضریب تبیین ( $R^2$ )

3. Levenberg-Marquardt

1. Over Fitting  
2. Automated Regularization  
3. Root of Mean Squares Error  
4. Coefficient of Efficiency  
5. Coefficient of Determination

(۱) ارائه شده است. نتایج این جدول نشان می‌دهد که کربن آلی خاک تغییرپذیری نسبتاً زیادی از خود نشان می‌دهد. آزمون نرمال بودن داده‌ها به روش کولموگروف - اسمیرونوف نشان داد که متغیر کربن آلی خاک دارای توزیع نرمال است.

مقدار میانگین مشاهدات و  $\bar{P}_m$  مقدار میانگین پیش‌بینی شده است.

### نتایج و بحث

نتایج آمار توصیفی کربن آلی خاک و سایر خصوصیات فیزیکی و شیمیایی خاک منطقه مورد مطالعه در جدول

جدول ۱- آمار توصیفی فاکتورهای اندازه‌گیری شده و درصد کربن آلی خاک در حوزه پاکل

**Table 1- Descriptive statistics of measured factors and percentage of soil organic carbon in Pakel area**

دامنه تغییرات variation range	انحراف معیار standard deviation	میانگین Average	حداکثر Maximum	حداقل Minimum	تعداد Number	عوامل خاکی مورد بررسی The studied soil factors
0.43	0.23	0.52	0.98	0.17	60	کربن (%) (C%)
0.36	8.71	23.79	40.6	8.6	60	رس (Clay)
0.45	13.15	28.70	60	0	60	سیلت (Silt)
0.44	0.02	0.05	0.12	0.01	60	نیترژن (N)
0.12	0.17	1.37	1.71	0.96	60	وزن مخصوص ظاهری خاک apparent specific gravity of the soil
0.09	0.04	0.43	0.53	0.30	60	ماده آلی (OC)
3.03	3.53	1.17	21	0.53	60	هدایت الکتریکی (EC)
0.03	0.25	7.42	8.02	6.85	60	اسیدیته (PH)

عدم وجود همبستگی بین خطاها رد نمی‌شود و می‌توان از رگرسیون استفاده کرد. فرض دیگر رگرسیون خطی بررسی هم‌راستایی بین متغیرهای مستقل است. بدین منظور از فاکتور عامل تورم واریانس<sup>۲</sup> (VIF) استفاده شد. متغیرهایی که VIF آن‌ها کمتر از ۱۰ باشد مشکل هم‌راستایی نخواهند داشت. مقادیر بین ۲-۱ این فاکتور برای متغیرهای مستقل نشان‌دهنده این است که این متغیر مشکل هم‌راستایی ندارد. از فرضیات دیگر رگرسیون نرمال بودن متغیر وابسته است که به همین منظور از آزمون کولموگروف-اسمیرنوف برای آزمون نرمال بودن استفاده شد (Hengl et al., 2004). نتایج این آزمون نشان داد که کربن آلی خاک دارای توزیع نرمال است. بعد از تعیین معادله توسط داده‌های آموزش کارایی این مدل در برآورد کربن آلی خاک توسط داده‌های آزمون بررسی شد که نتایج آن در جدول (۳) ارائه شده است. مقادیر ضریب تبیین،

در این تحقیق برای به دست آوردن مدل رگرسیونی خطی چندمتغیره برای کربن آلی خاک با استفاده از متغیرهای مستقل شامل هدایت الکتریکی، اسیدیته، درصد ماده آلی، درصد رس، درصد سیلت و وزن مخصوص ظاهری، از روش توأم<sup>۱</sup> ورود متغیرها استفاده شد. در رابطه ۵ مدل با استفاده از روش توأم نشان داده شده است. یکی از مفروضاتی که در رگرسیون مدنظر قرار می‌گیرد، استقلال خطاها (تفاوت بین مقدار واقعی و مقادیر پیش‌بینی شده توسط معادله رگرسیون) از یکدیگر است. در صورتی که فرضیه استقلال خطاها رد شود و خطاها با یکدیگر همبستگی داشته باشند امکان استفاده از رگرسیون وجود ندارد. به منظور بررسی استقلال خطاها از یکدیگر از آزمون دوربین-واتسون استفاده می‌شود. از آنجایی که مقدار آماره دوربین واتسون (۱/۹۴) در فاصله ۱/۵ تا ۲/۵ قرار دارد، فرض

