

نشریه آب و خاک

(علوم و صنایع کشاورزی)



جلد ۳۹ شماره ۶

سال ۱۴۰۴

شاپا: ۴۷۵۷-۲۰۰۸

شماره پیاپی ۱۰۴

عنوان مقالات

۵۳۱ بررسی اهمیت فاصله نمونه برداری بر ساختار مکانی پتاسیم قابل استفاده در خاک های زراعی دشت شهرکرد
مرضیه براتی زائانی - محمدحسن صالحی - علیرضا حسین پور - اعظم جعفری

پهنه بندی اگروکلیمایی ایران بر اساس تاریخ کاشت و طول دوره رشد محصول جو
۵۴۱ (*Hordeum vulgare* L.) با استفاده از روش های پیشرفته تحلیل فضایی
خالد احمد آلی - مینا کاظم پور - عرفان فضلی - عبدالمجید لیاقت - ایمان حاجی راد

۵۵۶ شبیه سازی بارش ماهانه با مدل های ترکیبی یادگیری ماشین: حوضه دریاچه نمک
علی دلیر گیر آباد - محمدامین عبداللہی - افشین اشرف زاده

ارزیابی عمقی ویژگی های خاک با استفاده از رویکرد تلفیقی مبتنی بر اندازه اثر و تحلیل چندمتغیره
۵۷۵ (مطالعه موردی: خاک های استان خراسان رضوی)
نجمه مظلوم - مهدی زنگی آبادی

۵۹۱ ارزیابی قابلیت اطمینان داده های شبکه بندی شاخص استاندارد شده بارش - تبخیر و تعرق در حوضه های آبریز ایران
نادیا پودینه - حمید نظری پور - محمود خسروی

تأثیر کاربرد بیوچار و کمپوست بر ویژگی های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر
۶۱۱
اکبر کریمی - الهام زنگنه یوسف آبادی

آب و خاک

(علوم و صنایع کشاورزی)

با شماره پروانه 21/2015 مورخه 1368/4/11 و درجه علمی-پژوهشی شماره 26524 تاریخ 1373/10/19 از

وزارت علوم، تحقیقات و فناوری

جلد 39 شماره 6 بهمن - اسفند سال 1404

بر اساس مصوبه وزارت عتف از سال 1398، کلیه نشریات دارای درجه "علمی-پژوهشی" به نشریه "علمی" تغییر نام یافتند.

صاحب امتیاز: دانشگاه فردوسی مشهد

مدیر مسئول:

رضا ولیزاده

سر دبیر:

امیر فتوت

اعضای هیئت تحریریه:

استاد- تغذیه نشخوارکنندگان (دانشگاه فردوسی مشهد)

استاد- علوم خاک (دانشگاه فردوسی مشهد)

علوم خاک (دانشگاه تبریز)

هواشناسی کشاورزی (دانشگاه تهران)

آبیاری (دانشگاه اوکلاهما، آمریکا)

علوم خاک (دانشگاه فردوسی مشهد)

علوم خاک (دانشگاه علوم کشاورزی و منابع طبیعی گرگان)

آبیاری و زهکشی (دانشگاه فردوسی مشهد)

علوم خاک (دانشگاه فردوسی مشهد)

خاکشناسی (دانشگاه گریفیت، استرالیا)

علوم خاک (دانشگاه فردوسی مشهد)

آبیاری و زهکشی (دانشگاه تهران)

آبیاری و مهندسی عمران (دانشگاه فردوسی مشهد)

هواشناسی کشاورزی (دانشگاه فردوسی مشهد)

اوستان، شاهین

بذرافشان، جواد

تقوایان، صالح

خراسانی، رضا

خرمالی، فرهاد

علیزاده، امین

فتوت، امیر

قدیری، حسین

لکزیان، امیر

لیاقت، عبدالمجید

مساعدی، ابوالفضل

موسوی بایگی، محمد

ناشر: دانشگاه فردوسی مشهد

نشانی: دانشگاه فردوسی مشهد - دانشکده کشاورزی - ص.پ. 91775-1163 - دبیرخانه نشریات علمی - نشریه آب و خاک

پست الکترونیکی: jsa3@um.ac.ir

مقاله‌های این شماره در سایت <https://jsw.um.ac.ir> به صورت کامل نمایه شده است.

این نشریه به صورت دو ماهانه (شی شماره در سال) منتشر می‌شود.

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

مندرجات

- 531 بررسی اهمیت فاصله نمونه برداری بر ساختار مکانی پتاسیم قابل استفاده در خاک های زراعی دشت شهر کرد
مرضیه براتی زانیانی - محمدحسن صالحی - علیرضا حسین پور - اعظم جعفری
- 541 پهنه بندی اگروکلیمایی ایران بر اساس تاریخ کاشت و طول دوره رشد محصول جو
(*Hordeum vulgare* L.) با استفاده از روش های پیشرفته تحلیل فضایی
خالد احمد آلی - مینا کاظم پور - عرفان فضلی - عبدالمجید لیاقت - ایمان حاجی راد
- 556 شبیه سازی بارش ماهانه با مدل های ترکیبی یادگیری ماشین: حوضه دریاچه نمک
علی دلیر گبر آباد - محمدامین عبداللهی - افشین اشرف زاده
- 575 ارزیابی عمقی ویژگی های خاک با استفاده از رویکرد تلفیقی مبتنی بر اندازه اثر و تحلیل چندمتغیره (مطالعه موردی: خاک های
استان خراسان رضوی)
نجمه مظلوم - مهدی زنگی آبادی
- 591 ارزیابی قابلیت اطمینان داده های شبکه بندی شاخص استاندارد شده بارش - تبخیر و تعرق در حوضه های آبریز ایران
نادیا پودینه - حمید نظری پور - محمود خسروی
- 611 تأثیر کاربرد بیوجار و کمپوست بر ویژگی های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر
اکبر کریمی - الهام زنگنه یوسف آبادی

Research Article

Vol. 39, No. 6, Feb.-Mar. 2026, p. 529-538

Assessing the Importance of Sampling Distance on the Spatial Structure of Available Potassium in the Agricultural Soils of Shahrekord Plain

M. Barati Zanyani^{1*}, M.H. Salehi¹, A. Hossienpur¹, A. Jafari²

1- Department of Soil Sciences and Engineering, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran
(*- Corresponding Author Email: marziehbarati99@yahoo.com)

2- Department of Soil Science, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

Received: 07 October 2025
Revised: 15 December 2025
Accepted: 10 January 2026
Available Online: 10 January 2026

How to cite this article:

Barati Zanyani, M., Salehi, M.H., Hossienpur, A., & Jafari, A. (2026). Assessing the effect of sampling distance on the spatial structure of available potassium in the agricultural soils of Shahrekord Plain. *Journal of Water and Soil*, 39(6), 529-538. (In Persian with English abstract).
<https://doi.org/10.22067/jsw.2026.95838.1504>

Introduction

Nowadays, the application of variable-rate fertilization is primarily based on soil analysis maps. These maps play a crucial role in decision-making for fertilizer management and the optimization of plant nutrient use. However, the sampling distance is often determined without considering the spatial variability of soil properties, which can lead to reduced map accuracy and inappropriate fertilization recommendations. Previous studies have shown that the density and spacing of soil samples have a significant impact on the accuracy of geostatistical models and the quality of maps produced using methods such as kriging. Moreover, soil management practices, including varying fertilizer application patterns, crop rotation, and historical land use, can strongly influence the spatial patterns of soil nutrients. Therefore, investigating the effect of sampling distance on the spatial distribution of major soil nutrients, particularly available potassium, can help optimize soil sampling and provide more precise recommendations for variable-rate fertilization. The present study aimed to examine the effect of sampling distance on the spatial structure of available potassium in the agricultural soils of the Shahrekord Plain.

Material and Methods

For this purpose, 120 soil samples were collected using a regular grid sampling design with a spacing of 1335 meters from the surface layer of agricultural soils in the Shahrekord plain, covering an area of 21400 ha, and the available potassium content was determined in the laboratory. Descriptive statistics of the data, including the minimum, maximum, mean, median, coefficient of variation, and skewness of the variable, were calculated, and the normality of the data distribution was assessed using histograms and the Kolmogorov-Smirnov test. The experimental variogram of available potassium was constructed, and various theoretical models were fitted to it. Subsequently, the variogram parameters and the spatial dependency class of the variable were determined. Model validation was performed by adjusting the initial parameters so that the final optimized model had a mean error (ME) close to zero and a minimum mean squared error (MSE). Ordinary kriging in ArcGIS 10.3 was then used to produce maps of available potassium.

Results and Discussion

The available potassium in the soils ranged from 120 to 812 mg kg⁻¹, with a coefficient of variation of 38.2%. The data were not normally distributed; however, the log-transformed data followed a normal distribution. Geostatistical analysis indicated that the exponential model best fitted the data. The nugget effect was 0.108, and the range of this variable was estimated at 53300 meters, indicating that the selected sampling distance is much smaller than the spatial variability range; therefore, the sampling distance appears to be sufficient. However, the



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.95838.1504>

exponential variogram is nearly flat at short distances, showing little change in semivariance, which reflects the influence of strong soil management practices, such as varying fertilizer application patterns, crop rotation, and historical land use, on data dispersion. The spatial dependence of the studied variable was 50.2%, which falls into the moderate spatial dependence class. The mean error (ME) of the estimated available potassium was -0.0008 , and the mean squared error (MSE) was 0.011, indicating the unbiasedness and high accuracy of the estimation. The maps produced using the kriging method exhibited acceptable accuracy. This was achieved despite the increased variability at short distances and the disruption of regular spatial patterns caused by intensive soil management practices.

Conclusion

According to the findings, using an appropriate sampling distance is essential to accurately represent the spatial variability of major soil nutrients, particularly potassium. The findings of this study indicated that the current sampling distance is not sufficient to accurately represent the spatial variability of available potassium in the soils under investigation. Therefore, for future studies, it is recommended to investigate the effect of sampling distance at distances shorter than 1,335 meters to evaluate the model sensitivity and the accuracy of kriging maps at larger scales. This can help optimize soil sampling and provide more precise recommendations for variable-rate fertilizer application. Furthermore, it is recommended that future studies also consider the role of soil management practices in the spatial modeling of potassium, as these factors can strongly influence the spatial distribution of soil nutrients.

Acknowledgements

The authors would like to thank the Soil Science Department of the University of Shahrekord for providing equipment and facilities.

Keywords: Available potassium, Distance, Kriging, Sampling, Variogram

بررسی اهمیت فاصله نمونه برداری بر ساختار مکانی پتاسیم قابل استفاده در خاک‌های زراعی دشت شهرکرد

مرضیه براتی زانیانی^{۱*} - محمدحسن صالحی^۱ - علیرضا حسین پور^۱ - اعظم جعفری^۲

تاریخ دریافت: ۱۴۰۴/۰۷/۱۵

تاریخ پذیرش: ۱۴۰۴/۱۰/۲۰

چکیده

امروزه کاربرد کود با نرخ متغیر عمدتاً بر پایه نقشه‌های آنالیز خاک انجام می‌شود، با این حال، فاصله نمونه برداری اغلب بدون توجه به تغییرپذیری مکانی ویژگی‌های خاک تعیین می‌گردد. پژوهش حاضر با هدف بررسی اهمیت فاصله نمونه برداری بر توزیع مکانی پتاسیم قابل استفاده در خاک‌های زراعی دشت شهرکرد انجام شد. بدین منظور، ۱۲۰ نمونه خاک به روش نمونه برداری شبکه‌بندی منظم با فواصل ۱۳۳۵ متر از لایه سطحی خاک‌های زراعی دشت شهرکرد با مساحت ۲۱۴۰۰ هکتار جمع‌آوری شد و مقادیر پتاسیم قابل استفاده در آزمایشگاه تعیین گردید. دامنه تغییرات پتاسیم قابل استفاده در خاک‌ها از ۱۲۰ تا ۸۱۲ میلی گرم بر کیلوگرم بود و ضریب تغییرات آن، ۳۸/۲ درصد بود. تحلیل زمین آماری نشان داد که مدل نمایی بیشترین تناسب را با داده‌ها دارد و همبستگی مکانی پتاسیم قابل استفاده در سطح متوسط است. دامنه تأثیر این متغیر برابر با ۵۳۳۰۰ متر برآورد شد که نشان می‌دهد فاصله نمونه برداری انتخاب شده بسیار کمتر از دامنه تغییرپذیری مکانی است؛ بنابراین فاصله نمونه برداری کافی به نظر می‌رسد. با این حال، واریوگرام نمایی در فواصل کوتاه تقریباً افقی است، به گونه‌ای که نیم‌واریانس تغییر چندانی ندارد و این وضعیت نشان‌دهنده تأثیر تغییرات مدیریتی شدید خاک مانند؛ الگوهای متفاوت مصرف کود، تناوب زراعی و سابقه بهره‌برداری بر پراکندگی داده‌ها است. علی‌رغم افزایش تغییرپذیری در فواصل کوتاه و کاهش الگوی مکانی منظم ناشی از تغییرات مدیریتی شدید خاک، نقشه‌های حاصل از روش کریجینگ دقت قابل قبولی دارند. بنابراین، اگرچه فاصله نمونه برداری از نظر دامنه اثر کافی است، این فاصله نمی‌تواند تمام نوسانات کوچک‌برد ناشی از مدیریت خاک را به‌طور کامل ثبت کند. برای مطالعات آینده توصیه می‌شود که اثر تراکم نمونه برداری در فواصل کمتر از ۱۳۳۵ متر مورد بررسی قرار گیرد تا بتوان حساسیت مدل و دقت نقشه‌های کریجینگ را در مقیاس‌های بزرگ‌تر ارزیابی کرد. این امر می‌تواند به بهینه‌سازی نمونه برداری از خاک و ارائه توصیه‌های دقیق‌تر برای کاربرد کود با نرخ متغیر کمک کند.

واژه‌های کلیدی: پتاسیم قابل استفاده، فاصله، کریجینگ، نمونه برداری، واریوگرام

مقدمه

رایج‌ترین ابزار برای تعیین نیاز گیاهان به کودهای شیمیایی مورد استفاده قرار می‌گیرد. با توجه به اینکه سطح اولیه حاصلخیزی خاک و میزان خروج عناصر غذایی در اثر برداشت محصول و کوددهی در سطح مزرعه یکنواخت نیست، شناسایی تغییرپذیری مکانی عناصر غذایی در خاک‌های زراعی برای برنامه‌ریزی بهینه کوددهی و مدیریت موثر تغذیه

فرآیند رشد و برداشت محصولات کشاورزی منجر به خروج عناصر غذایی از خاک می‌شود، از آنجا که تداوم این روند می‌تواند حاصلخیزی خاک را کاهش دهد، برای حفظ حاصلخیزی و پایداری تولید لازم است این عناصر از طریق کوددهی جایگزین شوند. آزمون خاک به‌عنوان

۱- گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

(*)- نویسنده مسئول: Email: marziehbarati99@yahoo.com

۲- گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

گیاهان اهمیت ویژه‌ای دارد (Mallarino & Blanchet et al., 2017; Wittry, 2000).

تغییرپذیری مکانی ویژگی‌های خاک نقش مهمی در مدیریت پایدار کشاورزی، بهینه‌سازی منابع و تصمیم‌گیری علمی در مدیریت خاک دارد (Li & Heap, 2008). عناصر غذایی ضروری خاک ماهیتی پویا داشته و نیازمند مدیریت به‌موقع در مزارع کشاورزی هستند. پیش‌بینی دقیق توزیع مکانی عناصر غذایی خاک با استفاده از تراکم نمونه‌برداری مناسب، پیش‌نیاز بهبود کاربرد عملی نقشه‌های حاصلخیزی خاک مکانی است (Sahrawat et al., 2008). با این حال، ارائه چنین اطلاعاتی معمولاً با چالش‌هایی همراه است، از جمله هزینه بالای نمونه‌برداری، صرف وقت زیاد و ضرورت انتخاب طرح نمونه‌برداری بهینه برای شناسایی ساختار مکانی.

پتاسیم یکی از عناصر ضروری برای رشد و عملکرد گیاهان در خاک‌های زراعی محسوب می‌شود و نقش مهمی در تنظیم فرآیندهای فیزیولوژیکی مانند سنتز پروتئین، فتوسنتز، انتقال قندها و تنظیم فشار اسمزی ایفا می‌کند. این عنصر همچنین در افزایش مقاومت گیاهان به بیماری‌ها و استرس‌های محیطی مؤثر است (Mc Lean & Watson, 1985). پتاسیم در خاک به چهار شکل شامل: محلول در آب، تبدلی، غیرتبدالی و ساختمانی وجود دارد. پتاسیم محلول و تبدالی به‌طور مستقیم در دسترس گیاهان قرار دارند، در حالی که پتاسیم غیرتبدالی به تدریج و تحت تأثیر فرآیندهای شیمیایی و فعالیت میکروبی خاک به شکل قابل استفاده تبدیل می‌شود. با توجه به اینکه قابلیت استفاده پتاسیم برای گیاهان به فرم شیمیایی و چگونگی توزیع آن در خاک بستگی دارد، اطلاعات دقیق از توزیع مکانی پتاسیم قابل استفاده به کشاورزان و متخصصان خاک کمک می‌کند تا راهبردهای مؤثر و برنامه‌ریزی دقیقی در مدیریت تغذیه گیاهان اتخاذ کنند (Mallarino & Wittry, 2000). در این راستا، روش‌های زمین‌آمار از جمله تخمین‌گرهای غیرپارامتری مانند میانگین متحرک وزنی و روش‌های پارامتری نظیر کریجینگ و کوکریجینگ مورد استفاده قرار می‌گیرند. این روش‌ها به دلیل در نظر گرفتن فاصله بین نقاط نمونه‌برداری، ناهمسانگردی و همبستگی مکانی داده‌ها، از اهمیت ویژه‌ای در تحلیل پراکنش داده‌های خاکی برخوردار بوده و برآوردهای دقیق‌تری از ویژگی مورد مطالعه ارائه می‌دهند (Webster & Oliver, 2007). با این حال، تراکم نمونه‌برداری تأثیر مستقیم بر دقت برآوردهای مکانی دارد.

مطالعات مختلف نشان داده‌اند که استفاده از فاصله‌های زیاد بین نقاط نمونه‌برداری ممکن است باعث از دست رفتن اطلاعات مکانی مهم و کاهش دقت پیش‌بینی‌ها شود (Dash et al., 2024). نمونه‌برداری با تراکم بسیار بالا نیز می‌تواند منجر به هدررفت منابع و افزایش هزینه‌ها شود. بنابراین انتخاب تراکم مناسب نمونه‌برداری با توجه به ساختار مکانی ویژگی‌های خاک و محدودیت‌های عملی، به بهینه‌سازی منابع و افزایش کارایی کمک می‌کند. مالارینو و ویتتری

(Mallarino & Wittry, 1997)، گزارش نمودند که فاصله بیشتر از ۸/۰ هکتار برای بررسی تغییرات مکانی پتاسیم در مزارع مناسب نیست. مطالعاتی در ایالت آیووا نشان داد که استفاده از شبکه‌بندی سیستماتیک با فاصله تقریباً ۱۳۵ متر، برای نمونه‌برداری پتاسیم قابل استفاده مناسب است و می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند (Mallarino, 2001). همچنین، داش و همکاران (Dash et al., 2024)، در مطالعه‌ای گزارش دادند که تراکم‌های نمونه‌برداری کمتر از ۲۴ نمونه در هر ۱۰۰۰ کیلومترمربع منجر به نتایج پرنویز و ناپایدار شدند، اما با افزایش تراکم، نیم‌واریوگرام‌ها پایدارتر شده و برازش مدل بهبود می‌یابد. با این حال، پس از رسیدن به تراکم حدود ۴۸ نمونه در هر ۱۰۰۰ کیلومترمربع، این بهبود کاهش می‌یابد. هان و همکاران (Han et al., 1994)، نتیجه گرفتند که اندازه بهینه واحد نمونه‌برداری به میزان تغییرپذیری مکانی بستگی دارد و بنابراین طرح بهینه نمونه‌برداری در میان مزارع مختلف متفاوت خواهد بود.

با وجود اهمیت پتاسیم قابل استفاده در خاک‌های زراعی، هنوز اطلاعات کافی درباره توزیع مکانی آن و اثر فاصله نمونه‌برداری بر دقت نقشه پتاسیم قابل استفاده در دشت شهرکرد در دسترس نیست. بنابراین، این مطالعه با هدف بررسی تغییرپذیری مکانی پتاسیم قابل استفاده و نقش فاصله نمونه‌برداری بر دقت و کارایی نقشه، در خاک‌های زراعی دشت شهرکرد انجام شد.

مواد و روش‌ها

دشت شهرکرد با کاربری زراعی با مساحت ۲۱۴۰۰ هکتار بین طول‌های جغرافیایی $29^{\circ} 40' 50''$ تا $29^{\circ} 15' 59''$ شرقی و عرض‌های جغرافیایی $32^{\circ} 30' 8''$ تا $32^{\circ} 33' 8''$ شمالی قرار گرفته است. این منطقه دارای اقلیم خشک و نیمه‌خشک با تابستان‌های معتدل و زمستان‌های سرد می‌باشد. به استناد آمار ایستگاه هواشناسی سینوپتیک شهرکرد، میانگین دما در گرم‌ترین ماه سال (تیر ماه) $24/6^{\circ}$ درجه سانتی‌گراد و در سردترین ماه سال (دی ماه) بین 0° تا -4° درجه سانتی‌گراد و متوسط بارش سالانه در این منطقه ۳۰۰ تا ۵۰۰ میلی‌متر می‌باشد. رژیم حرارتی خاک منطقه مزیک و رژیم رطوبتی آن زریک است. همچنین، بخش اعظم دشت شهرکرد به‌واسطه‌ی زمین‌های حاصلخیز، تحت کشت قرار دارد و کاربری عمده‌ی اراضی موجود در این منطقه، کشت آبی گندم، یونجه، ذرت و سیب‌زمینی می‌باشد. در این پژوهش، ۱۲۰ نمونه خاک به‌روش نمونه‌برداری شبکه‌بندی منظم (با استفاده از نرم‌افزار ArcGIS 10.3) با فواصل ۱۳۳۵ متر، از دشت شهرکرد (شکل ۱) از عمق ۳۰-۰ سانتی‌متری برداشته شد. پس از نمونه‌برداری، خاک‌ها به آزمایشگاه منتقل گردید و پس از هواخشک کردن از الک ۲ میلی‌متری عبور داده شدند. پتاسیم قابل استفاده در خاک‌ها با عصاره‌گیر استات آمونیوم ۱ مولار در pH خنثی (Knudsen

(et al., 1982) تعیین شد.


برای دستیابی به خلاصه‌ای از ویژگی‌های آماری پتاسیم قابل استفاده، تجزیه و تحلیل آماری با استفاده از نرم‌افزار Statistica 8 انجام شد. توصیف آماری داده‌ها، شامل حداقل، حداکثر، میانگین، میانه، ضریب تغییرات و چولگی برای متغیر تعیین گردید. همچنین، نرمال بودن توزیع داده‌ها به وسیله هیستوگرام آنها و آزمون کولموگروف-اسمیرنوف بررسی شد.

تجزیه و تحلیل الگوی ساختار تغییرات مکانی پتاسیم قابل استفاده از طریق محاسبات واریوگرام انجام شد. بدین منظور از نرم‌افزار GS+ استفاده گردید. در ابتدا، واریوگرام تجربی پتاسیم قابل استفاده ترسیم و سپس همسانگردی یا ناهمسانگردی آن مورد بررسی قرار گرفت. با توجه به عدم مشاهده ناهمسانگردی، تغییرنمای همه‌جهته برای پتاسیم قابل استفاده رسم گردید. پس از محاسبه واریوگرام تجربی، مدل‌های نظری مختلف بر آن برازش داده شد. سپس، پارامترهای تغییرنما و کلاس وابستگی مکانی متغیر، مشخص گردید. برای تعیین کلاس

وابستگی مکانی، از نسبت واریانس اثر قطعه‌ای به واریانس آستانه استفاده شد که معمولاً به صورت درصدی از واریانس کل بیان می‌شود (Camberdella et al., 1994). اگر این مقدار کمتر از ۲۵ درصد باشد، متغیر دارای وابستگی مکانی قوی و اگر بین ۲۵ تا ۷۵ درصد باشد، وابستگی مکانی متوسط و در صورتی که بیشتر از ۷۵ درصد باشد، وابستگی مکانی مقادیر متغیر مورد نظر ضعیف است. پس از تعیین پارامترهای واریوگرام، اعتبارسنجی مدل‌های تغییرنما از طریق تنظیم پارامترهای اولیه به‌گونه‌ای انجام شد که مدل نهایی بهینه دارای میانگین خطا (ME) نزدیک به صفر و حداقل میانگین مربعات خطا (MSE) باشد. این شاخص‌ها به ترتیب با استفاده از روابط زیر محاسبه شدند:

$$ME = \frac{1}{N} \sum_{i=1}^N [Z(X_i) - Z^*(X_i)]$$

$$MSE = \frac{1}{N} \sum_{i=1}^N [Z(X_i) - Z^*(X_i)]^2$$



شکل ۱- موقعیت نقاط نمونه‌برداری در دشت شهرکرد

Figure 1- Location of sampling points in the Shahrekord Plain

جدول ۱- خلاصه آماری ویژگی‌های اندازه‌گیری شده خاک

Table 1- Summary statistics of measured soil properties

ویژگی خاک	واحد	حداقل	حداکثر	میانگین	میان	انحراف معیار	ضریب تغییرات	چولگی
Soil property	Unit	Minimum	Maximum	Mean	Median	Standard deviation	Coefficient of variation	Skewness
پتاسیم قابل استفاده	میلی گرم بر کیلوگرم	120	812	341	310	130.2	38.2	1.25
Available Potassium	mg kg ⁻¹						(%)	

که، $Z(X_i)$ مقدار مشاهده شده متغیر در موقعیت X_i ، $Z^*(X_i)$ مقدار برآورد شده متغیر مورد نظر در همان موقعیت و N تعداد مشاهدات است. در ادامه، برای تهیه نقشه‌های پتاسیم قابل استفاده، از روش کریجینگ معمولی و نرم‌افزار ArcGIS 10.3 استفاده شد. روش تخمین آماری کریجینگ بر مبنای متحرک وزن‌دار استوار است و به‌عنوان بهترین تخمین‌گر ناربیب شناخته شده است. این تخمین‌گر با استفاده از فرمول ارائه شده توسط کریج (Krige, 1951)، به‌صورت زیر تعریف می‌شود:

$$Z(x) = \sum_{i=1}^n \lambda_i z_i$$

که در آن، λ_i وزن کمیت وابسته به نمونه z_i و Z مقدار متغیر مورد نظر در نمونه z_i است.


نتایج و بحث

خلاصه آماری پتاسیم قابل استفاده در خاک‌ها، در جدول ۱ نشان داده شده است. دامنه تغییرات پتاسیم قابل استفاده در خاک‌ها از ۱۲۰ تا ۸۱۲ میلی‌گرم بر کیلوگرم بوده و میانگین آن ۳۴۱ میلی‌گرم بر کیلوگرم می‌باشد. ضریب تغییرات پتاسیم قابل استفاده در خاک‌ها برابر با ۳۸/۲ درصد است که نشان‌دهنده تغییرپذیری نسبتاً زیاد این عنصر در منطقه مورد مطالعه می‌باشد. ضریب تغییرات بالای پتاسیم قابل استفاده، می‌تواند نشان‌دهنده تنوع در نوع و مقدار کودهای پتاسه مصرف‌شده و همچنین تفاوت در نحوه توزیع آن‌ها در سطح مزرعه باشد (Dobermann, 1994). چولگی داده‌ها برابر با ۱/۲۵ است، که بیانگر توزیع نامتقارن و متمایل به سمت راست داده‌ها می‌باشد؛ به‌منظور بررسی نرمال بودن توزیع داده‌های مربوط به پتاسیم قابل استفاده، از آزمون کولموگروف-اسمیرنوف استفاده شد. پتاسیم قابل استفاده در خاک، پس از تبدیل لگاریتمی داده‌ها دارای توزیع نرمال شد.


چنانچه شدت و چگونگی تغییرپذیری مکانی مقادیر یک متغیر فاقد وابستگی به جهات جغرافیایی باشد، آن تغییرپذیری را همسانگرد و در غیر این صورت، ناهمسانگرد گویند. نتایج در شکل ۲ نشان داده شده است. با توجه به تقارن نسبی واریوگرام سطحی در جهات مختلف، می‌توان نتیجه گرفت که پیوستگی مکانی متغیر مورد بررسی در راسه‌های مختلف مشابه بوده و بنابراین، تغییرپذیری مکانی آن همسانگرد در نظر گرفته شد (Webster & Oliver, 2007).

نیم‌تغییرنمای برازش داده شده بر پتاسیم قابل استفاده در شکل ۳ نشان داده شده است. مدل نمایی بهترین برازش را با داده‌ها داشته و تغییرپذیری مکانی پتاسیم قابل استفاده را در این خاک‌ها توصیف می‌کند. مدل نمایی به‌دلیل افزایش تدریجی نیم‌تغییرنما و نزدیک شدن مجانبی آن به مقدار سیل (آستانه واریانس)، قادر است تغییرپذیری مکانی تدریجی را در فواصل مختلف به‌خوبی توصیف کند (Webster & Oliver, 2007). بلانچت و همکاران (Blanchet et al., 2017) گزارش نمودند که پتاسیم قابل استفاده در خاک‌های کانتون فربورگ در سوئیس با مدل نمایی توصیف شد. همچنین، نتایج شعبانی و دلاور (Shabani & Delavar, 2016)، نشان داد که مدل نمایی بهترین برازش را برای پتاسیم قابل استفاده خاک داشته است.

جدول ۲، نتایج پارامترهای تغییرنمای پتاسیم قابل استفاده خاک را نشان می‌دهد. یکی از این پارامترها، اثر قطعه‌ای است که ناشی از خطاهای نمونه‌برداری صحرائی، اندازه‌گیری‌های آزمایشگاهی یا تغییرپذیری مکانی در فواصل کوتاه‌تر از کوچک‌ترین فاصله بین نقاط نمونه‌برداری می‌باشد، این اثر، ۰/۱۰۸ و دامنه تأثیر آن، ۵۳۳۰۰ متر می‌باشد. ایزاکس و سریواستاوا (Isaaks & Srivastava, 1989)، بیان نمودند که فاصله نمونه‌برداری باید ۰/۲۵ برابر دامنه تغییرپذیری مکانی باشد تا شبکه نمونه‌برداری بتواند تغییرات مکانی را به‌طور مؤثر پیش‌بینی کند. براین‌اساس، با توجه به دامنه مؤثر ۵۳۳۰۰ متر، فاصله نمونه‌برداری مناسب حداکثر ۱۳۳۲۵ متر خواهد بود. از آنجاکه فاصله نمونه‌برداری واقعی در این پژوهش، ۱۳۳۵ متر است که تقریباً ۱۰ برابر کمتر از مقدار توصیه‌شده می‌باشد، بنابراین، تراکم نمونه‌برداری کافی است و انتظار می‌رود تغییرات مکانی پتاسیم قابل استفاده با دقت بالاتری برآورد شوند.



شکل ۲- تغییرنمای سطحی پتاسیم قابل استفاده خاک
Figure 2- Surface map of soil available potassium



شکل ۳- واریوگرام‌های تجربی به همراه مدل نظری برازش داده شده پتاسیم قابل استفاده خاک
Figure 3- Experimental variograms with fitted theoretical models for soil available potassium

تغییرات مدیریتی شدید خاک نظیر الگوهای متفاوت مصرف کود، تناوب زراعی و سابقه بهره‌برداری زمین نیز قرار گیرد. این عوامل موجب افزایش تغییرپذیری در فواصل کوتاه و تضعیف الگوی مکانی منظم می‌شوند (Mallarino, 1996 Sen et al., 2007).

وانگ و همکاران (Wang et al., 2009) تغییرپذیری مکانی و عوامل مؤثر بر نیتروژن، فسفر، پتاسیم و ماده آلی خاک در زمین‌های زراعی شمال‌شرق چین را بررسی کردند. در این مطالعه، ۳۵۲ نمونه به روش تصادفی از عمق ۲۰-۰ سانتی‌متر و با مساحت ۳۴۳۵ کیلومتر

شکل تقریباً خطی واریوگرام نمایی ناشی از آن است که در این مدل، نیم‌واریانس در فواصل کوتاه نسبت به دامنه تغییرپذیری تقریباً رابطه‌ای خطی با فاصله دارد (Isaaks & Srivastava, 1989). بنابراین، به دلیل کوچک بودن فاصله نمونه‌برداری نسبت به دامنه مؤثر، بیشتر داده‌ها در بخش ابتدایی تابع نمایی قرار گرفته‌اند و واریوگرام تجربی به صورت تقریباً خطی مشاهده شده است (Webster & Oliver, 2007). با این حال، باید توجه داشت که شکل خطی واریوگرام می‌تواند علاوه بر محدودیت‌های ناشی از ساختار مدل، تحت تأثیر

مربع جمع‌آوری شد. نتایج نشان داد که داده‌های لگاریتمی نیتروژن، فسفر، پتاسیم و ماده آلی خاک از توزیع نرمال پیروی می‌کنند. واریوگرام تجربی داده‌های لگاریتمی ماده آلی، نیتروژن کل و فسفر قابل استخراج با مدل نمایی برازش داده شد، در حالی که پتاسیم قابل استخراج با مدل کروی برازش شد. دامنه مؤثر نیتروژن، فسفر، پتاسیم و ماده آلی خاک به ترتیب ۲۱۱، ۴۹/۳، ۲/۹ و ۱۲۳/۱ کیلومتر بود.

رادوجاج و همکاران (Radocaj et al., 2021)، به بررسی تأثیر تراکم نمونه‌برداری خاک بر دقت درون‌یابی پتاسیم خاک در اراضی زراعی به وسعت ۸۲۳/۴ هکتار با ۱۶۰ نمونه خاک به روش تصادفی طبقه‌بندی شده در شهرستان اوسیک-بارانیا کرواسی، پرداختند. نتایج نشان داد که تراکم نمونه‌برداری بیشترین تأثیر را بر دقت درون‌یابی دارد و کاهش تعداد نمونه‌ها کمتر از ۳۷/۵ درصد از کل مجموعه، باعث کاهش قابل توجه دقت شد. ژانگ و همکاران (Zhang et al., 2024)، به بررسی تغییرات مکانی و زمانی پتاسیم قابل استفاده در منطقه کارستی جنوب‌غربی چین پرداخته‌اند. آن‌ها با استفاده از تحلیل نیم‌واریوگرام، به شناسایی عوامل مؤثر بر تغییرات پتاسیم قابل استفاده و تعیین فاصله‌های نمونه‌برداری مناسب پرداخته‌اند. نتایج نشان می‌دهند که فاصله نمونه‌برداری باید کمتر از ۵ کیلومتر باشد تا تغییرات پتاسیم قابل استفاده به‌طور مؤثر شبیه‌سازی شوند.

میزان وابستگی متغیرها، با استفاده از نسبت اثر قطعه‌ای به حد آستانه به‌دست می‌آید که مقادیر کوچکتر از ۲۵ درصد نشان‌دهنده‌ی وابستگی مکانی قوی، ۲۵ تا ۷۵ درصد متوسط و بیش از ۷۵ درصد ضعیف می‌باشد (Camberdella et al., 1994). براین اساس، درصد وابستگی مکانی برای متغیر مورد مطالعه، ۵۰/۲ درصد است که در کلاس وابستگی مکانی متوسط قرار می‌گیرد. قرار گرفتن درصد وابستگی مکانی پتاسیم قابل استفاده در کلاس متوسط نشان‌دهنده‌ی تأثیر همزمان عوامل درونی، مانند؛ ویژگی‌های فیزیکوشیمیایی خاک و عوامل بیرونی نظیر فعالیت‌های مدیریتی (نحوه کوددهی، الگوی زراعی، تردد ماشین‌آلات) بر پراکنش مکانی این ویژگی می‌باشد. رضا و همکاران (Reza et al., 2019)، گزارش کردند که تحلیل‌های ژئواستاتیستیک نشان داد برای پتاسیم مدل نمایی بهترین برازش را

دارد و این عنصر در خاک از وابستگی مکانی ضعیفی برخوردار است. همچنین، نقشه توزیع مکانی پتاسیم بیانگر الگوی پراکندگی ناهمگون بوده و نشان می‌دهد که برای مدیریت کود پتاسیم در کشاورزی دقیق، لازم است نرخ مصرف کود متناسب با تغییرات مکانی این عنصر تنظیم شود. نتایج وانگ و همکاران (Wang et al., 2009)، نشان داد که نیتروژن کل، فسفر قابل استخراج و پتاسیم قابل استخراج دارای وابستگی مکانی متوسط بودند، در حالی که مواد آلی خاک وابستگی مکانی ضعیفی داشت.


میانگین خطای تخمین لگاریتم پتاسیم قابل استفاده برابر با ۰/۰۰۸ -، میانگین مربعات خطای تخمین برابر با، ۰/۰۱۱ و ریشه میانگین مربعات خطا برابر با ۰/۱۰۵ بود که بیانگر ناریب بودن و دقت بالای تخمین می‌باشد. نقشه پهنه‌بندی پتاسیم قابل استفاده و خطای پیش‌بینی در شکل ۴ نشان داده شده است. نقشه پهنه‌بندی پتاسیم قابل استفاده نشان داد که ۴۹۹۴ هکتار از اراضی دارای پتاسیم قابل استفاده بین ۱۲۰ تا ۲۵۰ میلی‌گرم بر کیلوگرم، ۸۰۲۵ هکتار از اراضی بین ۲۵۰ تا ۳۵۰ میلی‌گرم بر کیلوگرم، ۵۱۷۱ هکتار از اراضی بین ۳۵۰ تا ۴۵۰ میلی‌گرم بر کیلوگرم، ۱۶۰۵ هکتار از اراضی بین ۴۵۰ تا ۵۵۰ و ۱۶۰۵ هکتار از اراضی بین ۵۵۰ تا ۸۰۰ میلی‌گرم بر کیلوگرم می‌باشند. اراضی با مقادیر کمتر از ۲۵۰ میلی‌گرم بر کیلوگرم یا بیش از ۴۵۰ میلی‌گرم بر کیلوگرم در بخش‌های کوچک و پراکنده‌ای از منطقه دیده شد. این پراکنش موضعی بیانگر تغییرپذیری محلی خاک و احتمالاً بازتابی از تأثیر مدیریت زراعی بر وضعیت پتاسیم خاک است.

نقشه کریجینگ پتاسیم قابل استفاده در مقیاس ۱:۱۸۵۰۰۰ برای شناسایی الگوهای کلی مکانی و پهنه‌بندی‌های وسیع مفید است، اما دقت آن برای توصیه‌های مزرعه‌ای محدود بوده و برای کاربردهای دقیق‌تر، نیاز به افزایش تراکم نمونه‌برداری و استفاده از مقیاس‌های بزرگ‌تر است. نتایج بیانگر اهمیت مطالعات تفصیلی و تراکم بالای نمونه برداری (فواصل کم نمونه‌ها) در تولید و نقشه‌های مدیریت پذیر خاک با مقیاس بزرگ است.

جدول ۲- پارامترهای تغییرنمای پتاسیم قابل استفاده خاک

Table 2- Parameters of spatial variability of soil available potassium

ویژگی خاک	اثر قطعه‌ای	دامنه تأثیر	حد آستانه	مدل	ضریب وابستگی	ضریب تبیین	مجموع مربعات باقی‌مانده‌ها	کلاس وابستگی مکانی
Soil property	Nugget	Range (m)	Sill	Function	Dependency coefficient (%)	r ²	RSS	Spatial Dependency Class
لگاریتم پتاسیم قابل استفاده	0.108	53300	0.218	نمایی	50.2	0.48	2.58×10 ⁻⁴	متوسط
Available Potassium				Exponential				Medium



(الف) (ب)

شکل ۴- نقشه پهنه‌بندی پتاسیم قابل استفاده (الف) و خطای تخمین پتاسیم قابل استفاده (ب)

Figure 4- Zonation map of soil available potassium (a) and estimation error of available potassium (b)

نتیجه‌گیری

عامل اصلی تعیین‌کننده اثربخشی تراکم نمونه‌برداری خاک، ناهمگنی ذاتی خاک است که خود متأثر از مدیریت محصول و حاصلخیزی خاک است. با این وجود، در مزارع نسبتاً همگن، تعداد کمتری نمونه برای ارزیابی دقیق ویژگی‌های خاک لازم است، در حالی که در محیط‌های ناهمگن‌تر، نمونه‌برداری با تراکم بالاتر برای بازنمایی صحیح ویژگی‌های خاک ضروری است. با وجود اینکه تراکم نمونه‌برداری انتخاب شده کمتر از آن است که تمام جزئیات تغییرات مکانی پتاسیم قابل استفاده در دشت شهرکرد را ثبت کند، نقشه‌های

حاصل از روش کریجینگ دقت قابل قبولی دارند. این امر علی‌رغم افزایش تغییرپذیری در فواصل کوتاه و کاهش الگوی مکانی منظم ناشی از تغییرات مدیریتی شدید خاک، مانند الگوهای متفاوت مصرف کود، تناوب زراعی و سابقه بهره‌برداری، حاصل شده است؛ بنابراین، حتی با تراکم نمونه کمتر، مدل کریجینگ توانسته است الگوی کلی پتاسیم قابل استفاده را با دقت قابل قبول پیش‌بینی کند. با این حال، برای مطالعات آینده توصیه می‌شود اثر تراکم نمونه‌برداری در فواصل کمتر مورد بررسی قرار گیرد تا حساسیت مدل و دقت نقشه‌ها در مقیاس‌های بزرگ‌تر مشخص شود.