۰/۵۱ است که نشان می‌دهد که مدل رگرسیونی خطی دقت نسبتاً خوبی در برآورد کربن آلی خاک داشت.

$$c(\%) = 0.009 + 0.11clay \pm 0.47silt \pm (5)$$

$$0.32N + 0.2723E + 0.61OC + 0.04EC + 0.24ph$$

جدول ۲- خلاصه مدل رگرسیونی محاسبه شده به منظور مدل سازی کربن آلی خاک

**Table 2- Summary of the regression model calculated to model soil organic carbon**

ضریب همبستگی (CC)	ضریب تبیین ( $R^2$ )	ضریب تبیین تعدیل شده ( $R^2$ )	دوربین-واتسون
0.94	0.89	0.88	1.94


جدول ۳- نتایج آموزش و آزمون مدل رگرسیون خطی چندمتغیره برای کربن آلی خاک

**Table 3- Results of training and testing of multivariable linear regression model for soil organic carbon**

مرحله آموزش (Training stage)				مرحله آزمون (Test stage)				مدل رگرسیون Regression model
R	CE	RMSE	$R^2$	R	CE	RMSE	$R^2$	
0.81	0.65	0.13	0.66	0.80	0.51	0.08	0.64	

با یکدیگر داشته و اختلاف حاصل از برازش نمودارها در قسمت آزمون و آموزش در این نمودار آشکار است.

شکل (۵) نشانگر این نکته است که مقادیر مشاهده‌ای و برآوردی در دو مرحله آزمون و آموزش انطباق کمتری



شکل ۵- برازش مقادیر مشاهده‌ای و برآوردی با استفاده از رگرسیون خطی چندمتغیره در مرحله آموزش و آزمون

**Figure 5- Fitting the observed and estimated values using multi-variable linear regression in the training and test phase**

با  $CE=0.87$  و  $RMSE=0.36$ ،  $R^2=0.96$  به عنوان بهترین مدل شبکه عصبی مصنوعی انتخاب شد. شکل (۶) نحوه انطباق نتایج حاصل از داده‌های آموزش، صحت‌سنجی و آزمون را در شبکه عصبی مصنوعی بر روی هم نشان می‌دهد. نتایج حاصل بیانگر این نکته است که پیش‌بینی مقادیر مشاهده‌ای و برآوردی تا حدود زیادی مشابه با یکدیگر بوده و منطبق برهم است.

نتایج مدل سازی شبکه عصبی مصنوعی

در جدول (۴) آماره‌های خطا ضریب تعیین حاصل از اجرای شبکه عصبی مصنوعی برای سه مرحله آموزش، صحت‌سنجی و آزمایش در برآورد کربن آلی خاک ارائه گردیده است. ساختار مورد استفاده در این تحقیق شامل هفت لایه ورودی، دوازده لایه پنهان و یک لایه خروجی است. شبکه ۱-۱۲-۷ با قانون یادگیری لونیگ مارکوت با تابع انتقال سیگموئید در مرحله آزمون

جدول ۴- آماره‌های خطا و ضریب تعیین حاصل از اجرای شبکه عصبی مصنوعی برای مرحله‌های آموزش، صحت‌سنجی و آزمون در برآورد کربن آلی ذره‌های خاک

Table 4- Error statistics and coefficient of determination resulting from the implementation of ANN for the stages of training, verification and testing in the estimation of organic carbon of soil particles

نوع شبکه عصبی Neural network type	قانون یادگیری Law of learning	تابع فعالیت Activity function	آرایش Arrangement	مراحل Steps	R <sup>2</sup>	RMSE	CE
				آموزش (Training)	0.99	0.031	0.97
برسپترون چند لایه	لونبرگ مارکوت	سیگموئید	۷-۱۲-۱	صحت سنجی Validation	0.99	0.036	0.94
				آزمون (Test)	0.96	0.043	0.87



شکل ۶- برازش مقادیر مشاهده‌ای و برآوردی با شبکه عصبی مصنوعی در مرحله آزمون، صحت‌سنجی و آموزش  
Figure 6- Fitting the observed and estimated values with the ANN in the testing, validation and training stages