References

1. Blanchet, G., Libohova, Z., Joost, S., Rossier, N., Schneider, A., Jeangros, B., & Sinaj, S. (2017). Spatial variability of potassium in agricultural soils of the canton of Fribourg, Switzerland. *Geoderma*, 290, 107-121. <https://doi.org/10.1016/j.geoderma.2016.12.002>
2. Camberdella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., & Konopka, A.E. (1994). Field scale variability of soil properties in central Iowa soils. *Soil Science Society of America Journal*, 58, 1501-1511.
3. Dobermann, A. (1994). Factors causing field variation of direct-seeded flooded rice. *Geoderma*, 62(1-3), 125-150.
4. Dash, P.K., Miller, B.A., Panigrahi, N., & Mishra, A. (2024). Exploring the effect of sampling density on spatial prediction with spatial interpolation of multiple soil nutrients at a regional scale. *Land*, 13(10), 1615. <https://doi.org/10.3390/land13101615>
5. Han, S., Hummel, J.W., Goering, C.E., & Cahn, M.D. (1994). Cell size selection for site-specific crop management. *Transactions of the ASAE*, 37(1), 19-26.

6. Isaaks, E.H., & Srivastava, R.M. (1989). *Applied geostatistics*. New York: Oxford University Press, 561 p.
7. Knudsen, D., Peterson, G.A., & Pratt, P.F. (1982). Lithium, sodium and potassium. *Methods of Soil Analysis, Part 2: Chemical and Microbiological Properties*. (2nd ed.). American Society of Agronomy and Soil Science Society of America, Madison, Wisconsin. pp. 225-246.
8. Krige, D.G. (1951). A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Southern African Institute of Mining and Metallurgy*, 52(6), 119-139.
9. Li, J., & Heap, A.D. (2008). A review of spatial interpolation methods for environmental scientists.
10. Mallarino, A.P. (1996). Spatial variability patterns of phosphorus and potassium in no-tilled soils for two sampling scales. *Soil Science Society of America Journal*, 60(5), 1473-1481.
11. Mallarino, A., & Wittry, D. (1997). Use of DGPS, yield monitors, soil testing, and variable rate technology to improve phosphorus and potassium management.
12. Mallarino, A.P., & Wittry, D.J. (2000). Identifying cost-effective soil sampling schemes for variable-rate fertilization and liming.
13. Mallarino, A. (2001). Management zones soil sampling: A better alternative to grid and soil type sampling?
14. Mc Lean, E.O., & Watson, M.E. (1985). Soil measurements of plant-available potassium. *Potassium in Agriculture*, 277-308.
15. Reza, S.K., Ray, P., Ramachandran, S., Bandyopadhyay, S., Mukhopadhyay, S., Sah, K.D., ... & Ray, S.K. (2019). Spatial distribution of soil nitrogen, phosphorus and potassium contents and stocks in humid subtropical North-eastern India. *Journal of the Indian Society of Soil Science*, 67(1), 12-20. <https://doi.org/10.5958/0974-0228.2019.00002.1>
16. Radocaj, D., Jug, I., Vukadinovic, V., Jurisic, M., & Gasparovic, M. (2021). The effect of soil sampling density and spatial autocorrelation on interpolation accuracy of chemical soil properties in arable cropland. *Agronomy*, 11(12), 2430. <https://doi.org/10.3390/agronomy11122430>
17. Sahrawat, K.L., Rego, T.J., Wani, S.P., & Pardhasaradhi, G. (2008). Stretching soil sampling to watershed: Evaluation of soil-test parameters in a semi-arid tropical watershed. *Communications in Soil Science and Plant Analysis*, 39(19-20), 2950-2960. <https://doi.org/10.1080/00103620802432857>
18. Sen, P., Majumdar, K., & Sulewski, G. (2007). Spatial variability in available nutrient status in an intensively cultivated village. *Better crops*, 91(2), 10-11.
19. Shabani, H., & Delavar, M.R. (2016). Assessment of macronutrients spatial variability in the lands of University of Zanjan. *Journal of Agriculture*, 110, 75-82. (In Persian with English abstract). <https://doi.org/10.22092/aj.2016.109332>
20. Wang, Z.M., Song, K.S., Zhang, B., Liu, D.W., Li, X.Y., Ren, C.Y., ... & Zhang, C.H. (2009). Spatial variability and affecting factors of soil nutrients in croplands of Northeast China: a case study in Dehui County. *Plant Soil Environment*, 55(3), 110-120.
21. Webster, R., & Oliver, M.A. (2007). *Geostatistics for environmental scientists*. John Wiley & Sons.
22. Zhang, W., Zhang, Y., Zhang, X., Wu, W., & Liu, H. (2024). The spatiotemporal variability of soil available phosphorus and potassium in Karst Region: The crucial role of socio-geographical factors. *Land*, 13(6), 882. <https://doi.org/10.3390/land13060882>

Agroclimatic Zoning of Iran Based on Barley (*Hordeum vulgare* L.) Planting Date and Length of Growing Period Using Advanced Spatial Analysis Methods

Kh. Ahmadaali^{1*}, M. Kazempour¹, E. Fazli², A. Liaghat¹, I. Hajirad¹

1- Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

(*- Corresponding Author Email: khahmadauli@ut.ac.ir)

2- Soil and Water Research Institute, Agricultural Research Education and Extension Organization (AREEO), Karaj, Iran

Received: 23 December 2025
Revised: 23 February 2026
Accepted: 16 March 2026
Available Online: 16 March 2026

How to cite this article:

Ahmadaali, Kh., Kazempour, M., Fazli, E., Liaghat, A., & Hajirad, I. (2026). Agroclimatic zoning of Iran based on barley (*Hordeum vulgare* L.) planting date and length of growing period using advanced spatial analysis methods. *Journal of Water and Soil*, 39(6), 539-552. (In Persian with English abstract).
<https://doi.org/10.22067/jsw.2026.97155.1516>

Introduction

Increasing pressure on limited water resources, pronounced climatic variability, and the growing demand for agricultural production have made accurate agroclimatic assessment an essential component of sustainable agriculture in Iran. Identifying homogeneous agroclimatic zones enables more efficient resource management, optimized cropping calendars, and reduced production risk under variable environmental conditions. Agro-ecological zoning (AEZ) provides a scientific framework to integrate climatic, topographic, and crop phenological factors in order to delineate areas with similar production potential. Barley (*Hordeum vulgare* L.), as one of Iran's major cereal crops, plays a vital role in food security, livestock feed supply, and agricultural livelihoods. Barley yield and stability are highly sensitive to planting date and length of the growing period, both of which are directly influenced by climatic gradients, elevation, and rainfall patterns. Despite the importance of these parameters, national-scale agroclimatic zoning of barley based explicitly on planting date and growing period has received limited attention. Therefore, this study aimed to delineate agroclimatic zones for barley cultivation across Iran using advanced spatial interpolation and clustering techniques, providing a decision-support tool for sustainable crop planning.

Materials and Methods

This study adopted a spatial-analytical approach at the national scale of Iran. Point-based data on barley planting date and length of the growing period were obtained from the national Water Requirement System and related agroclimatic databases, covering approximately 790 stations distributed across the country. These data represent long-term average conditions relevant to barley phenology. To transform discrete point data into continuous spatial surfaces, the Empirical Bayesian Kriging Regression Prediction (EBK-RP) method was employed. This geostatistical technique combines regression modeling with Empirical Bayesian Kriging, allowing automatic estimation of semivariogram parameters and improved uncertainty handling, particularly in regions with sparse observations. Elevation derived from a digital elevation model (DEM) was incorporated as a covariate to enhance spatial prediction accuracy. The resulting raster layers for planting date and growing period length were then classified using the K-means clustering algorithm, a widely used unsupervised machine learning technique. The optimal number of clusters for each variable was determined using the elbow method based on within-cluster sum of squares (WCSS). Three clusters were identified for planting date and four clusters for growing period length. Finally, the classified layers were overlaid and combined to generate homogeneous agroclimatic zones for barley cultivation. To improve spatial coherence and reduce classification noise, focal statistics with a majority



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.97155.1516>

filter were applied.

Results and Discussion

The spatial distribution of barley planting dates and growing period lengths exhibited strong correspondence with Iran's climatic and altitudinal gradients. Early planting dates were predominantly observed in the humid Caspian coastal region and parts of western and northwestern Iran, where higher precipitation, moderate temperatures, and lower frost risk prevail. In contrast, delayed planting was common in the arid and semi-arid central, eastern, and southeastern regions, reflecting dependence on late and irregular rainfall events. The length of the growing period showed an inverse relationship with temperature and aridity. Longer growing seasons (approximately 230–300 days) were identified in high-altitude and humid regions such as the Caspian lowlands, Alborz and Zagros mountain ranges, and western provinces. Shorter growing periods (around 120–170 days) characterized the hot, dry southern and eastern regions, where high temperatures and moisture stress accelerate crop development and shorten phenological stages. The integration of planting date and growing period classes resulted in twelve agroclimatic zones for barley cultivation. Among these, zones characterized by early to intermediate planting and moderate to long growing periods demonstrated the highest suitability for barley production. These zones are mainly located in northern, western, and parts of northwestern Iran, where climatic conditions provide more stable growth environments. Conversely, zones with late planting and short growing periods, largely distributed across central, eastern, and southeastern Iran, were identified as high-risk areas with significant climatic limitations for barley cultivation. These findings highlight the dominant role of climate, elevation, and moisture availability in shaping barley phenology and production potential. The spatial patterns observed are consistent with previous agro-ecological zoning studies in Iran and other semi-arid regions, reinforcing the reliability of the applied methodology.

Conclusion

This study demonstrated that integrating advanced geostatistical modeling (EBK Regression Prediction) with unsupervised clustering (K-means and elbow method) provides a robust framework for national-scale agroclimatic zoning of barley. The results clearly indicate that barley planting date and length of the growing period in Iran are strongly controlled by climatic–altitudinal gradients. Only a limited portion of the country—primarily humid and semi-humid northern and western regions—offers high and stable potential for sustainable barley production, while large arid and semi-arid areas face substantial climatic constraints. The derived agroclimatic zones can serve as a strategic decision-support tool for policymakers, planners, and extension services. They facilitate optimized cropping calendars, targeted selection of barley cultivars, improved water resource management, and risk reduction under climate variability. Ultimately, applying such zoning-based approaches can enhance productivity, promote sustainable land use, and support long-term food security in Iran.

Keywords: Agro-ecological zones, Barley, Elbow method, Empirical Bayesian Kriging, K-Means, Regression prediction

پهنه‌بندی اگروکلیمایی ایران بر اساس تاریخ کاشت و طول دوره رشد محصول جو (*Hordeum vulgare* L.) با استفاده از روش‌های پیشرفته تحلیل فضایی

خالد احمدآلی^۱ * - مینا کاظم‌پور^۱ - عرفان فضلی^۲ - عبدالمجید لیاقت^۱ - ایمان حاجی‌راد^۱

تاریخ دریافت: ۱۴۰۴/۱۰/۰۲

تاریخ پذیرش: ۱۴۰۴/۱۲/۲۵

چکیده

کاهش منابع آب، تغییرات شدید اقلیمی و نیاز به بهره‌وری آب بالاتر، اهمیت ارزیابی قابلیت‌های اگروکلیمایی در کشاورزی ایران را افزایش می‌دهد. این پژوهش با تحلیل داده‌های ۷۹۰ ایستگاه، مناطق اگروکلیمایی جو را بر اساس تاریخ کاشت و طول دوره رشد با استفاده از کریجینگ بیزین تجربی با پیش‌بینی رگرسیون و الگوریتم K-Means شناسایی کرد. در این مطالعه، داده‌های اقلیمی و فنولوژیک ۱۷ ساله (۱۳۸۵ تا ۱۴۰۲) برای اطمینان از نمایندگی تغییرات اقلیمی اخیر استفاده شد. تعداد خوشه‌های بهینه تعیین شده با روش آرنج به این صورت بود که سه کلاس برای تاریخ کاشت و چهار کلاس برای طول دوره رشد استخراج گردید. برای ساده‌سازی، هر منطقه زراعی با کدی ترکیبی از کلاس تاریخ کاشت و طول دوره رشد مشخص شده است (مثلاً کد ۲۱ نشان‌دهنده کلاس دوم تاریخ کاشت و کلاس اول طول دوره رشد است) و این کدگذاری صرفاً برای دسته‌بندی و مقایسه مناطق است. ترکیب این دو منجر به تولید ۱۲ کلاس نهایی همگن زراعی برای محصول جو شد. نتایج نشان داد که توزیع زمان کاشت و طول دوره رشد، تابع مستقیم گرادیان اقلیمی-ارتفاعی ایران است. نواحی مرطوب خزری و غرب کشور در کلاس‌های ۱۳ (کاشت زودهنگام-دوره رشد طولانی)، ۱۴ (کاشت زودهنگام-دوره رشد بسیار طولانی)، ۲۳ (کاشت میان‌رس-دوره رشد طولانی)، ۲۴ (کاشت میان‌رس-دوره رشد بسیار طولانی) قرار گرفته که دارای کاشت زودهنگام و فصل رشدی طولانی هستند. مناطق خشک و نیمه‌خشک مرکزی، شرقی و جنوب‌شرقی عمدتاً در کلاس‌های ۳۱ تا ۳۳ قرار دارند که کاشت دیر هنگام و دوره رشد کوتاه را نشان می‌دهد. مناسب‌ترین مناطق برای کشت جو در کلاس‌های ۱۱، ۱۲، ۱۳ و ۲۲ با رطوبت و دمای متعادل و فصل رشد پایدار هستند، در حالی که کلاس‌های ۳۳ و ۳۴ بیشترین محدودیت اقلیمی و ریسک را دارند. این نتایج می‌تواند سیاست‌گذاران را در شناسایی مناطق کم‌بازده راهنمایی کند.

واژه‌های کلیدی: جو، روش آرنج، زون‌بندی کشاورزی-اکولوژیکی، K-Means، کریجینگ بیزین تجربی با پیش‌بینی رگرسیون

مقدمه

مدیریت بهینه آب و سایر نهاده‌ها را ارتقا داد (Hajirad et al., 2025). شناسایی و تفکیک نواحی مختلف کشور بر اساس ویژگی‌های اقلیمی و نیازهای فنولوژیک محصولات زراعی، یکی از رویکردهای کلیدی برای بهبود مدیریت منابع و افزایش کارایی تولید است (Hajirad et al., 2021). پهنه‌بندی کشاورزی-اکولوژیکی یا اگروکلیمایی^۳ (AEZ) این امکان را فراهم می‌کند که تاریخ کاشت، نیاز حرارتی و طول دوره

با افزایش جمعیت و رشد تقاضا برای تولید غذا، فشار فزاینده‌ای بر منابع مؤثر در تولید، به‌ویژه آب و خاک، وارد می‌شود. در این شرایط، شناخت و تفکیک مناطق همگن زراعی به‌عنوان واحدهای برنامه‌ریزی اهمیت ویژه‌ای دارد، زیرا تنها از طریق آن می‌توان بهره‌وری منابع و

۱- گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

(*)- نویسنده مسئول: Email: khahmadauli@ut.ac.ir

۲- بخش تحقیقات شناسایی خاک و ارزیابی اراضی، مؤسسه تحقیقات خاک و آب، سازمان تحقیقات آموزش و ترویج کشاورزی، کرج، ایران

رشد هر محصول در مناطق مختلف به صورت علمی و دقیق تعیین شود و از این طریق مدیریت بهینه تر منابع و افزایش پایداری تولید فراهم آید. ایران نیز با اقلیم خشک و نیمه خشک، محدودیت منابع آب و خاک، و نوسانات اقلیمی گسترده، بیش از بسیاری از مناطق جهان با این چالش ها مواجه است. از این رو، به روشنی آشکار شده است که ارتقای تولیدات کشاورزی در آینده نه تنها باید با بهره گیری بهینه از نهاده ها صورت گیرد، بلکه باید هم زمان با حفاظت و تقویت پایه های طبیعی تولید همراه باشد تا پایداری درازمدت سیستم های زراعی تضمین شود (Neamatollahi et al., 2012; Taati & Sarmadian, 2015).

در گذشته، تمرکز اصلی پژوهش های کشاورزی عمدتاً بر بررسی روابط عمودی و تک بعدی در مقیاس های محدود بوده است؛ به گونه ای که گیاه، آب، خاک و اقلیم به صورت جداگانه و در واحدهای نسبتاً همگن مورد مطالعه قرار می گرفتند. اما امروزه مدیریت صحیح منابع طبیعی و دستیابی به تولید پایدار مستلزم نگرشی افقی و گسترده تر است که در آن تعاملات پیچیده عناصر زیستی، فیزیکی و اجتماعی-اقتصادی در مقیاس های وسیع تر مکانی و زمانی تحلیل شود (Sivakumar & Valentin, 1997; Yu et al., 2022). ابزارهای نوین از جمله سیستم های اطلاعات جغرافیایی (GIS) و روش های مدل سازی فضایی، امکان انجام تحلیل های یکپارچه و گسترده را فراهم کرده اند و رویکرد AEZ به عنوان یکی از کارآمدترین چارچوب ها برای این نوع ارزیابی مطرح است (Fischer et al., 2006; Van Wart et al., 2013). مفهوم AEZ ابتدا در دهه ۱۹۷۰ توسط سازمان غذا و کشاورزی ملل متحد (FAO) ارائه شد (Dadrasi et al., 2023). این رویکرد به عنوان یک ابزار تحلیلی و عملی، زمینه ای یکپارچه برای تعریف زون ها فراهم می کند و ویژگی های اقلیمی و اکولوژیک مؤثر بر تولید را هم به صورت کمی و قابل مقایسه بررسی می کند و هم محدودیت ها و فرصت های منابع را بر اساس ویژگی های اکوفیزیولوژیکی محصولات، شرایط خاک و اقلیم ارزیابی می نماید. برای دستیابی به تولید بهینه و پایدار کشاورزی، لازم است شرایط محیطی و اقلیمی از نظر توانایی ها و محدودیت ها مشخص شوند. از جمله مزایای پهنه بندی AEZ می توان به شناسایی مناطق مشابه یا متفاوت، تسهیل انتقال فناوری و نتایج تحقیقات، تعیین دوره های تنش محصول و امکان ارائه راه حل واحد برای حل چالش ها در هر AEZ اشاره کرد؛ به گونه ای که اگر در مرکز AEZ ها، هر تحقیق و پژوهشی ارائه شود نتایج آن قابل تعمیم به کل سطح AEZ بوده و می توان در هر AEZ سیاست گذاری واحد داشت.