مقایسه مدل‌های مختلف با استفاده از شاخص RMSE و  $R^2$  امکان‌پذیر است. این فاکتورها زمانی می‌توانند برتری مدل‌ها را تعیین نمایند که بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده محاسبه شوند. توجه به مقادیر RMSE،  $R^2$  و CE مزیت نسبی مدل‌ها را نشان می‌دهد. بیشترین ضریب تبیین، بیشترین مقدار ضریب کارایی و کمترین میزان خطا، بهترین روش را معرفی می‌نماید؛ بنابراین روش شبکه عصبی مصنوعی با نوع تابع سیگموئید ( $R^2=0.96$ ،  $RMSE=0.043$  و  $CE=0.087$ ) نسبت به رگرسیون چندمتغیره ( $R^2=0.64$ )

به‌عنوان بهترین روش تعیین گردید. دلیل این امر در نظر گرفتن روابط غیرخطی بین پدیده‌ها در روش شبکه عصبی مصنوعی می‌باشد (Navabian, et al., 2007). مدل توسعه یافته شبکه عصبی مصنوعی برای پیش‌بینی کربن آلی خاک در منطقه مورد مطالعه ۹۶ درصد از تغییرپذیری در سطح ویژگی‌های زودبافت را توجیه نمود و در نهایت حدود ۴ درصد از تغییرپذیری کربن آلی خاک در این منطقه تبیین نگردید، که این موضوع تا اندازه زیادی به دلیل در نظر نگرفتن و عدم اندازه‌گیری پارامترهای مدیریتی می-

تغییرات کربن آلی را پیش‌بینی کنند. مقایسه بین مدل‌های رگرسیونی و شبکه عصبی نشان داد که مقادیر برآورد شده به وسیله شبکه عصبی دارای دقت بیشتری نسبت به روش رگرسیونی می‌باشد. روش‌های آماری و نتایج شبکه‌های عصبی برتری مدل‌های شبکه عصبی را در برآورد کربن آلی ذره‌های خاک بیان می‌کند. سایر محققین نیز (Moghaddamnia *et al.*, 2009; Parasarman *et al.*, 2006; Baiat varkesh *et al.*, 2011; Parsafar and Marofi, 2009) در مطالعات خود به این موضوع اشاره نموده و این مدل را دارای صحت و دقت بالا معرفی کرده‌اند. علت تفاوت بین عملکرد بهتر شبکه‌های عصبی در مقایسه با روش‌های آماری را می‌توان در قابلیت تخمین و پیش‌بینی شبکه‌های عصبی مصنوعی برای تقریب غیرخطی با حجم کم داده‌ها جستجو نمود. این در حالی است که عملکرد و دقت روش‌های رگرسیونی به شدت از حجم کم نمونه‌ها تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری گردد (Norani and Salehi, 2008). نتایج کلی پژوهش نشان می‌دهد که در عرصه‌های طبیعی که مشکلات خاص نمونه‌برداری، هزینه‌های تجزیه و آنالیز نمونه‌ها در سطح زیاد وجود دارد، می‌توان از روش‌های هوش مصنوعی و به کمک داده‌های زودیافت برای تخمین کربن آلی خاک سود جست. انتظار می‌رود در مطالعات آتی برای ایجاد مدلی معتبرتر که تغییرپذیری بیشتری از مقدار کربن آلی خاک در این منطقه را پیش‌بینی نماید، از نمونه‌برداری متراکم‌تر و تلفیق متغیرهای فیزیوگرافی و خاکی مؤثر بر کربن آلی به نتایج رضایت بخش‌تری دست یافت.

#### نتیجه‌گیری

در این تحقیق به‌منظور برآورد کربن آلی خاک از مدل‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره استفاده شد. نتایج نشان داد که مقدار کربن آلی خاک

باشد. در همین ارتباط در پژوهشی، پس از مقایسه مدل‌های رگرسیونی و شبکه عصبی مصنوعی در برآورد کربن آلی خاک، با توجه به مقدار مجموع مربعات خطا (SSE) که در مدل شبکه عصبی و مدل رگرسیونی چندمتغیره به ترتیب ۵/۴۳ و ۶/۲۳ بودند، به برتری مدل شبکه عصبی پی بردند (Ingleby and Crowe, 2001). مدل‌های شبکه عصبی به دلیل در نظر گرفتن روابط غیرخطی موجود میان ویژگی‌های زودیافت خاک و کربن آلی خاک و به دنبال آن افزایش دقت در برآورد پیش‌بینی‌ها می‌تواند جایگزین مناسبی برای مدل‌های مرسوم رگرسیونی در مدل‌سازی کربن آلی خاک باشد (Navabian *et al.*, 2007). پیرامون ارتباط فاکتور کربن آلی خاک با ویژگی‌های زودیافت خاک تاکنون پژوهش‌های اندکی صورت گرفته است اما در ارتباط با کربن آلی کل با داده‌های آنالیز سطح زمین تحقیقات زیادی صورت گرفته است که از آن جمله می‌توان به تحقیق ایوبی و علیزاده (Auobi and Alizadeh, 2006) اشاره کرد. آنها از مدل رگرسیون خطی چندمتغیره برای برآورد کربن آلی براساس ویژگی‌های پستی و بلندی در ۳ واحد سنگ‌شناسی استفاده کردند و به این نتیجه رسیدند که این مدل می‌تواند ۲۸ تا ۳۵ درصد از تغییرات کربن آلی خاک را در منطقه توجیه نماید و همچنین نتایج نشان داد که فاکتورهای پستی و بلندی مهم که با کربن آلی ارتباط داشتند و در مدل رگرسیونی نیز وارد شده، به‌طور عمده شامل شیب و جهت آن، ارتفاع، شاخص قدرت جریان و شاخص حمل رسوب بوده است. در همین ارتباط سومفلت و دوتمن (Sumfleth and Duttman, 2008) از داده‌های عوارض زمین برای پیش‌بینی توزیع خصوصیات خاک از جمله کربن آلی خاک استفاده کردند. تامسون و کولکا (Thompson and Kolka, 2005) نیز با مدل رگرسیون زمین‌نما توانستند ۷۰ درصد از

نتایج کلی پژوهش نشان می‌دهد که در عرصه‌های طبیعی که مشکلات خاص نمونه‌برداری، هزینه‌های تجزیه و آنالیز نمونه‌ها در سطح زیاد وجود دارد، می‌توان از روش‌های هوش مصنوعی و به کمک داده‌های زودیافت برای تخمین کربن آلی خاک سود جست. انجام مطالعات دوره‌ای پایش ترسیب کربن در منطقه مورد مطالعه به منظور بررسی تغییرات زمانی ترسیب کربن در کاربری‌های مورد نظر و تهیه نقشه ذخیره کربن آلی خاک در نواحی مختلف برای تشخیص مناطق دارای پتانسیل ترسیب کربن و مدیریت حاصلخیزی خاک می‌تواند مناسب باشد. این نوع مطالعات برای ارزیابی تأثیر تغییر کاربری اراضی بر تغییر کربن آلی خاک نیز مفید خواهد بود. در نهایت پیشنهاد می‌شود که از سایر روش‌ها و مدل‌ها در تخمین و پیش‌بینی کربن آلی خاک استفاده شود.

## References

- Agharaz, H. (2018). Biomechanical Operation effect on soil carbon of Pakal Basin, Markazi Province. *Journal of Watershed Engineering and Management*. 10(4), 529-536.
- Allison, L.E. (1975). Organic carbon. In: Black CA, Evans DD, White JL, Ensminger LE, Clark FE. (Eds.), *Methods of soil analysis, Part 2, Chemical and microbiological properties*. American Society of Agronomy, Madison. 1367p.
- Auobi, S. & Alizadeh, M. (2006). Soil surface attributes prediction using digital topographic model (Case Study: part of Mehr Watershed, Sabzevar, and Khorasan Province). *Science and Technology of Agriculture and Natural Resources*, 10(2), 85-96.
- Baiat varkesh, M., Zare abiane, H., Marofi, S., Sabziparvar, A. & Soltani, F. (2009). Simulates daily crop reference evapotranspiration using artificial intelligence methods and compared with experimental measurements of having cold semi arid climate, Hamedan. *J SOIL WATER CONSERV*. 16(4), 79-83.
- متأثر از خصوصیات فیزیکی و شیمیایی خاک منطقه می‌باشد، لذا لازم است از روش‌های محاسباتی با دقت مطلوب در تخمین این پارامتر پیچیده و مهم استفاده شود. مقایسه مدل‌های مختلف با استفاده از شاخص  $RMSE$ ،  $R^2$  و  $CE$  امکان‌پذیر است. این فاکتورها زمانی می‌توانند برتری مدل‌ها را تعیین نمایند که بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده محاسبه و مقایسه انجام شود. توجه به مقادیر شاخص‌ها، مزیت نسبی مدل‌ها را نشان می‌دهد؛ بنابراین با توجه به مباحث مطرح شده روش شبکه عصبی مصنوعی با نوع تابع سیگموئید ( $RMSE=0.043$ ،  $R^2=0.96$  و  $CE=0.87$ ) به عنوان روش بهتری نسبت به رگرسیون چندمتغیره ( $RMSE=0.064$ ،  $R^2=0.96$  و  $CE=0.51$ ) تعیین گردید. روش‌های آماری و نتایج شبکه‌های عصبی، برتری مدل‌های شبکه عصبی را در برآورد کربن آلی ذره‌های خاک بیان می‌کند.
- Bird, S.B., Herrick, J.E., Wander, M.M., & Wright, S.F. (2013). Spatial heterogeneity of aggregate stability and soil carbon in semi-arid rangeland. *Environ. Poll*, 116(3), 445-455.
- Blake, G.R. & Hartge, K.H. (1986). Bulk density Methods of Soil Analysis, Physical & Mineralogical Methods. *Soil Science Society of America Journal*, 9(1), 361-376.
- Broge, N.H., Greve, M.H. & Larsen, R. (2005). Estimating topsoil organic matter content in two experimental fields in Denmark using multi-spectral aerial imagery and topographic data. *Geografisk Tidsskrift*, D, J, G. 105(2), 1-14.
- Chen, S., Arrouays, D., Angers, D.A., Chenu, C., Barré, P., Martin, M.P., Saby, N.P. & Walter, C. (2019). National estimation of soil organic carbon storage potential for arable soils: A data-driven approach coupled with carbon-landscape zones. *Science of the Total Environment*, 666, 355-367.
- Crowther Thomas, W., Mark, A. & Bradford, A. (2013). Thermal acclimation in widespread heterotrophic soil microbes. *ECOL LETT*, 16.4, 469-477.