اگر وکلیم در حقیقت تلاقی ویژگی های اقلیمی و اکولوژیک مؤثر بر رشد، توسعه و عملکرد یک گیاه یا سیستم زراعی است. از آنجاکه دما، بارندگی، تبخیر-تعرق، طول فصل رشد و زمان بندی رخدادهای اقلیمی در نقاط مختلف کشور و در سال های مختلف تفاوت چشمگیری

دارد، گونه ها و ارقام زراعی نیز بسته به شرایط مکانی و زمانی، نیازمند مدیریت و تقویم زراعی متفاوتی هستند (Dadrasi et al., 2023; Aktaş & Gökdere, 2025). در ایران، این ناهمگنی اقلیمی بسیار برجسته است؛ به طوری که از اقلیم فراخشک در شرق کشور تا اقلیم مرطوب خزری در شمال و اقلیم سرد کوهستانی در غرب، طیف وسیعی از محیط های تولیدی وجود دارد که هر یک امکانات و محدودیت های خاص خود را دارند (Neamatollahi et al., 2012; Taati & Sarmadian, 2015). در ایران، مطالعات پهنه بندی برای گندم، چغندر قند و ذرت در دشت مشهد (Neamatollahi et al., 2012) و همچنین ارزیابی اراضی برای جو و گندم آبی و دیم در منطقه آبیک نشان داده اند که AEZ ابزار مؤثری برای طبقه بندی محیطی، تعیین مناطق مناسب و نامناسب کشت و ارائه راهبردهای مدیریتی است (Taati & Sarmadian, 2015). این پهنه بندی به پژوهشگران امکان می دهد تا تناسب مناطق مختلف برای محصولات خاص و زمان های بهینه کاشت و برداشت را پیش بینی کنند و پارامترهای کلیدی مانند درجه-روز-رشد (GDD)^۱، فصلی بودن دما و شاخص خشکی را برای تعیین رشد، عملکرد و دسترس پذیری آب محصول تحلیل نمایند.

محصول جو، به عنوان یکی از مهم ترین غلات کشور، از دیرباز نقش حیاتی در تأمین علوفه، خوراک دام و حتی امنیت غذایی مناطق مختلف ایران داشته است. با این حال، نیازهای حرارتی، آبی و فیزیولوژیک جو، و حساسیت آن به زمان کاشت و طول دوره رشد، موجب شده است که عملکرد این محصول در مناطق مختلف کشور تفاوت قابل توجهی داشته باشد (Bagheri, 2025). شناخت دقیق مناطق AEZ مناسب برای کشت جو و تعیین تاریخ های بهینه کاشت، طول دوره رشد و میزان نیاز آبی آن، می تواند نقش تعیین کننده ای در افزایش بهره وری و کاهش ریسک های ناشی از تغییرات اقلیمی ایفا کند (Van Wart et al., 2013; Asante et al., 2019). AEZ امکان دسترسی به اطلاعات محیطی و خاکی در مقیاس وسیع را برای برنامه ریزی دقیق کشت و کاهش ریسک فراهم می کند. نتیجه مطالعات مختلف نشان داده که AEZ برای شناسایی محدودیت های اقلیمی، خاک، آب و تعیین مناطق پشتیبان تولید و ارائه استراتژی های افزایش تولید، کاربرد دارد. تعیین AEZ در هر کشوری کمک شایانی به برنامه ریزی ملی نموده و می تواند منجر به بهره وری بالاتر و مدیریت بهینه منابع شود.

تعیین زون های اگروکلیمایی، این امکان را فراهم می کند که ویژگی های اقلیمی و زیست محیطی هر منطقه به صورت کمی و مقایسه پذیر ارزیابی شود و نیازهای محصول با ظرفیت های محیطی تطبیق داده شود. این رویکرد علاوه بر تعیین مناسب ترین زمان کاشت، طول فصل رشد، و نیاز آبی، می تواند مناطق کمتر مساعد را که از نظر محیطی دچار محدودیت هستند نیز شناسایی کرده و اولویت های

برگی و سفیدک پودری در مراحل حساس می‌شود. تاریخ کشت، زمان مناسب برای کاشت یک محصول زراعی در یک منطقه خاص است که بر اساس شرایط آب‌وهوایی، نیازهای حرارتی و نوری گیاه، رطوبت خاک و تقویم زراعی تعیین می‌شود. عواملی نظیر: دمای لازم برای جوانه‌زنی، احتمال وقوع یخبندان یا گرمای شدید، میزان بارندگی و رطوبت خاک، طول روز و نیاز نوری گیاه و نوع رقم محصول در تعیین تاریخ کشت آن موثر هستند. طول دوره رشد، مدت زمانی است که گیاه از مرحله کاشت تا برداشت طی می‌کند که شامل مراحل جوانه‌زنی، رشد رویشی، گلدهی، تشکیل دانه و مرحله رسیدگی است. طول دوره رشد می‌تواند بر اساس نوع گیاه و شرایط محیطی متفاوت باشد (Porter & Semenov, 2005; Hatfield & Prueger, 2015; Bhagat et al., 2023). طول دوره رشد در این پژوهش به صورت کل دوره فنولوژیک محصول از تاریخ کاشت تا رسیدگی فیزیولوژیک و برداشت تعریف شده است و شامل تمامی مراحل رشد گیاه اعم از جوانه‌زنی، استقرار، رشد رویشی، ساقه‌دهی، خوشه‌دهی، گلدهی، تشکیل و پرشدن دانه و رسیدگی نهایی می‌باشد. بنابراین، منظور از طول دوره رشد در این مطالعه صرفاً دوره رشد رویشی نبوده، بلکه کل چرخه رشدی محصول تا زمان برداشت را دربر می‌گیرد.

این مطالعه از نوع مطالعات تحلیلی-مکانی^۲ است که با هدف پهنه‌بندی مناطق زراعی محصول جو در سطح ایران بر اساس شاخص‌های تاریخ شروع کشت و طول دوره رشد انجام شد. روند کلی تحقیق شامل تهیه بانک داده مربوط به تاریخ کشت و طول دوره رشد مستخرج از سامانه نیازآب (Ebrahimi-Pak et al., 2022)، مدل‌سازی مکانی، خوشه‌بندی آماری، ترکیب داده‌های رستری و نرم‌سازی نهایی بود. داده‌های اولیه شامل داده‌های نقطه‌ای ثانویه تاریخ شروع کشت و طول دوره رشد برای محصول جو در ۷۹۳ ایستگاه در سطح کشور بود. برای پردازش و تحلیل داده‌ها، از نرم‌افزار ArcGIS Pro نسخه ۴٫۳ جهت مدیریت داده‌های رستری و تحلیل‌های فضایی و از نرم‌افزار RStudio برای اجرای الگوریتم‌های خوشه‌بندی استفاده شد.

به منظور تبدیل داده‌های نقطه‌ای به سطوح پیوسته در مقیاس کشوری، روش درونیابی فضایی به کار گرفته شد. در این مطالعه از پیش‌بینی رگرسیونی با کریجینگ بیزین تجربی^۳ (EBK Regression Prediction) که یک مدل تخمین مکانی حاصل ترکیب کریجینگ بیزین تجربی (EBK) و رگرسیون برای مدل‌سازی مکانی است، استفاده شد. این روش یک تکنیک خودکار و از نظر آماری قوی است که قادر به تخمین مقادیر متغیرها در نقاط فاقد داده می‌باشد.

مدیریت منابع و توسعه کشاورزی را در آن‌ها مشخص نماید (Caldiz et al., 2002; Dadrasi et al., 2023). با توجه به خلأ موجود در مطالعات پیشین در زمینه لحاظ کردن همزمان تاریخ کاشت و طول دوره رشد در تعیین مناطق اگروکلیمایی (AEZ)، هدف این پژوهش تعیین و پهنه‌بندی مناطق AEZ محصول جو در مقیاس ملی بر اساس این دو پارامتر کلیدی با بهره‌گیری از روش نوین زمین‌آماری ترکیبی کریجینگ بیزین تجربی و رگرسیون (EBK-RP)^۱ است. نتایج این پژوهش می‌تواند به عنوان مبنایی علمی برای برنامه‌ریزی کشت، بهینه‌سازی مدیریت منابع آب و اصلاح الگوی کشت مورد استفاده قرار گیرد.


مواد و روش‌ها

منطقه مورد مطالعه

ایران با مساحتی بالغ بر ۱۶۴۸،۱۹۵ کیلومتر مربع یکی از بزرگترین کشورهای خاورمیانه است و بین مدار ۲۵ تا ۴۰ درجه شمالی و ۴۴ تا ۶۳ درجه شرقی (شکل ۱)، از ارتفاع ۴۰ متر پایین‌تر از سطح دریا تا ۵۶۷۸ متر بالاتر از سطح دریا واقع شده است (Ahmadaali et al., 2013). ایران به دلیل عوامل ژئوقلیمی از جمله بازه وسیع عرض جغرافیایی، وجود رشته کوه‌های البرز در شمال، رشته کوه‌های زاگرس در غرب، دو کویر بزرگ (لوت و کویر) واقع در مرکز فلات ایران و تنوع ارتفاعی قابل توجه، با طیف وسیعی از آب و هوا پوشیده شده است (Rahimi et al., 2013). میانگین بلندمدت بارش، دما و تبخیر-تعرق پتانسیل برابر ۲۲۶/۴۶ میلی‌متر، ۱۷/۶۷ درجه سانتی‌گراد و ۱۲۱۸/۲۴ میلی‌متر است. این مقادیر براساس میانگین بلندمدت داده‌های ۱۷ ساله (سال‌های ۱۳۸۵ تا ۱۴۰۲) محاسبه شده‌اند. دمای زمستان در ارتفاعات بالاتر عمدتاً کمتر از ۲۰- درجه سانتی‌گراد است و دمای تابستان در جنوب به ۵۰ درجه سانتی‌گراد می‌رسد (Ahmadaali et al., 2021; Ramezani Etedali et al., 2019).

روش تحقیق

تاریخ کشت و طول دوره رشد از مهم‌ترین عوامل مدیریتی در تولید محصولات زراعی هستند که تأثیر مستقیمی بر عملکرد، کیفیت محصول و استفاده بهینه از منابع دارند. تعیین دقیق تاریخ کشت محصول جو به عنوان رایج‌ترین محصول زراعی کشور، می‌تواند سبب جلوگیری از سرمازدگی، استفاده بهتر از بارش مؤثر، جلوگیری از مقارن شدن گلدهی با گرمای بهار و کاهش آفات و بیماری‌هایی مثل لکه



شکل ۱- پراکنش داده‌های مورد مطالعه
Figure 1- Distribution of the study data

خوشه‌بندی آماری استفاده شد. خوشه‌بندی در محیط RStudio با بهره‌گیری از الگوریتم K-Means انجام گردید. الگوریتم K-Means یکی از شناخته‌شده‌ترین الگوریتم‌های خوشه‌بندی‌های پرکاربرد خوشه‌بندی‌های غیر سلسله مراتبی در حوزه یادگیری بدون نظارت است که جزو الگوریتم‌های خوشه‌بندی بخشی است. بخش‌بندی یک مجموعه داده به خوشه‌ها شامل یافتن حداقل خطای مربعات بین نقاط مختلف داده در مجموعه داده و میانگین یک خوشه است، سپس هر نقطه داده، به نزدیک‌ترین مرکز خوشه نسبت داده می‌شود. از نظر ریاضی، اگر یک مجموعه داده‌ای $X = \{x_i\}$ که $i = 1, 2, \dots, n$ شامل نقاط داده d بعدی با اندازه n داشته باشیم، X به k خوشه $C = \{c_j\}$ که $j = 1, 2, \dots, k$ تقسیم می‌شود (رابطه ۱).

$$J(c_k) = \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (1)$$

تابع هدف الگوریتم K-means حداقل کردن مجموع مربعات خطا برای هر یک از k خوشه است (رابطه ۲):

$$J(C) = \sum_{k=1}^K \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (2)$$

در این الگوریتم فرآیند خوشه‌سازی را با انتخاب تصادفی k مرکز اولیه از میان داده‌ها آغاز می‌کند. سپس فاصله هر نقطه داده با این مراکز محاسبه می‌شود و هر نقطه به نزدیک‌ترین مرکز تخصیص

به این صورت که نیازی به تنظیم دستی پارامترها به منظور دستیابی به نتایج دقیق نیست و پارامترها طی فرآیند شبیه‌سازی محاسبه می‌گردند. تفاوت دیگر این تکنیک با سایر روش‌های کریجینگ این است که در این روش خطاهای مربوط به به برآورد نیم‌تغییرنما در نظر گرفته می‌شود در حالی که در سایر روش‌ها، نیم‌تغییرنما از مکان‌های با داده‌های مشخص استفاده می‌کند و سپس از این نیم‌تغییرنمای منفرد برای پیش‌بینی در مکان‌های نامشخص استفاده می‌کند. با توجه به اینکه عدم قطعیت برآورد نیم‌تغییرنما را در محاسبات وارد نمی‌کند، منجر به برآورد خطای استاندارد پایین می‌شود. از جمله محاسن این مدل نیاز به حداقل فعل و انفعالات مدل‌سازی، پیش‌بینی خطای استاندارد دقیق‌تر، دقت بیشتر برای مجموعه داده‌های کوچک و پیش‌بینی دقیق‌تر داده‌های نسبتاً ایستا اشاره نمود (Krivoruchko & Gribov, 2019). برای افزایش دقت برآوردها، مدل رقومی ارتفاع (DEM) با تفکیک‌پذیری ۵۰۰ متری به‌عنوان رستر کمکی در مدل EBK لحاظ شد. نتایج این مرحله شامل چهار نقشه رستری پیوسته برای تاریخ شروع کشت و طول دوره رشد جو بود.

خوشه‌بندی آماری و تعیین کلاس‌های زراعی

برای طبقه‌بندی مقادیر پیوسته رستری به‌دست آمده، از روش

K از ۱ تا ۱۰ برای هر دو متغیر تاریخ کشت و طول دوره رشد محصول جو اجرا شد و مقدار WCSS متناظر با هر K محاسبه گردید. سپس نمودار تغییرات WCSS بر حسب افزایش K ترسیم شد. با افزایش تعداد خوشه‌ها، WCSS همواره کاهش می‌یابد، زیرا نقاط داده به مراکز خوشه‌های خود نزدیک‌تر می‌شوند. با این حال، نقطه‌ای که در آن نرخ کاهش WCSS به‌طور قابل توجهی کند می‌شود و نمودار شکل آرنج پیدا می‌کند، به‌عنوان تعداد بهینه خوشه‌ها انتخاب شد. این نقطه نشان‌دهنده آن است که افزودن خوشه‌های بیشتر، بهبود معناداری در فشرده‌سازی و همگنی خوشه‌ها ایجاد نکرده و تنها پیچیدگی مدل را افزایش می‌دهد. بر اساس این تحلیل، تعداد نهایی خوشه‌ها برای هر متغیر مشخص گردید.

ترکیب و نرم‌سازی نهایی نقشه‌ها

در مرحله نهایی، نقشه‌های طبقه‌بندی شده با یکدیگر ترکیب و به منظور کاهش نویز، نرم‌سازی شدند. ابتدا، نقشه‌های طبقه‌بندی شده مربوط به تاریخ شروع کشت و طول دوره رشد با استفاده از ابزار Raster Calculator ترکیب گردید. سپس به‌منظور حذف پیکسل‌های ایزوله و نرم کردن مرزهای کلاس‌های زراعی، نقشه‌های ترکیب شده از تابع آمار کانونی^۵ استفاده شد. در این فرآیند، نوع همسایگی دایره‌ای با شعاع ۵۰ واحد در نظر گرفته شد و معیار آماری اکثریت^۶ به کار گرفته شد تا لبه‌های کلاس‌ها صاف‌تر شده و همگنی پهنه‌ها افزایش یابد. انتخاب پارامترهای نرم‌سازی بر اساس ملاحظات فضایی و آزمون حساسیت انجام شد. نوع همسایگی دایره‌ای به‌دلیل شباهت بیشتر به الگوی انتشار تدریجی متغیرهای اقلیمی در طبیعت انتخاب گردید، زیرا تغییرات اقلیم و ارتفاع معمولاً به‌صورت پیوسته و شعاعی رخ می‌دهند نه در قالب ساختارهای مربعی. شعاع ۱۷ واحد با انجام چندین اجرای آزمایشی تعیین شد؛ به‌گونه‌ای که ضمن حذف پیکسل‌های منفرد و نویزهای ناشی از طبقه‌بندی K-means، از هموارسازی بیش از حد و ادغام غیرواقعی کلاس‌های مجاور جلوگیری شود. همچنین استفاده از معیار اکثریت به این دلیل انتخاب شد که بتواند کلاس غالب در همسایگی هر پیکسل را حفظ کرده و انسجام فضایی پهنه‌های اگروکلیمایی را بدون تغییر ساختار اصلی الگوهای اقلیمی-ارتفاعی تقویت نماید.

نتایج و بحث

خلاصه خصوصیات آماری داده‌های تاریخ کاشت و طول دوره رشد محصول جو در ۷۹۰ نقطه از کشور در جدول ۱ آورده شده است.

می‌یابد. با اضافه شدن هر نقطه به یک خوشه، مرکز آن خوشه دوباره محاسبه می‌شود. این فرآیند به‌صورت تکراری ادامه می‌یابد تا زمانی که ساختار خوشه‌ها به‌حالت پایدار برسد و تغییر معنی‌داری در عضویت نقاط مشاهده نشود (Ikotun et al., 2023). به‌دلیل سادگی پیاده‌سازی و کارایی بالا، الگوریتم K-means به‌طور گسترده در حوزه‌های مختلف برای انجام کارهای خوشه‌بندی مورد استفاده قرار می‌گیرد. اینکه در این الگوریتم تعداد خوشه‌های مورد نظر می‌بایست از پیش تعیین شود، چالش اصلی استفاده از الگوریتم مزبور است. برای حل مشکل، تعیین بهینه تعداد خوشه‌ها دو رویکرد اصلی سایه‌نما^۱ و روش آرنج^۲ ارائه شده است.

در این مطالعه، تعداد بهینه خوشه‌ها (K) برای هر متغیر به‌طور مستقل با استفاده از روش آرنج تعیین شد. این روش یک تکنیک تحلیلی و بصری است که بر اساس معیار مجموع مربعات خطاهای درون خوشه‌ای^۳ (WCSS) عمل می‌کند و به انتخاب بهترین تعداد خوشه‌ها کمک می‌کند. WCSS به‌صورت مجموع مربعات فواصل اقلیدسی هر نقطه داده از مرکز خوشه^۴ مربوط به خود تعریف می‌شود و هدف اصلی خوشه‌بندی کاهش حداقل مقدار WCSS است. در واقع هر خوشه با محاسبه و مقایسه فواصل نقاط آرنج استفاده کرد. یعنی هر خوشه با محاسبه و مقایسه فواصل نقاط داده در یک خوشه با مرکز آن تشکیل می‌شود. در همین راستا روشی ایده‌آل برای تعیین تعداد مناسب خوشه‌ها، محاسبه مجموع مربعات درون خوشه‌ها (WCSS) است. مقدار این متغیر مجموع مربعات فواصل هر نقطه داده در همه خوشه‌ها تا مرکز متناظر با آن ارائه می‌دهد:

$$WCSS = \sum_{C_k}^{C_n} \left(\sum_{d_i \in C_i}^{P_m} distance(d_i, C_k)^2 \right) \quad (3)$$

که در آن C مراکز خوشه و i نقاط موجود در خوشه است و تابع هدف حداقل نمودن مجموع بالا است (Kodinariya & Makwana, 2013). فرض n مشاهده در یک مجموعه داده وجود دارد که اگر تعداد خوشه‌ها را برابر n در نظر بگیریم، مقدار WCSS برابر صفر خواهد بود زیرا هر یک از نقاط داده خود به عنوان مرکز عمل می‌کنند و فاصله نقاط تا مرکز برابر صفر خواهد بود و در این حالت n خوشه خواهیم داشت که تعدادی بدیهی و غیرمنطقی است. لذا یک مقدار آستانه برای K وجود خواهد داشت که می‌توان آن را با استفاده از نمودار آرنج پیدا کرد. برای این منظور به‌طور تصادفی الگوریتم K-Means را برای محدوده‌ای از مقادیر K مقدار دهی اولیه نموده و مقدار WCSS را برای هر K ترسیم می‌کنیم.

در این مطالعه، الگوریتم K-Means به‌صورت متوالی برای مقادیر

4- Centroid

5- Focal Statistics

6- Majority

1- Silhouette Score

2- Elbow Method

3- Within-Cluster Sum of Squares



مرطوب) و تغییرات ارتفاعی (از ۴۰- تا ۵۶۷۸ متر) مرتبط است که باعث می‌شود بازه تاریخ کاشت در نقاط مختلف کشور تا ۸۱ روز اختلاف داشته باشد. در حالی که طول دوره رشد محصول، علی‌رغم تغییرات، تابع محدودیت‌های بیولوژیک گیاه بوده و نوسانات کمتری را نسبت به میانگین نشان می‌دهد.

ملاحظه می‌گردد که محدوده تغییرات تاریخ کاشت و طول دوره رشد به‌ترتیب از ۱ تا ۸۱ روز و از ۱۲۰ تا ۲۹۰ روز با میانگین‌های به‌ترتیب ۳۵/۷ و ۲۱۰/۴ متغیر است. بالا بودن ضریب تغییرات در پارامتر تاریخ کاشت (۵۳/۹٪) نسبت به طول دوره رشد (۱۷٪)، بازتاب‌دهنده ناهمگنی شدید زمانی در آغاز عملیات زراعی در مقیاس ملی است. این موضوع مستقیماً با تنوع گسترده اقلیم‌های ایران (از فراخشک تا

جدول ۱- آنالیز آماری تاریخ کشت و طول دوره رشد محصول جود در سطح کشور


Table 1- Statistical analysis of planting date and length of the growth period of barley across the country

پارامتر Parameter	تاریخ کاشت (روز نسبت به اول مهر) Planting Date (days from 22nd September)	طول دوره رشد Length of Growth Period (days)
مینیمم Minimum	1	120
ماکزیمم Maximum	81	290
میانگین Mean	35.7	210.4
انحراف معیار Standard deviation	19.2	35.8
چولگی Skewness	0.06	-0.39
کشدگی Kurtosis	-0.59	-0.79
ضریب تغییرات Coefficient of variation	53.9	17



شکل ۲- نمودار تغییرات WCSS در مقابل تغییرات تعداد خوشه

Figure 2- Plot of WCSS variations versus the number of clusters



شکل ۳- نقشه طبقه‌بندی شده تاریخ کاشت با تکنیک K-Means و روش آرنج
Figure 3- Classified map of planting date using the K-Means technique and the elbow method

و نیمه‌مرطوب پهنه خیزی یعنی بخش‌هایی از گیلان، مازندران و نوار باریک شمالی البرز، وضعیت اقلیمی با رطوبت بالا و بارش پاییزه قابل‌اتکا، زمینه کاشت بسیار زود هنگام جو را فراهم می‌کند. در این مناطق که اغلب ارتفاع کمی نیز دارند، خاک زودتر مرطوب می‌شود، خطر سرمای زودرس کمتر است. در مناطق غرب و شمال‌غرب که شامل آذربایجان شرقی، آذربایجان غربی، کردستان، همدان، زنجان و بخش‌هایی از کرمانشاه است مناطق مدیترانه‌ای و نیمه‌مرطوب دیده می‌شود. این مناطق بارش پاییزی خوبی دریافت می‌کنند اما ارتفاعات زاگرس و البرز غربی دمای هوا را در ماه‌های ابتدایی فصل سرد کاهش می‌دهد و همین امر باعث تأخیر نسبی در کاشت، نسبت به نواحی خیزی می‌شود. در نتیجه مقادیر تاریخ کاشت در بازه ۲۵ تا ۴۵ روز قرار گرفته که بیانگر تعادل میان رطوبت مناسب و سرمای ارتفاعی است. در فلات مرکزی ایران که بیشتر مساحت آن در طبقات نیمه‌خشک و خشک قرار دارد، الگوی کاشت تغییر قابل‌توجهی می‌یابد. میزان بارش کم، پراکندگی بارش‌های پاییزه و وابستگی شدید کشاورزی دیم به نخستین سامانه‌های بارش مؤثر، موجب می‌شود کاشت جو نسبتاً دیرتر انجام گیرد. ارتفاعات متوسط نیز در بخش‌هایی از اصفهان، یزد، مرکزی و قم این تأخیر را تشدید می‌کند. الگوی این مناطق حاصل کمبود رطوبت در اقلیم نیمه‌خشک و تأثیرات ارتفاعی بر سردی فصل است. در نهایت، شرق و جنوب‌شرق ایران شامل استان‌های

لازم به ذکر است که هرچند محدوده تغییرات داده‌های ایستگاهی بین ۱ تا ۸۱ روز متغیر است، اما در نقشه نهایی پهنه‌بندی، به دلیل فرآیند خوشه‌بندی K-means و اعمال فیلترهای نرم‌سازی فضایی جهت حذف نویزهای تک‌پیکسلی، بازه کلاس نهایی به ۷۷ روز تعدیل شده است. این امر به منظور دستیابی به پهنه‌های همگن و کاربردی در مقیاس ملی صورت گرفته است. بر اساس روش آرنج و با توجه به نمودارهای شکل ۲، تعداد خوشه پهنه، که به بیشترین میزان کاهش در مقدار WCSS منجر می‌شود، برای تاریخ کاشت و طول دوره رشد به ترتیب برابر سه و چهار کلاس تعیین شد. نقشه پهنه‌بندی شده تاریخ کاشت با استفاده از تکنیک رگرسیون کریجینگ بیزین تجربی و طبقه‌بندی شده با تکنیک K-Means و روش آرنج در شکل ۳ نشان داده شده است.

بررسی نقشه تاریخ کاشت جو در ایران نشان می‌دهد که الگوی زمانی کاشت از شمال‌غرب و شمال کشور با مقادیر بسیار پایین (۰ تا ۲۷ روز) آغاز می‌شود و در جهت جنوب‌شرق و شرق کشور به مقادیر بسیار بالا (۴۶ تا ۷۷ روز) افزایش می‌یابد. این الگوی گسترده و پیوسته به‌طور دقیق نتیجه برهم‌کنش دو عامل اساسی یعنی تنوع اقلیمی ایران و تغییرات ارتفاعی گسترده کشور است. با توجه به شکل ۳ و طبقه‌بندی اقلیمی دمارتن گسترش یافته، ملاحظه می‌گردد که در نواحی مرطوب

و کاهش خشکی با افزایش طول دوره رشد و همچنین رابطه معکوس بین ارتفاع بالا (که دما را تعدیل می‌کند) و خشکی شدید با طول مدت رشد گیاه است. به‌طور پیوسته از جنوب گرم و بسیار خشک با ارتفاع کم و فصل رشد کوتاه، به شمال و شمال‌غرب مرطوب و خنک‌تر با ارتفاعات مؤثر و فصل رشدی بسیار طولانی حرکت می‌کنیم و این توزیع دقیقاً بازتاب هم‌زمان الگوی اقلیمی و توپوگرافی ایران است.

در ادامه با برهم‌نهی دو نقشه هم تاریخ کاشت و هم طول دوره رشد اقدام به تهیه نقشه کلاس‌های زراعی و قابلیت کشت محصول جو در ایران گردید. سپس نقشه تهیه شده بر اساس الگوریتم K-Means و روش آرنج طبقه‌بندی شد. ترکیب کلاس‌های تاریخ کشت (۳ کلاس) و طول دوره رشد (۴ کلاس) منجر به تولید ۱۲ کلاس زراعی نهایی برای جو (۳×۴) شد که در شکل ۵ ارائه شده است.

با توجه به نقشه شکل ۵، کدگذاری کلاس‌های نهایی بر اساس فرمول (۴) بدست آمده و در جدول ۲ آورده شده است.


$$\begin{aligned} \text{Agricultural Class Number} \\ = \text{Planting Date Class Number} \times 10 \\ + \text{Growth Season Duration Class Number} \end{aligned} \quad (4)$$

در ایران، تنوع اقلیمی و تغییرات ارتفاعی نقش اساسی در تعیین کلاس‌های زراعی و قابلیت کشت جو دارند. نقشه‌های اقلیمی (Rahimi et al., 2013) و رقوم ارتفاعی کشور نشان می‌دهند که هرچه از شمال به جنوب و از غرب به شرق حرکت کنیم، از میزان رطوبت، بارش و شرایط مساعد برای رشد این محصول کاسته می‌شود و به تدریج کلاس‌های زراعی به سمت کدهای مرتبط با مناطق خشک و نیمه‌خشک تغییر می‌کنند.

در مناطق شمالی، شمال‌غربی و بخش‌هایی از شمال‌شرقی ایران، که شامل اقلیم‌های مرطوب و نیمه‌مرطوب در سواحل خزر و دامنه‌های البرز و همچنین اقلیم‌های نیمه‌خشک و مدیترانه‌ای در ارتفاعات هستند، بهترین شرایط برای کشت جو مشاهده می‌شود. این نواحی معمولاً در کلاس‌های زراعی ۱۲، ۱۳ و ۱۴ قرار می‌گیرند که معرف دوره رشد طولانی‌تر، بارش مناسب و دمای معتدل‌تر هستند. علاوه بر این، در برخی جلگه‌های شمالی و مناطق با اقلیم معتدل‌تر، کلاس‌هایی مانند ۲۲ و ۲۳ نیز دیده می‌شود که نشان‌دهنده پتانسیل مناسب کشت آبی و دیم هستند. نقش ارتفاعات البرز و زاگرس در شکل‌گیری این شرایط مطلوب بسیار تعیین‌کننده است، زیرا با افزایش ارتفاع، بارش بیشتر و دما کاهش می‌یابد و امکان شکل‌گیری کلاس‌های نیمه‌سرد و معتدل فراهم می‌شود.


سیستان و بلوچستان، شرق کرمان، جنوب خراسان جنوبی و بخش‌هایی از هرمزگان، در طبقات فوق‌خشک و خشک قرار می‌گیرند. این مناطق خشک‌ترین نقاط ایران هستند و دریافت بارش پاییزی در آن‌ها دیر هنگام، بسیار محدود و نامنظم است. علاوه بر این، بخش‌هایی از شرق کشور تحت تأثیر بادهای خشک، تبخیر بسیار بالا، و وقوع تأخیر در نخستین بارش مؤثر هستند. همین شرایط باعث می‌شود که کاشت جو در این مناطق بیشترین تأخیر زمانی را داشته باشد. ترکیب اقلیم فوق‌خشک با ارتفاعات پراکنده و ناهمگن باعث شده کاشت جو حتی تا ۸۱ روز نیز به تعویق بیفتد.

نتایج شکل ۴ نشان داد که الگوی تغییرات طول دوره رشد محصول جو، به‌صورت پیوسته با اقلیم‌های ایران بر اساس دومارتین گسترش یافته و همچنین با الگوی ارتفاعی ایران هماهنگ است. هرچه شرایط اقلیمی خشک‌تر و ارتفاع پایین‌تر باشد، دما بالاتر و طول فصل رشد کوتاه‌تر می‌شود و برعکس. در اقلیم‌های مرطوب‌تر و نواحی مرتفع که دما پایین‌تر است، فصل رشد طولانی‌تر می‌شود. از جنوب و جنوب‌شرق و جنوب‌غرب ایران که عمدتاً در اقلیم فراخشک و خشک قرار دارند و ارتفاع آن‌ها نسبتاً پایین است، کوتاه‌ترین دوره رشد، یعنی حدود ۱۲۰ تا ۱۷۱ روز مشاهده می‌شود. این نواحی شامل سواحل مکران، بخش‌های وسیعی از هرمزگان و بوشهر، جنوب خوزستان و نواحی کم‌ارتفاع سیستان و بلوچستان هستند که هم از نظر اقلیمی بسیار گرم و خشک‌اند و هم به دلیل عرض جغرافیایی پایین و تابش زیاد، رشد محصول سریع‌تر اما کوتاه‌تر تمام می‌شود. با حرکت به سمت نواحی مرکزی ایران، در فلات مرکزی و اقلیم نیمه‌خشک و مدیترانه‌ای، طول دوره رشد به حدود ۱۷۰ تا ۲۲۰ روز می‌رسد. این مناطق شامل بخش‌هایی از کرمان، یزد، اصفهان، قم، مرکزی و بخش‌هایی از خراسان جنوبی و رضوی هستند که گرچه خشک‌اند، اما در مقایسه با جنوب، دما کمی ملایم‌تر و نوسانات فصلی بیشتر است و همین باعث افزایش نسبی طول فصل رشد می‌شود. در مرحله بعد، نواحی واقع در ارتفاعات متوسط و اقلیم نیمه‌مرطوب مانند دامنه‌های زاگرس از فارس تا کهگیلویه و بویراحمد، چهارمحال و بختیاری، لرستان و بخش‌هایی از کردستان و کرمانشاه، وارد محدوده ۲۰۴ تا ۲۳۴ روز می‌شوند. نقش ارتفاع در این بخش بسیار مهم است؛ دمای پایین‌تر در دوره‌های انتقالی سال باعث طولانی‌تر شدن زمان مناسب رشد می‌شود. در نهایت، بیشترین طول دوره رشد یعنی حدود ۲۳۴ تا نزدیک ۲۹۰ روز در نواحی شمالی و شمال‌غربی و مناطق پرباران کشور مشاهده می‌شود، جایی که اقلیم نیمه‌مرطوب و مرطوب دامنه‌های البرز و اقلیم مرطوب خزری غالب است. استان‌های گیلان، مازندران و بخش‌هایی از اردبیل و گلستان به دلیل بارش فراوان، رطوبت بالا، عرض جغرافیایی بالاتر و دمای معتدل، امکان یک دوره رشد بسیار طولانی و ممتد را فراهم می‌کنند. در این مناطق، سرمای شدید کوتاه‌مدت بوده و طول دوره گرمای مناسب برای رشد گیاه بیشتر ادامه دارد. بنابراین، این پهنه‌بندی بیانگر رابطه مستقیم بین افزایش رطوبت



شکل ۴- نقشه طبقه‌بندی شده طول دوره رشد با تکنیک K-Means و روش آرنج

Figure 4- Classified map of the length of the growing period using the K-Means technique and the elbow method



شکل ۵- پهنه‌بندی کلاس‌های زراعی و قابلیت کشت محصول جو در ایران

Figure 5- Zoning of agricultural classes and the suitability for cultivating barley in Iran

جدول ۲- کلاس‌های زراعی محصول جو در کشور و تفسیر آن‌ها

Table 2- Agricultural classes of barley in the country and their interpretations

کلاس کشاورزی Agricultural Class	توضیحات Description
11*	تاریخ کاشت ۲۷-۰ روز و دوره رشد ۱۷۱-۱۲۰ روز Planting date 0-27 days and growth period 120-171 days
12	تاریخ کاشت ۲۷-۰ روز و دوره رشد ۱۷۱-۲۰۴ روز Planting date 0-27 days and growth period 171-204 days
13	تاریخ کاشت ۲۷-۰ روز و دوره رشد ۲۰۴-۲۳۴ روز Planting date 0-27 days and growth period 204-234 days
14	تاریخ کاشت ۲۷-۰ روز و دوره رشد ۲۳۴-۳۰۲ روز Planting date 0-27 days and growth period 234-302 days
21	تاریخ کاشت ۲۷-۴۶ روز و دوره رشد ۱۷۱-۱۲۰ روز Planting date 27-46 days and growth period 120-171 days
22	تاریخ کاشت ۲۷-۴۶ روز و دوره رشد ۱۷۱-۲۰۴ روز Planting date 27-46 days and growth period 171-204 days
23	تاریخ کاشت ۲۷-۴۶ روز و دوره رشد ۲۰۴-۲۳۴ روز Planting date 27-46 days and growth period 204-234 days
24	تاریخ کاشت ۲۷-۴۶ روز و دوره رشد ۲۳۴-۳۰۲ روز Planting date 27-46 days and growth period 234-302 days
31	تاریخ کاشت ۴۶-۸۱ روز و دوره رشد ۱۷۱-۱۲۰ روز Planting date 46-81 days and growth period 120-171 days
32	تاریخ کاشت ۴۶-۸۱ روز و دوره رشد ۱۷۱-۲۰۴ روز Planting date 46-81 days and growth period 171-204 days
33	تاریخ کاشت ۴۶-۸۱ روز و دوره رشد ۲۰۴-۲۳۴ روز Planting date 46-81 days and growth period 204-234 days
34*	تاریخ کاشت ۴۶-۸۱ روز و دوره رشد ۲۳۴-۳۰۲ روز Planting date 46-81 days and growth period 234-302 days

* کلاس‌های ۱۱ و ۳۴ که حاصل اشتراک شرایط مربوطه هست، در گستره کشور موجود نیست.

گرم و نیمه‌گرمسیر سازگارند.

در غرب و جنوب‌غربی کشور، تنوع اقلیمی بیشتری وجود دارد. ارتفاعات زاگرس با اقلیم نیمه‌خشک و بارندگی‌های کوهستانی امکان ایجاد کلاس‌های معتدل و نیمه‌سرد مانند ۲۲ و ۲۳ را فراهم می‌کنند، در حالی‌که با کاهش ارتفاع و نزدیک‌شدن به مناطق گرمسیری، کلاس‌های گرمسیری و کم‌بارش غالب می‌شوند.

به‌طور کلی، الگوی توزیع کلاس‌های زراعی جو در ایران کاملاً با پهنه‌بندی اقلیمی دومارتن و تغییرات ارتفاعی سازگار است. ارتفاعات بالاتر، اقلیم‌های مرطوب‌تر و دماهای پایین‌تر معمولاً با کلاس‌های مناسب‌تر کشت مانند ۱۲، ۱۳ و ۱۴ همراه‌اند، در حالی‌که با کاهش ارتفاع و افزایش خشکی، کلاس‌ها به سمت ۲۱، ۲۲، ۲۳ و نهایتاً ۳۱ و ۳۲ تغییر می‌کنند. این روند نشان می‌دهد که جغرافیا و اقلیم نقش تعیین‌کننده‌ای در انتخاب نوع و کلاس مناسب کشت جو در مناطق مختلف کشور دارند و نواحی با بارش مناسب و دمای معتدل به‌طور

در مناطق مرکزی ایران، که اقلیم خشک و نیمه‌خشک بر آن غالب است، کلاس‌هایی مانند ۲۱ و ۲۲ رایج‌تر هستند. این نقاط دوره‌های رشد کوتاه‌تری دارند و میزان رطوبت و بارش در آن‌ها به شدت محدود است. به همین دلیل، کشت جو در این مناطق بیشتر به‌صورت کوتاه‌مدت یا در شرایط مدیریت‌شده منابع آب انجام می‌شود. هرچه به سمت کویرهای مرکزی و شرقی پیش می‌رویم، خشکی افزایش یافته و کلاس‌ها به سمت کدهای ۳۱ و ۳۲ تغییر می‌کنند که معرف محدودیت شدید منابع آبی و پتانسیل پایین‌تر برای کشت هستند.

در جنوب و جنوب‌شرق ایران، به‌ویژه در مناطق بیابانی و بسیار خشک، کلاس‌های زراعی ۲۳ تا ۳۳ گسترش دارند. این نواحی به دلیل دمای بالا، بارش بسیار کم و رطوبت محدود، مناسب کشت جو در دوره‌های طولانی نیستند و تنها امکان کشت جوهای مقاوم یا کوتاه‌دوره وجود دارد. در نواحی گرمسیری و کم‌ارتفاع جنوب مانند خوزستان و جنوب فارس، کلاس‌هایی مانند ۱۴ و ۳۳ دیده می‌شود که با شرایط

طبیعی برای تولید این محصول مناسب‌تر هستند.