- Eskandari, Sh., Nabiollahi, K., & Taghizadeh-Mehrjardi, R. (2018). Digital Mapping of Soil Organic Carbon (Case Study: Marivan, Kurdistan Province). *Journal of Water and Soil*, 2-4, 737-750 (In Persian)
- Follett, R.F., Samson-Liebig, E., Kimble, J.M., Pruessner, E.G. & Waltman, S. (2001). Carbon sequestration under CRP in the historic grassland soils of the USA. *SSSA Special Publication*, 57, 27-40.
- Gee, G.W. & Bauder, J.W. (1986). Particle size analysis. 383-411p, In: *Methods of soil analysis*. Part 2nd ed. Klute, A. (Ed). Agron. Monogr. 9. ASA. Madison. WI.
- Hengl, T., Huvelink, G.B.M., & Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120(1-2), 75-93.
- Hernandez, R., Koohafkan, P. & Antoine, J. (2004). Assessing Carbon Stocks and modeling win-win Scenarios of carbon sequestration throughland-use change, 166 pp.
- Holmberg, M., Forsius, M., Starr, M., & Huttunen, M. (2006). *An application of artificial neural networks to carbon, nitrogen and phosphorus concentration in three boreal streams and impacts of climate change*. International Society for Ecological Information 3rd Conference. Grottaferrata, Roma, ITALIE. 195, 51-60.
- Ingleby, H.R., & Crowe, T.G. (2001). Neural network models for predicting organic matter content in Saskatchewan soils. *Can, Biosyst, Eng*. 43, 71-75.
- Karkaj, A., Sepehri, E., Barani, H. & Motamedi, J. (2017). The relationship between soil organic carbon storage and some soil properties in East Azarbaijan rangelands. *Rangeland Scientific Journal* 2, 125-138. (In Persian).
- Khamoshi, S.E., Sarmadian, F.S., Mousavi, R. & Rahmani, A. (2019). *Organic soil carbon mapping using random forest model*. In: 16th Iranian Soil Science Congress, University of Zanzjan, Iran, 1-6. (In Persian).
- Khordehbin, S., Hojatia, S., Landi A. & Ahmadianfar, I. (2020). Comparison of different data mining methods in predicting soil organic carbon storage in some lands of Behbahan city. *Iranian Journal of Soil and Water Research*, 4(51), 1041-1054. (In Persian).
- Mahmoudzadeh, H., Matinfar, H.R., Taghizadeh-Mehrjardi, R., & Kerry, R. (2020). Spatial prediction of soil organic carbon using machine learning techniques in western Iran. *Geoderma Regional*.
- Mahmoudzadeh, H., Metinfar, H. & Taghizadeh Mehrjardi, R. (2020). Digitization of soil organic carbon with artificial neural network and multivariable linear regression in Kurdistan province. *Journal of soil management and sustainable production*, 10(4), 77-98. (In Persian).
- Matinfar, H.R., Mahmodzadeh, H. & Fariabi, A. (2018). Estimation soil organic matter (SOM) content using visible and near infrared spectral data, PLSR and PCR statistical models. *Iranian Remote Sensing & GIS*, 10(2), 15-32. (In Persian).
- Menhaj, M.B. (1998). *Fundamentals of neuralnetworks*. First Edition, Professor Hesabi Publishers, 502 pp.
- Merdun, H., Ozer, T., Meral, R. & Apan, M. (2006). Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90, 108-116.
- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S. & Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro fuzzy inference system techniques. *Adv Water Resour*, 32, 89-97.
- Navabian, M., Liaghat, A.M. & Homaei, M. (2007). Comparison of transfer functions of artificial neural network and regression in estimating the saturated hydraulic conductivity. *Proceedings of the Tenth Soil Science Congress of Iran, Karaj*, Pp. 189-204.
- Norani, V. & Salehi, K. (2008). *Rainfall-runoff modeling using adaptive fuzzy neural network and comparison with neural network and fuzzy inference*. *National*

- Congress on Civil Engineering, Tehran University*. Proceedings of the Fourth National Congress of Civil Engineering. Proceedings of the Tenth Soil Science Congress of Iran, Karaj, Pp. 967-969.
- Pahlavan-Rad, M.R., Dahmardeh, K., & Brungard, C. (2018). Predicting soil organic carbon concentrations in a low relief landscape, eastern Iran. *Geoderma Regional* 15, e00195.
- Parasurman, K, Elshorbagy, A. & Si, B. (2006). Estimating saturated hydraulic conductivity in spatially variable fields using neural network in Ensembles. *Soil Science Society of America Journal*, 70, 1851-1859.
- Parsafar, N. A. & Marofi, S. (2011). Estimated temperatures at depths using network neural network - Fuzzy (Case Study: Kermanshah region). *Journal of Soil and Water Sci.* 21(3), 21-22. (in Persian).
- Pilevari, A., Auobi, S.h. & Khademi, H. (2010). Comparison of artificial neural network and multiple linear regression analysis to predict soil organic carbon data to the ground. *Journal of Soil and Water Conservation*, 24(6), 1151-1163.
- Raei, B., Ahmadi, A., Neyshaburi, M.R., Ghorbani, M.A., & Asadzadeh, F. (2020). *Journal of water and soil research in Iran*, 51(1), 61-76. DOI: 0.22059/ijswr. 2019. 283359. 668233
- Schaap, M.G. & Bouten, W. (1996). Modeling water retention curves of sandy soil using neural networks. *WATER RESOUR RES*, 32, 3033-3040.
- Somarathna, P.D.S.N., Minasny, B. & Malone, B.P. (2017). More data or a better model? Figuring out what matters most for the spatial prediction of soil carbon. *Soil Science Society of America Journal*, 81(6), 1413-1426.
- Sumfleth, K., & Duttmann, R. (2008). Prediction of soil property distribution in paddy soil landscapes using terrain data and satellite information as indicators. *ECOL, INDIC*, 8, 485 – 501.
- Taghizadeh-Mehrjardi, R., Neupane, R., Sood, K. & Kumar, S. (2017). Artificial bee colony feature selection algorithm combined with machine learning algorithms to predict vertical and lateral distribution of soil organic matter in South Dakota, USA. *Carbon Management*, 8-3, 277-291.
- Thompson, J.A. & Kolka, R.K. (2005). Soil carbon storage estimation in a forested watershed using quantities soil - landscape modeling. *Soil Science Society of America Journal*, 69, 1086–1093.
- Wang, B., Waters, C., Orgill, S., Cowie, A., Clark, A., Liu, D.L., Simpson, M., McGowen, I. & Sides, T. (2018). Estimating soil organic carbon stocks using different modelling techniques in the semi-arid rangelands of eastern Australia. *Ecological Indicators*, 88, 425-438.
- Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S. & Finke, P. (2019). Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma*, 338, 445-452.
- Zhang, H., P. Wu., Yin, A., Yang, X., Zhang, M. & Gao, C. (2017). Prediction of soil organic carbon in an intensively managed reclamation zone of eastern China: A comparison of multiple linear regressions and the random forest model. *Science of the Total Environment* 592, 704-713.