نتیجه‌گیری

یافته‌های این پژوهش نشان می‌دهد که بهره‌گیری هم‌زمان از داده‌های اقلیمی، ارتفاعی، فنولوژیک و روش‌های نوین تحلیل فضایی مانند کریجینگ بیزین تجربی و خوشه‌بندی K-Means با روش آرنج، می‌تواند امکان تعیین دقیق نواحی اگروکلیمایی محصول جو را در مقیاس ملی فراهم سازد. بررسی‌های انجام‌شده نشان داد که تاریخ کاشت و طول دوره رشد محصول جو در ایران به‌شدت تحت تأثیر گرادیان اقلیمی-ارتفاعی است؛ به‌طوری‌که نواحی غرب، شمال‌غرب و بخش‌هایی از سواحل خزری با بارش بیشتر، دمای معتدل‌تر و رطوبت کافی، توان بالایی برای کاشت زودهنگام و دوره رشدی طولانی دارند. این ویژگی‌ها زمینه ایجاد محیطی پایدار، کاهش احتمال تنش سرمایی یا گرمایی در مراحل حساس رشد و در نهایت افزایش عملکرد را فراهم می‌کند. در مقابل، نواحی شرقی، جنوب‌شرقی و بخش‌هایی از فلات مرکزی به‌دلیل رطوبت بسیار کم، پراکنش نامنظم بارش، دماهای بالا و تبخیر زیاد، شرایط محدودکننده‌ای برای محصول جو دارند. این مناطق معمولاً با کاشت دیرهنگام، دوره رشد کوتاه و ریسک بالای تنش‌های محیطی مواجه‌اند. در نتیجه مدل‌سازی با روش‌ها و الگوریتم‌های ذکر شده، سطح کشور به ۱۲ کلاس همگن زراعی از نظر تاریخ کاشت و طول دوره رشد برای محصول جو تقسیم شد که این طبقه‌بندی نشان داد که تنها بخش محدودی از کشور (عمدتاً در غرب و شمال‌غرب) دارای بالاترین پتانسیل برای کشت پایدار جو است، در حالی‌که بسیاری از مناطق خشک و نیمه‌خشک تنها در دوره‌های کوتاه و محدود امکان کشت را دارند. این نتایج اهمیت برنامه‌ریزی مبتنی بر

توان اکولوژیک، مدیریت منابع آب و پرهیز از توسعه کشت در مناطق ناپایدار را برجسته می‌کند. با استفاده از نتایج این تحقیق می‌توان مناطق کم‌بازده و کم‌پتانسیل برای تولید را از مدار تولید خارج کرده همچنین برای ارتقا بهره‌وری می‌توان از تقویم‌های کاشت منطقه‌ای متناسب با کلاس‌های شناسایی‌شده، انتخاب ارقام زودرس و مقاوم به خشکی، تغییر زمان کاشت برای اجتناب از تنش‌های دمایی، و به‌کارگیری روش‌های نوین آبیاری بهره‌جست. علاوه بر این، انتقال کشت جو به پهنه‌های دارای پتانسیل بالا، کاهش سطح زیرکشت در مناطق با محدودیت شدید، مدیریت بقایا برای حفظ رطوبت خاک و توسعه سامانه‌های هوشمند مبتنی بر GIS جهت ارائه توصیه‌های دقیق کاشت از راهکارهای کلیدی برای ارتقای پایداری تولید جو در کشور به‌شمار می‌آیند. این اقدامات می‌توانند نقشی اساسی در مدیریت ریسک ناشی از تغییرات اقلیمی، بهبود بهره‌وری و افزایش امنیت غذایی ایفا کنند.

با وجود دقت مناسب روش‌های به‌کاررفته، این پژوهش با برخی محدودیت‌ها مواجه بود. نخست، تحلیل‌ها بر پایه داده‌های بلندمدت ایستگاهی و میانگین‌های اقلیمی انجام شد و تغییرات سالانه و نوسانات حدی اقلیم به‌صورت صریح وارد مدل نگردید. دوم، اثر سناریوهای تغییر اقلیم آینده بر جابجایی احتمالی پهنه‌های اگروکلیمایی مورد بررسی قرار نگرفت. همچنین متغیرهای خاک، مدیریت مزرعه و تنوع ارقام جو در سطح ملی به‌طور مستقیم در فرآیند پهنه‌بندی لحاظ نشدند. پیشنهاد می‌شود در پژوهش‌های آتی از داده‌های با تفکیک مکانی و زمانی بالاتر، سناریوهای اقلیمی آینده، و مدل‌های تلفیقی اقلیم-رشد گیاه استفاده شود تا پویایی فضایی پهنه‌های زراعی و ریسک‌های ناشی از تغییر اقلیم با دقت بیشتری ارزیابی گردد.

References

- Ahmadaali, K., Eskandari Damaneh, H., Ababaei, B., & Eskandari Damaneh, H. (2021). Impacts of droughts on rainfall use efficiency in different climatic zones and land uses in Iran. *Arabian Journal of Geosciences*, 14(2), 126. <https://doi.org/10.1007/s12517-020-06389-1>
- Ahmadaali, K., Liaghat, A.M., Heydari, N., & Haddad, O.B. (2013). Application of artificial neural network and adaptive neural-based fuzzy inference system techniques in estimating of virtual water. *International Journal of Computer Applications*, 76(6). <https://doi.org/10.5120/13250-0715>
- Aktaş, B., & Gökdere, H.İ. (2025). Evaluation of grain yield, and quality characteristics of some bread wheat cultivars in different agro-ecological regions of Türkiye. *Heliyon*, 11(1). <https://doi.org/10.1016/j.heliyon.2024.e41547>
- Asante, B.O., Temoso, O., Addai, K.N., & Villano, R.A. (2019). Evaluating productivity gaps in maize production across different agroecological zones in Ghana. *Agricultural Systems*, 176, 102650. <https://doi.org/10.1016/j.agsy.2019.102650>
- Bagheri, A. (2025). Effects of climate change on barley yield in Isfahan Province. *Spatial Planning*, 15(4), 69-90. (In Persian with English abstract). <https://doi.org/10.22108/sppl.2025.145531.1852>
- Bhagat, M.A., Kaur, N., & Kaur, S. (2023). Effect of sowing dates on the phenology, grain yield and stress tolerance indices of barley (*Hordeum vulgare* L.) genotypes under subtropical conditions of Punjab. *Journal of Agrometeorology*, 25(1), 113-119. <https://doi.org/10.54386/jam.v25i1.1841>

7. Caldiz, D.O., Haverkort, A.J., & Struik, P.C. (2002). Analysis of a complex crop production system in interdependent agro-ecological zones: a methodological approach for potatoes in Argentina. *Agricultural Systems*, 73(3), 297-311. [https://doi.org/10.1016/S0308-521X\(01\)00085-3](https://doi.org/10.1016/S0308-521X(01)00085-3)
8. Dadrasi, A., Chaichi, M., Nehbandani, A., Soltani, E., Nemati, A., Salmani, F., ... & Yousefi, A.R. (2023). Global insight into understanding wheat yield and production through Agro-Ecological Zoning. *Scientific Reports*, 13(1), 15898. <https://doi.org/10.1038/s41598-023-43191-x>
9. Ebrahimi-Pak, N., Tafteh, A., Hosseini, N., & Keykhaii, F. (2022). *Water requirement system (Samaneh Niyaz Ab)*. Soil and Water Research Institute. <http://niwr.ir> (In Persian)
10. Fischer, G., Shah, M., van Velthuizen, H., & Nachtergaele, F. (2006). *Agro-ecological zones assessments*. Oxford: Eolss Publishers.
11. Hajirad, I., Ahmadaali, K., & Liaghat, A. (2025). Crop yield and water productivity modeling using nonlinear growth functions. *Scientific Reports*, 15(1), 30087. <https://doi.org/10.1038/s41598-025-16096-0>
12. Hajirad, I., Mirlatifi, S.M., Dehghanisanij, H., & Mohammadi, S. (2021). Determining yield response factor (ky) of silage maize under different irrigation levels of pulsed and continuous irrigation management. *Central Asian Journal of Plant Science Innovation*, 1(4), 214-220. <https://doi.org/10.1007/s00271-023-00880-9>
13. Hatfield, J.L., & Prueger, J.H. (2015). Temperature extremes: Effect on plant growth and development. *Weather and climate extremes*, 10(Part A), 4-10. <https://doi.org/10.1016/j.wace.2015.08.001>
14. Ikotun, A.M., Ezugwu, A.E., Abualigah, L., Abuhaija, B., & Heming, J. (2023). K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data. *Information Sciences*, 622, 178-210. <https://doi.org/10.1016/j.ins.2022.11.139>
15. Kodinariya, T.M., & Makwana, P.R. (2013). Review on determining number of Cluster in K-Means Clustering. *International Journal*, 1(6), 90-95.
16. Krivoruchko, K., & Gribov, A. (2019). Evaluation of empirical Bayesian kriging. *Spatial Statistics*, 32, 100368. <https://doi.org/10.1016/j.spasta.2019.100368>
17. Neamatollahi, E., Bannayan, M., Jahansuz, M.R., Struik, P., & Farid, A. (2012). Agro-ecological zoning for wheat (*Triticum aestivum*), sugar beet (*Beta vulgaris*) and corn (*Zea mays*) on the Mashhad plain, Khorasan Razavi province. *The Egyptian Journal of Remote Sensing and Space Science*, 15(1), 99-112. <https://doi.org/10.1016/j.ejrs.2012.05.002>
18. Porter, J.R., & Semenov, M.A. (2005). Crop responses to climatic variation. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 360(1463), 2021-2035. <https://doi.org/10.1098/rstb.2005.1752>
19. Rahimi, J., Ebrahimpour, M., & Khalili, A. (2013). Spatial changes of extended De Martonne climatic zones affected by climate change in Iran. *Theoretical and applied climatology*, 112(3), 409-418. <https://doi.org/10.1007/s00704-012-0741-8>
20. Ramezani Etedali, H., Ahmadaali, K., Gorgin, F., & Ababaei, B. (2019). Optimization of the cropping pattern of main cereals and improving water productivity: application of the water footprint concept. *Irrigation and Drainage*, 68(4), 765-777. <https://doi.org/10.1002/ird.2362>
21. Sivakumar, M.V.K., & Valentin, C. (1997). Agroecological zones and the assessment of crop production potential. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 352(1356), 907-916. <https://doi.org/10.1098/rstb.1997.0070>
22. Taati, A., & Sarmadian, F. (2015). Evaluation of land suitability for rainfed barley and wheat in agroecological zones of Abyek area. *Land Management Journal*, 2(2), 123-136. (In Persian with English abstract). <https://doi.org/10.22092/lmj.2015.101275>
23. Van Wart, J., van Bussel, L.G., Wolf, J., Licker, R., Grassini, P., Nelson, A., ... & Cassman, K.G. (2013). Use of agro-climatic zones to upscale simulated crop yield potential. *Field Crops Research*, 143, 44-55. <https://doi.org/10.1016/j.fcr.2012.11.023>
24. Yu, H., Huang, M., Zhao, T., Wang, J., Li, Z., Chen, D., ... & Wang, X. (2022). Analysis of agricultural production potential and enhancement strategy in the Qaidam Basin based on the Agro-Ecological Zone method. *Frontiers in Environmental Science*, 10, 908888. <https://doi.org/10.3389/fenvs.2022.908888>

Monthly Rainfall Simulation Using Hybrid Machine Learning Models: NAMAK Lake Basin

A. DalirGabrabad¹, M.A. Abdollahi¹, A. Ashrafzadeh^{1*}

1- Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

(*- Corresponding Author Email: a.ashrafzadeh@ut.ac.ir)

Received: 29 January 2026

Revised: 28 May 2026

Accepted: 01 June 2026

Available Online: 01 June 2026

How to cite this article:

DalirGabrabad, A., Abdollahi, M.A., & Ashrafzadeh, A. (2026). Monthly rainfall simulation using hybrid machine learning models: NAMAK lake basin. *Journal of Water and Soil*, 39(6), 553-572. (In Persian with English abstract). <https://doi.org/10.22067/jsw.2026.97595.1522>

Introduction

Precipitation is a fundamental component of the hydrological cycle and plays a vital role in water resource management, agriculture, ecosystem sustainability, hydropower generation, disaster mitigation, and urban planning. Accurate rainfall prediction is essential for effective water allocation, flood and drought risk management, and the development of early warning systems, thereby reducing potential damages to human communities and infrastructure. In agriculture, reliable precipitation forecasts support optimal planting schedules and resource management, leading to increased productivity and reduced weather-related losses. Furthermore, rainfall prediction is crucial for reservoir operation and sustainable long-term water resource planning.

Due to the limited spatial coverage of ground-based meteorological stations, satellite-based precipitation products have gained increasing attention as reliable alternatives for regional-scale rainfall analysis. Among these, the Climate Hazards Group InfraRed Precipitation with Stations (CHIRPS) dataset is widely recognized for its extensive spatial coverage, relatively high accuracy in arid and mountainous regions, and free accessibility. CHIRPS integrates satellite observations with ground station data and provides precipitation estimates at approximately 5 km spatial resolution across multiple temporal scales since 1981. In this study, monthly mean CHIRPS precipitation data for the period 2000–2024 were extracted and analyzed for rainfall prediction purposes.

The inherent nonlinearity and complex behavior of precipitation processes make traditional statistical approaches insufficient for accurate forecasting. Consequently, machine learning techniques have emerged as powerful tools for modeling complex climatic phenomena. Although numerous previous studies have applied machine learning algorithms, such as Artificial Neural Networks (ANN), Random Forest (RF), Support Vector Machines (SVM), and Convolutional Neural Networks (CNN), to rainfall prediction, most have focused on single-model evaluations or simple model comparisons. However, combining multiple models has been shown to reduce prediction uncertainty and improve forecast robustness, an approach that has received comparatively limited attention.

The primary objective of this research is to evaluate the performance of satellite-based CHIRPS precipitation data and to enhance monthly rainfall prediction using machine learning models implemented in the WEKA environment. To achieve this goal, fifteen individual machine learning models were first assessed independently. Subsequently, pairwise combinations of these models (105 combinations in total) were developed using simple averaging and brute-force weighting strategies to improve predictive accuracy. The novelty of this study lies not merely in the application of multiple machine learning algorithms but in proposing a systematic, transparent, and reproducible framework for satellite-based rainfall prediction in data-scarce basins. This framework is region-independent and can be readily applied to other climatic and hydrological settings.



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.97595.1522>

Materials and Methods

This study investigates monthly precipitation prediction in the Salt Lake Basin using satellite-based CHIRPS data for the period January 2000 to December 2025, extracted via the Google Earth Engine platform. CHIRPS was selected due to its adequate spatial resolution (0.05°), integration of satellite and ground-based observations, long-term temporal coverage since 1981, and suitability for arid and semi-arid regions with sparse rain-gauge networks. Data quality was assessed using the Interquartile Range (IQR) method, and no outliers were detected. As the dataset exhibited consistent scaling across all time steps, no normalization was applied. The data were divided into training (January 1999–December 2021) and testing (January 2022–December 2024) subsets. All modeling procedures were implemented in the WEKA environment using time-series modules. To validate the CHIRPS dataset, satellite-derived precipitation estimates were compared with observations from four ground stations over ten years (2007–2017), and basin-scale performance was evaluated using averaged statistical metrics. Initially, sixteen machine learning models were examined, and one model (Random Tree) was excluded due to poor performance. The final set of fifteen models included Gaussian Processes, Random Forest, MLP Regressor, RBF Regressor, Linear Regression, SMOreg, IBk, LWL, Additive Regression, Bagging, Random Committee, Random SubSpace, Decision Table, M5Rules, and M5P. Model hyperparameters were optimized using the Grid Search tool in WEKA. To improve prediction accuracy and robustness, pairwise ensemble models were generated using simple averaging, resulting in 105 combined configurations. Additionally, a brute-force weighting approach was applied by assigning weights between 0 and 1 with a step of 0.1 to each model, subject to a unity-sum constraint, in order to identify the optimal ensemble structure.

Model performance was evaluated using the correlation coefficient, RMSE, MAE, MSE, bias, and Nash–Sutcliffe efficiency (NSE), and the most accurate configuration was selected based on testing results.

Results and Discussion

The accuracy of the CHIRPS satellite precipitation product was first evaluated using observed rainfall data from four rain-gauge stations distributed across the Salt Lake Basin. The validation results indicated a satisfactory agreement between satellite-derived and observed precipitation, with an overall coefficient of determination (R^2) of approximately 0.69 and an NSE of 0.70, confirming the suitability of CHIRPS data for monthly rainfall analysis in the study area. Subsequently, the performance of fifteen individual machine learning models was assessed for monthly precipitation prediction using the testing period (January 2022–December 2024). Model evaluation based on correlation coefficient, RMSE, MAE, MSE, bias, and Nash–Sutcliffe efficiency (NSE) revealed notable differences among algorithms. Rule-based and tree-based models, particularly M5Rules and Additive Regression, exhibited superior performance, characterized by higher NSE values, lower error magnitudes, and relatively small bias. In contrast, instance-based models such as IBk and function-based models like RBF Regressor showed weaker performance, with larger error dispersion and lower correlation with observed data. The combined analysis of bias, residual standard deviation, and median absolute error provided a more comprehensive understanding of model behavior than single error metrics alone. Visual assessments using Taylor diagrams and scatter plots further confirmed the robustness of M5Rules, followed by Additive Regression and Random Forest, in capturing both the variability and temporal patterns of observed precipitation.

To enhance prediction accuracy and stability, pairwise combinations of the individual models were developed using simple averaging, resulting in 105 ensemble configurations. The results demonstrated that most ensemble models outperformed their corresponding single-model counterparts, as evidenced by higher NSE values and reduced error metrics. The combination of Additive Regression–M5Rules achieved the best overall performance, yielding the lowest MAE and MSE and the highest NSE among all tested configurations. Histogram analysis of NSE values showed that a large proportion of the ensemble models achieved NSE values above 0.75, indicating the general effectiveness of the ensemble approach rather than improvement limited to specific combinations. In addition, a brute-force weighting strategy was applied to optimize model contributions within the ensembles. Compared to simple averaging, the Brute Force approach consistently improved NSE values by reducing the influence of weaker models and assigning higher weights to more accurate ones. This improvement was particularly evident in combinations involving low-performing models such as IBk and RBF Regressor. Nevertheless, simple averaging also produced competitive and stable results without increasing computational complexity.

Overall, the results indicate that monthly rainfall prediction accuracy depends not only on the choice of individual algorithms but also on the interaction and complementarity of model errors. The proposed ensemble framework effectively reduced bias and variance while avoiding overfitting through strict temporal data separation and independent testing. These findings demonstrate that systematic pairwise model combination, even with simple averaging, can substantially enhance the accuracy and robustness of precipitation forecasts in data-scarce and climatically complex regions.

Conclusion

The Salt Lake Basin is characterized by sparse rain-gauge coverage and high climatic variability, making accurate monthly precipitation estimation essential for water resources management. This study evaluated the CHIRPS satellite precipitation dataset and assessed the performance of individual and combined machine learning models for monthly rainfall prediction. Validation against four ground stations confirmed that CHIRPS reliably represents the temporal pattern of monthly precipitation in the basin, with acceptable correlation and Nash–Sutcliffe efficiency values, indicating its suitability for hydrological applications in arid and semi-arid regions. Among the fifteen evaluated machine learning models, M5Rules, Additive Regression, and Random Forest exhibited superior performance as single models. Ensemble modeling further improved prediction accuracy by reducing systematic errors and enhancing robustness. The Additive Regression–M5Rules combination achieved the best performance ($NSE \approx 0.88$), outperforming all individual models. These results highlight the effectiveness of integrating CHIRPS data with ensemble machine learning approaches for improving monthly precipitation prediction in data-scarce basins. The proposed framework provides a reliable and transferable tool for supporting sustainable water resources management in arid and semi-arid regions.

Keywords: Climate data prediction, Precipitation data modeling, WEKA

شبیه‌سازی بارش ماهانه با مدل‌های ترکیبی یادگیری ماشین: حوضه دریاچه نمک

علی دلیر گبرآباد^۱ - محمدامین عبداللهی^۱ - افشین اشرف‌زاده^{۱*}

تاریخ دریافت: ۱۴۰۴/۱۱/۰۹

تاریخ پذیرش: ۱۴۰۵/۰۳/۱۱

چکیده

پیش‌بینی دقیق بارش ماهانه به‌ویژه در مناطق خشک و نیمه‌خشک، برای مدیریت منابع آب و برنامه‌ریزی‌های هیدرولوژیک اهمیت بالایی دارد. با توجه به کمبود و پراکندگی ایستگاه‌های زمینی در حوضه دریاچه نمک، استفاده از داده‌های ماهواره‌ای با دقت مکانی مناسب، ضرورت می‌یابد. نوآوری اصلی این پژوهش، ارزیابی کارایی داده‌های بارش CHIRPS در مدل‌سازی بارش ماهانه با بهره‌گیری از طیفی متنوع از مدل‌های یادگیری ماشین و همچنین بررسی اثربخشی مدل‌های ترکیبی در افزایش دقت پیش‌بینی است. در این مطالعه، داده‌های بارش CHIRPS با تفکیک افقی 0.5° برای دوره ۲۰۰۰ تا ۲۰۲۴ استخراج و پس از اعتبارسنجی اولیه مورد استفاده قرار گرفت. در این پژوهش برای ارزیابی داده‌های بارش CHIRPS، طیفی از مدل‌های یادگیری ماشین شامل مدل‌های درختی، مدل‌های رگرسیونی، مدل‌های کرنلی، مدل‌های مبتنی بر فاصله و مدل‌های ترکیبی به‌منظور مدل‌سازی رفتار غیرخطی بارش ماهانه مورد استفاده قرار گرفتند. این تنوع رویکردها، امکان ارزیابی تطبیقی ساختارهای مختلف یادگیری و بررسی تأثیر معماری مدل بر دقت پیش‌بینی را فراهم می‌سازد. مدل M5Rules با بدست آوردن $NSE = 0.80$ بهترین عملکرد را در مدل‌های منفرد داشت. همچنین برای بهبود دقت، بر پایه میانگین‌گیری ساده، 105 مدل ترکیبی به‌صورت دوبه‌دو تولید و ارزیابی شد و سپس برای پیدا کردن بهترین وزن از روش bruteforce (جستجوی فراگیر برای وزن‌دهی بهینه) استفاده شد. نتایج نشان داد که؛ مدل‌های ترکیبی به‌طور کلی عملکرد بهتری نسبت به مدل‌های منفرد دارند. ترکیب Additive Regression-M5Rules بهترین عملکرد را نسبت به سایر ترکیب‌ها با $MAE = 0.155$ ، $MSE = 0.05$ و $NSE = 0.88$ ارائه کرد. این یافته‌ها نشان می‌دهد که ترکیب داده‌های CHIRPS با مدل‌های ترکیبی یادگیری ماشین می‌تواند رویکردی کارآمد و قابل اتکا برای پیش‌بینی بارش ماهانه در مناطق با شبکه ایستگاهی محدود باشد.

واژه‌های کلیدی: الگوریتم‌های یادگیری ماشین، پیش‌بینی داده‌های اقلیمی، مدل‌سازی داده‌های بارش، وکا

مقدمه

برف به باران و افزایش مشکلات مربوط به سیل و آبگرفتگی به ویژه در مناطق شهری، پیش‌بینی‌های قابل اعتماد امکان ایجاد سیستم‌های هشدار زودهنگام را فراهم می‌کند که برای اقدامات پیشگیرانه جهت حفاظت از جوامع و دارایی‌ها ضروری هستند (Abdollahi et al., 2024; Fikileni & Wolski, 2022). پیش‌بینی بارش در کشاورزی، به‌ویژه در کشورهایی مانند هند، برای تعیین زمان مناسب کشت و مدیریت منابعی چون آب و کود ضروری است. این اقدامات باعث افزایش بهره‌وری، بهبود عملکرد محصولات، و کاهش خسارات ناشی از شرایط جوی نامساعد می‌شود (Patel et al., 2023). پیش‌بینی بارش در مدیریت مخازن و سدها نقش کلیدی دارد و با تنظیم ذخیره و آزادسازی آب، نیازهای کشاورزی، صنعتی و خانگی را برآورده می‌سازد. همچنین، داده‌های پیش‌بینی کمک می‌کنند تا منابع آب به‌صورت پایدار، مدیریت شده و دسترسی طولانی‌مدت به آن تضمین

بارش یکی از مهم‌ترین متغیرهای چرخه هیدرولوژیکی است که؛ نقش حیاتی در مدیریت منابع آب، کشاورزی و اکوسیستم‌های طبیعی ایفا می‌کند. پیش‌بینی دقیق میزان بارش نه تنها برای برنامه‌ریزی منابع آب ضروری است؛ بلکه نقش مهمی در مدیریت خطرات سیل و خشکسالی دارد. زیرا کاهش آسیب‌های احتمالی به انسان‌ها و زیرساخت‌ها را در پی دارد. همچنین با توجه به تغییر نوع بارش‌ها از

۱- گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، کرج، ایران

(*)- نویسنده مسئول: (Email: a.ashrafzadeh@ut.ac.ir)

<https://doi.org/10.22067/jsw.2026.97595.1522>

علمی و کاربردی مشخصی صورت گرفته است. نخست، CHIRPS دارای پوشش زمانی بلندمدت و پیوسته از سال ۱۹۸۱ میلادی تاکنون است که امکان تحلیل روندهای اقلیمی در مقیاس چنددهه‌ای را فراهم می‌کند؛ در حالی که برخی محصولات ماهواره‌ای مانند TRMM و GPM دوره زمانی کوتاه‌تری را پوشش می‌دهند (Funk et al., 2015). دوم، این مجموعه داده با ترکیب برآوردهای ماهواره‌ای و داده‌های ایستگاه‌های زمینی، دقت خود را به‌ویژه در مناطق خشک و کوهستانی افزایش داده است؛ که این ویژگی برای منطقه مورد مطالعه اهمیت بالایی دارد (Beck et al., Funk et al., 2015). علاوه بر این، وضوح مکانی مناسب (حدود ۵ کیلومتر) و ارائه داده‌ها در مقیاس‌های زمانی روزانه، دهه‌ای و ماهانه، انعطاف‌پذیری لازم برای تحلیل‌های آماری و مکانی را فراهم می‌سازد. از نظر اجرایی نیز، دسترسی رایگان، به‌روزرسانی منظم، ارائه در فرمت‌های استاندارد (مانند NetCDF^{۱۱} و GeoTIFF^{۱۲}) و سازگاری کامل با نرم‌افزارهای متداول تحلیل داده، استفاده از این مجموعه داده را تسهیل می‌کند و نیاز به پیش‌پردازش‌های پیچیده را کاهش می‌دهد. همچنین، کاربرد گسترده CHIRPS در مطالعات منطقه‌ای و بین‌المللی موجب افزایش قابلیت مقایسه‌پذیری نتایج این پژوهش با سایر تحقیقات شده است. بر این اساس، انتخاب CHIRPS نه تنها بر مبنای دسترسی، بلکه بر اساس ترکیب پوشش زمانی بلندمدت، دقت مکانی مناسب، ادغام داده‌های زمینی و ماهواره‌ای و اعتبار علمی گسترده آن صورت گرفته است. در این تحقیق، داده‌های میانگین ماهانه CHIRPS برای بازه زمانی ۲۰۰۰ تا ۲۰۲۴ میلادی به‌منظور بررسی پیش‌بینی بارش در منطقه مورد مطالعه استخراج و تحلیل شده‌اند.

با توجه به نوسانات اقلیمی و اثرات فزاینده آن بر منابع آب، نیاز به پیش‌بینی مناسب‌تر بارش در دوره‌های زمانی مختلف، بیش از پیش احساس می‌شود. در این میان، داده‌های ماهواره‌ای به دلیل پوشش مکانی وسیع و پیوستگی زمانی، ابزاری مناسب برای استفاده در پژوهش‌ها در کنار داده‌های ایستگاهی محسوب می‌شوند. همچنین، با رشد الگوریتم‌های یادگیری ماشین، امکان مدل‌سازی دقیق‌تری از رفتار پیچیده و غیرخطی بارش فراهم شده است. در بسیاری از مطالعات پیشین، از مدل‌های یادگیری ماشین برای پیش‌بینی بارش استفاده شده، اما اغلب آن‌ها به ارزیابی یک یا چند مدل به‌صورت مجزا محدود شده‌اند. این در حالی است که؛ ترکیب خروجی مدل‌ها می‌تواند منجر به کاهش خطا و افزایش پایداری پیش‌بینی‌ها شود (Tuysuzoglu et al., 2023)، موضوعی که تاکنون کمتر مورد توجه

شود (Ramani et al., 2024). پیش‌بینی بارش برای تولید برق آبی ضروری است، زیرا با پیش‌بینی جریان آب به مخازن، تولید برق را بهینه و عرضه پایدار انرژی را تضمین می‌کند. همچنین، این پیش‌بینی‌ها تخصیص بهینه منابع انرژی را ممکن کرده و به کاهش خطر کمبود برق کمک می‌کنند، پیش‌بینی بارش در برنامه‌ریزی شهری برای طراحی سیستم‌های زهکشی کارآمد و کاهش خطر آبگرفتگی شهری مؤثر است. همچنین، این پیش‌بینی‌ها در توسعه زیرساخت‌هایی مانند جاده‌ها و پل‌ها با ارائه اطلاعات درباره شرایط جوی و خطرات احتمالی نقش مهمی دارند (Patel et al., 2023). پیش‌بینی دقیق بارش برای مدیریت مؤثر منابع آب، برنامه‌ریزی کشاورزی، آمادگی در برابر بلایا و توسعه زیرساخت ضروری است (Salahi et al., 2024a,b). بهبود مستمر در فناوری‌های پیش‌بینی برای پاسخگویی به چالش‌های رو به رشد ناشی از تغییرات آب و هوایی و اطمینان از مدیریت پایدار منابع آب ضروری است.

با توجه به عدم کفایت پوشش مکانی ایستگاه‌های زمینی، داده‌های ماهواره‌ای مانند CHIRPS^۱ به‌عنوان منابع قابل اعتماد برای تحلیل بارش در مقیاس‌های منطقه‌ای مورد توجه قرار گرفته‌اند. از سوی دیگر، با پیچیدگی و ماهیت غیرخطی الگوهای بارش، مدل‌های یادگیری ماشین^۲ ابزارهای مناسبی برای تحلیل چنین داده‌هایی محسوب می‌شوند. داده‌های سنجش از دور با فناوری‌های پیشرفته، نقشی کلیدی در پایش محیط زیست، برنامه‌ریزی شهری و مدیریت منابع آب دارند. این داده‌ها، امکان پایش بلادرنگ تغییرات محیطی و جنگل‌زدایی را فراهم می‌سازند (Mahjoobi & Rafiei, 2025). تهیه نقشه‌ها و تحلیل تنوع زیستی (Fagan & DeFries, 2024)، رصد دقیق تغییرات کاربری اراضی با تصاویر وضوح بالا و ادغام با GIS^۳ و یادگیری ماشین را ارائه می‌دهند (Xu & Zheng, 2024). با توجه به تنوع مجموعه داده‌های بارش در دسترس نظیر TRMM^۴، GPM^۵، MERRA-2^{۱۰}، ERA5^۶، CRU^۸، GPCC^۷، PERSIANN^۹، انتخاب مجموعه داده CHIRPS در این پژوهش بر اساس معیارهای

- 1- CHIRPS: Climate Hazards Group InfraRed Precipitation with Station data
- 2- Machine Learning
- 3- Geographic Information System
- 4- Tropical Rainfall Measuring Mission
- 5- Global Precipitation Measurement
- 6- Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks
- 7- Global Precipitation Climatology Centre
- 8- Climatic Research Unit
- 9- ECMWF Reanalysis v5
- 10- Modern-Era Retrospective Analysis for Research and Applications, Version 2

11- Network Common Data Form

12- Geographic Tagged Image File Format

قرار گرفته است.

با پیشرفت الگوریتم‌های داده‌کاوی^۱ و یادگیری ماشین، استفاده از این رویکردها برای مدل‌سازی پدیده‌های اقلیمی، رشد قابل توجهی یافته است. با وجود گسترش مطالعات در زمینه پیش‌بینی بارش با استفاده از مدل‌های هوش مصنوعی، بیشتر پژوهش‌ها بر ارزیابی تک‌مدل‌ها یا مقایسه چند الگوریتم متمرکز بوده‌اند. در مقابل، کمتر مطالعه‌ای به‌صورت سیستماتیک به ترکیب مدل‌های^۲ یادگیری ماشین و ارزیابی هم‌زمان چند الگوریتم در چارچوبی یکپارچه و قابل تکرار پرداخته است. هدف اصلی این پژوهش، ارزیابی داده‌های بارش ماهواره‌ای CHRS و پیش‌بینی بارش ماهانه با استفاده از داده‌های ماهواره‌ای و مدل‌های یادگیری ماشین در محیط نرم‌افزار WEKA^۳ است. در این راستا، ابتدا عملکرد ۱۵ مدل یادگیری ماشین به‌صورت مجزا بررسی شده و سپس با ترکیب دو به دوی آن‌ها (در مجموع ۱۰۵ حالت)، تلاش شده است تا دقت پیش‌بینی‌ها به‌طور قابل توجهی بهبود یابد. نوآوری و ارزش افزوده این پژوهش صرفاً در به‌کارگیری مدل‌های یادگیری ماشین یا افزایش تعداد آن‌ها خلاصه نمی‌شود، بلکه در ارائه یک چارچوب سیستماتیک و قابل تکرار برای ارزیابی داده‌های CHIRPS و بهبود پیش‌بینی بارش ماهانه در حوضه‌های کم‌داده نهفته است.

در این مطالعه، کلیه مراحل شامل استخراج داده، پیش‌پردازش، تقسیم‌بندی زمانی، آموزش، آزمون و ترکیب مدل‌ها به‌صورت شفاف و قابل بازتولید تشریح شده‌اند. استفاده از ترکیب‌های دویدهو با میانگین‌گیری ساده و وزن‌دهی BruteForce یک رویکرد عمومی است؛ که می‌تواند بدون وابستگی به منطقه خاص، در سایر حوضه‌ها نیز پیاده‌سازی شود. از این‌رو، پژوهش حاضر نه‌تنها قابل تکرار است، بلکه می‌تواند به‌عنوان یک چارچوب مرجع برای مطالعات مشابه در سایر مناطق اقلیمی مورد استفاده قرار گیرد. مطالعات مرتبط با پیش‌بینی بارش و برآورد تغییرات آن را می‌توان در چند دسته اصلی طبقه‌بندی کرد. این دسته‌ها از روش‌های داده‌کاوی و یادگیری ماشین تا مدل‌های آماری ریزمقیاس‌نمایی و رویکردهای هیبریدی را دربرمی‌گیرند.

در نخستین گروه، پژوهش‌هایی قرار می‌گیرند که از روش‌های مبتنی بر قواعد و داده‌کاوی برای استخراج الگوهای تصمیم‌گیری استفاده کرده‌اند. برای مثال، Omary و همکاران در سال ۲۰۱۲ با معرفی الگوریتم DIAL^۴ توانستند قواعد انجمنی مؤثر در پیش‌بینی محلی آب‌وهوا را استخراج کنند (Omary et al., 2012). همچنین

کومار و اسواتی (2023Kumar & Swathi) با استفاده از الگوریتم J48 در محیط WEKA نشان دادند که درخت تصمیم^۵ قادر است قوانین پیش‌بینی بارش را با دقت قابل قبول استخراج کند.

گروه دوم شامل پژوهش‌هایی است که یادگیری عمیق و شبکه‌های عصبی را برای پیش‌بینی بارش به‌کار گرفته‌اند. بال و همکاران با بهره‌گیری از شبکه‌های عصبی کانولوشنی^۶ نشان دادند که این مدل‌ها در پیش‌بینی بارش روزانه عملکرد بهتری نسبت به روش‌های سنتی دارند (Abishek et al., 2017). خان و همکاران (۲۰۲۲) نیز با بررسی شبکه‌های عصبی و مدل‌های ترکیبی گزارش کردند که این روش‌ها می‌توانند دقت پیش‌بینی بارش را به‌طور چشمگیری افزایش دهند (Rahman et al., 2022). در همین چارچوب، برخی پژوهش‌ها به پیش‌بینی بارش فصلی با استفاده از سیستم استنباط فازی^۷ و شبکه عصبی مصنوعی پرداخته‌اند. در این مطالعات، بارش بازه دسامبر تا می در منطقه خراسان بزرگ بررسی شده و نشان داده شده است که؛ استفاده از ANN^۸ و مدل فازی می‌تواند در برآورد بارش فصلی مؤثر باشد. این دسته از پژوهش‌ها به‌طور مشخص به مقایسه‌ی دو رویکرد فازی و شبکه عصبی برای پیش‌بینی فصلی می‌پردازند (Fallah-Ghalhari et al., 2009). Babaei Hessar & Ghazavi, 2014

گروه سوم شامل پژوهش‌هایی است که؛ از الگوریتم‌های کلاسیک یادگیری ماشین استفاده کرده‌اند. سونی و همکاران (۲۰۱۸) با مقایسه^۹ KNN، SVM، درخت تصمیم و شبکه عصبی مصنوعی، نشان دادند که ANN عملکرد بهتری در پیش‌بینی بارش روزانه دارد (Amrehn et al., 2018). در پژوهشی دیگر، اوسوال (Oswal, 2019) با استفاده از داده‌های هواشناسی استرالیا و روش‌هایی نظیر رگرسیون لجستیک^{۱۰}، KNN^{۱۱}، درخت تصمیم و مدل‌های ترکیبی، بر نقش تعیین‌کننده انتخاب مدل مناسب و کیفیت پیش‌پردازش داده‌ها تأکید کرد. پاتل و همکاران (Patel et al., 2023) نیز با ارزیابی الگوریتم‌های مختلف داده‌کاوی در نرم‌افزار WEKA نشان دادند که Random Forest در پیش‌بینی بارش عملکرد بهتری ارائه می‌دهد. علاوه بر این، ولاسکو و همکاران (Velasco et al., 2022) با بهره‌گیری از مدل SVR^{۱۲} نشان دادند که انتخاب بهینه هسته و پارامترهای مدل نقش مهمی در افزایش دقت پیش‌بینی دارد.

5- Decision Tree

6- CNN

7- Fuzzy

8- Artificial Neural Network

9- Support Vector Machine

10- Logistic Regression

11- K-Nearest Neighbors

12- Support Vector Regression

1- Data Mining

2- ensemble

3- Waikato Environment for Knowledge Analysis

4- Differential Absorption Lidar

مواد و روش‌ها

داده‌های مورد استفاده

در این پژوهش، داده‌های بارش ماهانه CHIRPS مربوط به بازه زمانی ژانویه ۲۰۰۰ تا دسامبر ۲۰۲۵ برای حوضه آبریز دریاچه نمک مورد استفاده قرار گرفت (شکل ۱). مجموعه داده CHIRPS توسط گروه Climate Hazards Group توسعه یافته و با تفکیک مکانی ۰.۵ درجه از سال ۱۹۸۱ تاکنون ارائه می‌شود. این داده‌ها از ترکیب تصاویر مادون قرمز ماهواره‌ای، اقلیم‌نگاشت‌های بلندمدت و داده‌های ایستگاه‌های باران‌سنجی تولید می‌شوند. در فرآیند تولید ابتدا بارش بر اساس دمای ابر در تصاویر ماهواره‌ای برآورد می‌شود، سپس با استفاده از داده‌های اقلیمی و ایستگاه‌های زمینی تصحیح و کالیبره می‌گردد و در ادامه از روش‌های آماری برای کاهش بایاس و بهبود دقت استفاده می‌شود. به دلیل ترکیبی بودن داده‌ها، پوشش مکانی مناسب و عملکرد قابل اعتماد در مناطق دارای شبکه ایستگاهی محدود، CHIRPS به یکی از معتبرترین منابع برآورد بارش در مناطق خشک و نیمه‌خشک تبدیل شده و گزینه‌ای مناسب برای تحلیل بارش در حوضه آبریز دریاچه نمک محسوب می‌شود (Funk et al., 2015).

پیش‌پردازش و تقسیم‌بندی داده‌ها

داده‌های استخراج‌شده بارش ماهانه پیش از مدل‌سازی تحت فرآیند پیش‌پردازش قرار گرفتند. به منظور شناسایی داده‌های پرت، از روش دامنه بین چارکی^۱ استفاده شد. در این روش، چارک اول (Q1) و چارک سوم (Q3) محاسبه شده و دامنه بین چارکی مطابق رابطه (۱) تعیین گردید. داده‌هایی که در دامنه (a,b) قرار نگیرند به عنوان داده پرت در نظر گرفته می‌شوند (Turkey, 1977).

$$IQR = Q3 - Q1 \quad (1)$$

$$(a) = Q1 - 1.5 * IQR \quad (2)$$

$$(b) = Q3 + 1.5 * IQR \quad (3)$$

نتایج بررسی نشان داد که هیچ مقدار خارج از این بازه در سری زمانی مشاهده نشد؛ بنابراین داده‌ها فاقد نقاط پرت آماری معنادار بودند. از آنجاکه روش IQR یک روش ناپارامتری است و مبتنی بر توزیع داده نمی‌باشد، آزمون سطح معناداری کلاسیک (مانند آزمون‌های پارامتری) در این مرحله موضوعیت نداشت و معیار شناسایی بر اساس قاعده $IQR \times 1/5$ انجام شد. همچنین به منظور بررسی ناسازگاری احتمالی در سری زمانی، روند کلی و پیوستگی مقادیر در بازه زمانی مورد مطالعه از نظر نوسانات غیرمنطقی یا گسست ناگهانی بررسی گردید؛ که موردی مشاهده نشد.


در ادامه این دسته، پژوهش‌هایی قرار می‌گیرند که بر تخمین و پیش‌بینی ارتفاع بارش در مناطق فاقد داده تمرکز دارند. در این راستا، حدادیان و یزدی (Haddadi & Yazdi, 2025) با استفاده از XGBoost^۱ نشان می‌دهند که این الگوریتم یادگیری ماشین برای مناطق فاقد اندازه‌گیری میدانی گزینه‌ای مناسب است و می‌تواند در کاربردهای مرتبط با مدیریت منابع آب به کار رود. بنابراین، این پژوهش را باید ذیل پیش‌بینی بارش در مناطق کم‌داده با رویکرد XGBoost طبقه‌بندی کرد. در نهایت، برخی مطالعات از مدل‌های آماری ریزمقیاس‌نمایی^۲ برای برآورد اثرات تغییر اقلیم بر بارش استفاده کرده‌اند. برای مثال، در مطالعه‌ای که از مدل SDSM^۳ در دو اقلیم خشک و فراخشک استفاده شد، نشان داده شد که عملکرد مدل در منطقه خشک بهتر از فراخشک است و تا سال ۲۰۹۹، بارش سالانه در کرمان اندکی کاهش و در بم افزایش می‌یابد (Rezaei et al., 2014). این نتایج نشان می‌دهد که؛ مدل‌های آماری ریزمقیاس‌نما می‌توانند در برآورد اثرات تغییر اقلیم بر بارش محلی نقش مؤثری داشته باشند.

در کنار این‌ها، پژوهش‌هایی نیز رویکردهای ترکیب مدل‌ها^۴ یا مدل‌های هیبریدی را توسعه داده‌اند. یل‌دیز و همکاران (۲۰۲۳) با توسعه روش EK-stars^۵ مبتنی بر یادگیری گروهی، افزایش دقت پیش‌بینی بارش را گزارش کردند (Tuysuzoglu et al., 2023).

در جمع‌بندی پیشینه می‌توان بیان کرد که؛ اگرچه مطالعات متعددی از روش‌های یادگیری ماشین، یادگیری عمیق و مدل‌های ترکیبی برای پیش‌بینی بارش استفاده کرده‌اند، اما همچنان چند شکاف مهم وجود دارد: نخست آن که بررسی هم‌زمان عملکرد داده‌های CHIRPS در کنار طیف گسترده‌ای از مدل‌های یادگیری ماشین کمتر انجام شده و اغلب پژوهش‌ها بر داده‌های زمینی یا تعداد محدودی مدل تمرکز داشته‌اند؛ دوم آن که مقایسه نظام‌مند مدل‌های منفرد و ترکیبی در مقیاس ماهانه، به‌ویژه در مناطق خشک با رفتار بارشی نامنظم، کمتر مورد توجه قرار گرفته است؛ و سوم آن که اغلب مطالعات از وزندهی ساده برای ترکیب مدل‌ها استفاده کرده‌اند و رویکردهای بهینه‌سازی وزن‌ها، مانند روش BruteForce برای افزایش دقت پیش‌بینی، کمتر به کار رفته است. بنابراین مطالعه حاضر با ارزیابی جامع داده‌های CHIRPS، مقایسه طیفی از مدل‌های یادگیری ماشین و توسعه یک مدل ترکیبی با وزن‌های بهینه‌شده، به‌طور مستقیم این شکاف‌ها را هدف قرار می‌دهد.

- 1- Extreme Gradient Boosting
- 2- Statistical Downscaling Models
- 3- Statistical DownScaling Model
- 4- ensemble
- 5- Ensemble K-Star

6- Interquartile Range – IQR



شکل ۱ - حوضه دریاچه نمک

Figure 1- Salt Lake Basin

به منظور آموزش و ارزیابی مدل‌ها، داده‌ها به دو بخش تقسیم گردید:

داده‌های آموزش: ژانویه ۲۰۰۰ تا دسامبر ۲۰۲۱

داده‌های آزمون: ژانویه ۲۰۲۲ تا دسامبر ۲۰۲۴

ارزیابی دقت داده‌های بارش CHIRPS

به منظور ارزیابی دقت داده‌های بارش CHIRPS، از داده‌های مشاهده‌ای چهار ایستگاه زمینی با پراکندگی مکانی مناسب در حوضه مورد مطالعه استفاده شد. ایستگاه‌های آغچه در استان اصفهان، ارتش‌آباد در استان قزوین، و ایستگاه‌های آراقله و احمدآباد در استان مرکزی طی دوره آماری ۱۰ ساله (۲۰۰۷ تا ۲۰۱۷) مورد بررسی قرار گرفتند. مشخصات مکانی ایستگاه‌ها در جدول ۱ ارائه شده است. در این مطالعه، ابتدا داده‌های روزانه بار CHIRPS با داده‌های مشاهده‌ای هر ایستگاه به صورت جداگانه مقایسه شدند. برای این منظور، مقادیر بارش ماهواره‌ای متناظر با مختصات جغرافیایی هر ایستگاه استخراج و سپس شاخص‌های آماری ارزیابی گردید.

با توجه به یکنواخت بودن مقیاس داده‌ها در کل دوره زمانی نیازی به نرمال‌سازی داده‌ها وجود نداشت. در نتیجه داده‌ها بدون تغییر مقیاس وارد مرحله آموزش و آزمون مدل‌ها شدند. در این پژوهش، داده‌های بارش ماهانه به عنوان متغیر ورودی مدل‌ها مورد استفاده قرار گرفت. بدین منظور، میانگین بارش ماهانه استخراج شده از پایگاه داده CHIRPS (بر حسب mm) برای منطقه مورد مطالعه به عنوان یکی از ورودی‌های اصلی مدل‌ها در نظر گرفته شد. همچنین به منظور در نظر گرفتن تغییرات فصلی بارش در طول سال، شماره ماه نیز به عنوان یک متغیر ورودی به مدل‌ها اضافه شد. بنابراین ورودی مدل‌ها شامل دو متغیر اصلی یعنی میانگین بارش ماهانه و شماره ماه مربوطه بود. در این پژوهش از داده‌های بارش با زمان تأخیر^۱ استفاده نشده است و تمرکز اصلی بر بررسی رابطه بین مقادیر بارش ماهانه و تغییرات زمانی آن در طول سال بوده است.

1- Lag Time

جدول ۱- مختصات ایستگاه‌های بررسی شده

Table 1- Coordinates of the investigated stations

نام ایستگاه Station name	استان Province	ارتفاع Elevation (m)	طول جغرافیایی Longitude (DMS)	عرض جغرافیایی Latitude (DMS)
آغچه (Aghcheh)	اصفهان (Esfahan)	2500	50-23-25	33-04-02
ارتش آباد (Artesh Abad)	قزوین (Ghazvin)	1750	49-25-47	35-39-31
آراقله (Ara Qaleh)	مرکزی (Markazi)	1641	49-43-19	35-06-05
احمدآباد (Ahmad Abad)	مرکزی (Markazi)	104	50-26-18	34-59-42

مدل‌های درختی و قاعده‌محور (M5P و M5Rules، Decision Tree، Random Forest، Bagging، Additive و Random SubSpace، Regression)، انجام شد. دلیل آزمون این طیف متنوع از مدل‌ها، بررسی توانایی آن‌ها در بازنمایی رفتار غیرخطی و نوسانی بارش ماهانه و همچنین ارزیابی این فرضیه بود؛ که مدل‌های ترکیبی و درختی به دلیل قابلیت مدیریت روابط پیچیده و کاهش واریانس، می‌توانند عملکرد بهتری نسبت به مدل‌های ساده‌تر ارائه دهند. این رویکرد امکان مقایسه جامع و انتخاب ساختار بهینه برای پیش‌بینی بارش در حوضه مورد مطالعه را فراهم می‌سازد. با استفاده از ابزار Grid Search در نرم‌افزار WEKA پارامترهای هر مدل متناسب با سری زمانی به صورت بهینه انتخاب شدند. در ادامه جدول ۲ توضیحات مدل‌ها را نشان می‌دهد.

ترکیب مدل‌ها

به منظور ارتقاء دقت و پایداری، پس از اجرای انفرادی مدل‌ها، ابتدا ترکیب‌های زوجی بر اساس میانگین‌گیری ساده از خروجی دو مدل ایجاد شدند. این ترکیب بدون اعمال وزن بوده و صرفاً به عنوان راهی برای کاهش خطا و افزایش اعتبار پذیری پیش‌بینی‌ها به کار رفت. در مجموع، ۱۰۵ ترکیب مختلف حاصل شد که ارزیابی و انتخاب مدل‌های برتر، مبتنی بر نتایج داده‌های آزمون صورت پذیرفت. پس از میانگین‌گیری ساده، از روش Brute force (جستجوی فراگیر برای وزن‌دهی بهینه) استفاده شده است. در این روش از صفر تا یک، به هر مدل با گام ۰/۰۱ وزن داده می‌شود؛ به طوری که مجموع وزن مدل‌ها، یک می‌شود و تمام حالت‌هایی که می‌شود به یک مدل وزن داد، امتحان می‌شود. در این روش تمام ترکیب‌های ممکن از وزن‌ها بررسی می‌شود تا بهترین حالت پیدا شود.

همچنین به منظور نمایش پراکنش مکانی ایستگاه‌ها در محدوده حوضه آبریز دریاچه نمک، موقعیت آن‌ها در نقشه منطقه مورد مطالعه نیز در شکل ۱ نمایش داده شده است. مدل‌های مورد استفاده در این مطالعه، ابتدا ۱۶ مدل مختلف یادگیری ماشین برای پیش‌بینی سری زمانی بارش مورد بررسی قرار گرفت. به دلیل عملکرد ضعیف یکی از مدل‌ها (مدل Random Tree با ضریب همبستگی کمتر از ۰/۵ و مقدار RMSE بالا)، مدل مزبور حذف گردید و نهایتاً ۱۵ مدل برتر انتخاب و ارزیابی شدند. مدل‌های مورد استفاده در این پژوهش طیف متنوعی از رویکردهای یادگیری ماشین شامل مدل‌های خطی، مبتنی بر فاصله، مبتنی بر هسته، درختی و مدل‌های ترکیبی را در بر می‌گیرند. هر یک از این الگوریتم‌ها دارای نقاط قوت و محدودیت‌های خاص خود هستند. به طور کلی، مدل‌های خطی مانند LR^1 دارای سادگی و تفسیرپذیری بالا هستند اما در بازنمایی روابط غیرخطی محدودیت دارند. مدل‌های مبتنی بر هسته مانند SVR و GP^2 توانایی مدل‌سازی روابط پیچیده را دارند ولی از نظر محاسباتی پرهزینه‌تر هستند. الگوریتم‌های درختی و مبتنی بر قواعد مانند M5Rules و M5P تعادل مناسبی میان دقت و تفسیرپذیری ایجاد می‌کنند. در نهایت، روش‌های ترکیبی مانند Bagging و جنگل تصادفی^۳ با کاهش واریانس و خطای مدل‌های پایه، پایداری پیش‌بینی را افزایش می‌دهند. انتخاب این مجموعه متنوع از مدل‌ها با هدف مقایسه جامع عملکرد و بررسی امکان بهبود دقت از طریق ترکیب آن‌ها صورت گرفته است. انتخاب این مدل‌ها با هدف پوشش رویکردهای مختلف مدل‌سازی شامل مدل‌های خطی (Linear Regression)، مبتنی بر فاصله (IBk)، مبتنی بر هسته (SMOreg و Gaussian Processes)، شبکه‌های عصبی (MLP و RBF)،

- 1- Linear Regression
- 2- Gaussian Processes
- 3- Random Forest

جدول ۲- توضیحات مدل‌های یادگیری ماشین مورد استفاده در پژوهش

Table 2- Description of the Machine Learning Models used in the study

مدل Model	معایب Disadvantages	مزایا Advantages	مرجع Reference
Gaussian Processes	هزینه محاسباتی بالا، حساس به انتخاب کرنل High computational cost; sensitive to kernel selection	توانایی مدل‌سازی روابط غیرخطی پیچیده؛ ارائه عدم قطعیت پیش‌بینی؛ عملکرد قوی در داده‌های کوچک Ability to model complex nonlinear relationships; provides prediction uncertainty; strong performance with small datasets	(Schulz <i>et al.</i> , 2018)
Random Forest	کاهش تفسیرپذیری؛ نیاز به تنظیم تعداد درخت‌ها و پارامترهای دیگر Reduced interpretability; requires tuning of tree numbers and parameters	مقاوم به نویز؛ کاهش بیش‌برازش نسبت به درخت منفرد؛ عملکرد قوی در داده‌های غیرخطی Robust to noise; reduces overfitting compared to a single tree; strong nonlinear performance	(Biau & Scornet 2016)
MLP Regressor	نیاز به تنظیم زیاد پارامترها؛ حساس به داده کم Requires extensive hyperparameter tuning; sensitive to small datasets	قدرت بالا در مدل‌سازی روابط غیرخطی پیچیده؛ مناسب سری‌های زمانی Strong capability for modeling complex nonlinear patterns; suitable for time series	(Goodfello Bengio & Courville, 2016)
Linear Regression	ناتوان در مدل‌سازی روابط غیرخطی Cannot model nonlinear relationships	ساده، سریع، قابل تفسیر؛ مبنای مقایسه Simple, fast, interpretable; baseline method	(James <i>et al.</i> , 2021)
SMOreg	انتخاب پارامتر کرنل پیچیده Complex kernel parameter selection	عملکرد پایدار در داده‌های نویزی؛ کنترل بیش‌برازش Stable performance on noisy data; effective control of overfitting	(Cervantes <i>et al.</i> , 2020)
IBk	حساس به مقیاس داده؛ عملکرد ضعیف در داده پرتعداد Sensitive to data scaling; weak performance on large datasets	ساده؛ بدون فرض توزیع؛ مناسب داده‌های محلی Simple; no distribution assumptions; suitable for local patterns	(Taunk <i>et al.</i> , 2019)
LWL	وزن High computational cost during prediction; sensitive to weighting parameters	مدل‌سازی رفتار موضعی؛ انعطاف‌پذیر Models local behavior; highly flexible	(Abinaya, 2020)
Additive Regression	خطر بیش‌برازش در تکرار زیاد Risk of overfitting with too many iterations	کاهش بایاس؛ بهبود مدل پایه Reduces bias; improves the base learner	(Chen & Guestrin, 2016)
Bagging	کاهش تفسیرپذیری Reduced interpretability	کاهش واریانس؛ پایداری بالا Reduces variance; high stability	(Sagi & Rokach, 2018)
Random Committee	وابسته به کیفیت مدل پایه Dependent on quality of base learner	بهبود پایداری مدل پایه؛ ساده در اجرا Improves stability of the base model; easy to implement	(Dong <i>et al.</i> , 2020)
Random SubSpace	احتمال حذف ویژگی‌های مهم Reduces correlation among models; suitable for high-dimensional data	کاهش همبستگی بین مدل‌ها؛ مناسب داده‌های با ویژگی زیاد Possible removal of important features	(Kuncheva, 2014)
Decision Table	عملکرد ضعیف در روابط پیچیده Poor performance on complex relationships	تفسیرپذیری بالا؛ سادگی High interpretability; simple	(Fürnkranz <i>et al.</i> , 2012)
M5Rules	حساس به داده‌های نویزی Sensitive to noisy data	ترکیب درخت تصمیم و رگرسیون خطی؛ تفسیرپذیر و دقیق Combines decision trees with linear regression; interpretable and accurate	(Holmes <i>et al.</i> , 1999)
M5P	امکان بیش‌برازش در داده کم Possible overfitting with small datasets	مناسب روابط غیرخطی؛ ساختار قابل تفسیر Suitable for nonlinear relationships; interpretable	(Wang & Witten, 1997)
RBF Regressor	حساس به انتخاب مراکز و پارامتر Sensitive to selection of centers and parameters	همگرایی سریع‌تر از MLP؛ مناسب روابط موضعی Faster convergence than MLP; suitable for local relationships	(Wu <i>et al.</i> , 2012)

معیارهای ارزیابی عملکرد مدل‌ها

به منظور سنجش و مقایسه دقیق عملکرد مدل‌های منفرد و ترکیبی، از شاخص‌های آماری و معیارهای خطای زیر استفاده شد:

ضریب همبستگی (Correlation): این شاخص میزان همبستگی و ارتباط خطی بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده توسط مدل را نشان می‌دهد و مقدار آن بین -۱ تا +۱ تغییر می‌کند. هرچه مقدار این شاخص به ۱ نزدیک‌تر باشد، نشان‌دهنده تطابق بهتر بین داده‌های مشاهده‌ای و مقادیر برآورد شده توسط مدل است. معمولاً از توان دوم این ضریب استفاده می‌شود.

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}) \cdot (S_i - \bar{S})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \cdot \sum_{i=1}^n (S_i - \bar{S})^2} \quad (۱)$$

ریشه میانگین مربعات خطا (RMSE^۱): این شاخص یکی از متداول‌ترین معیارها برای ارزیابی دقت مدل‌ها است و میزان انحراف مقادیر پیش‌بینی شده از مقادیر مشاهده شده را نشان می‌دهد. مقدار کمتر RMSE نشان‌دهنده عملکرد بهتر مدل است.

این شاخص در بازه ۰ تا +۱ است و هرچه مقدار این شاخص به ۰ نزدیک‌تر باشد نشان‌دهنده دقت بالاتر است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - S_i)^2}{n}} \quad (۲)$$

میانگین قدر مطلق خطا (MAE^۲): این شاخص میانگین قدر مطلق اختلاف بین مقادیر مشاهده شده و پیش‌بینی شده را نشان می‌دهد و نسبت به خطاهای بزرگ حساسیت کمتری نسبت به RMSE دارد. مقدار کمتر MAE بیانگر دقت بیشتر مدل است. این شاخص در بازه ۰ تا +۱ است و هرچه مقدار این شاخص به ۰ نزدیک‌تر باشد نشان‌دهنده دقت بالاتر است.

$$MAE = \frac{\sum_{i=1}^n (O_i - S_i)}{n} \quad (۳)$$

میانگین توان دو خطا (MSE^۳): این شاخص میانگین مربع اختلاف بین مقادیر مشاهده شده و پیش‌بینی شده است و به دلیل مجذور شدن خطاها، نسبت به خطاهای بزرگ حساسیت بیشتری دارد. این شاخص در بازه ۰ تا +۱ است و هرچه مقدار این شاخص به ۰ نزدیک‌تر باشد نشان‌دهنده دقت بالاتر است.

$$MSE = \frac{\sum_{i=1}^n (O_i - S_i)^2}{n} \quad (۴)$$

بایاس (Bias): شاخص بایاس میزان تمایل مدل به بیش‌برآوردی یا کم‌برآوردی مقادیر را نشان می‌دهد. مقدار مثبت بیانگر بیش‌برآوردی و مقدار منفی نشان‌دهنده کم‌برآوردی مدل است و

هرچه به ۰ نزدیک‌تر باشد نزدیک‌تر بودن به مقادیر واقعی را نشان می‌دهد.

$$SE = \bar{O} - \bar{S} \quad (۵)$$

شاخص نش-ساتکلیف (NSE^۴): این شاخص یکی از معیارهای پرکاربرد در ارزیابی مدل‌های هیدرولوژیکی است و میزان کارایی مدل در بازتولید داده‌های مشاهده‌ای را نشان می‌دهد. مقدار این شاخص بین منفی بی‌نهایت تا ۱ تغییر می‌کند و هرچه مقدار آن به ۱ نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است.

$$NSE = \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۶)$$

O_i مقدار مشاهده شده در گام زمانی i

$\bar{O}$ میانگین مقدار مشاهداتی

$\bar{S}$ میانگین مقادیر پیش‌بینی شده

S_i مقدار پیش‌بینی شدت در گام زمانی i

n تعداد نمونه یا تعداد داده

کلیه این معیارها برای تمام مدل‌های منفرد و ترکیبی محاسبه شد تا بهترین ساختار مدل‌سازی بارش ماهانه در محدوده مطالعه انتخاب گردد.

نتایج و بحث

نتایج ارزیابی دقت ماهواره

پس از انتخاب ایستگاه‌های باران‌سنجی در محدوده حوضه آبریز دریاچه نمک ایستگاه‌های آغچه در استان اصفهان، ارتش‌آباد در استان قزوین، و ایستگاه‌های آراقلعه و احمدآباد در استان مرکزی طی دوره آماری ۱۰ ساله (۲۰۰۷ تا ۲۰۱۷) مورد بررسی قرار گرفتند و داده‌های بارش ماهانه این ایستگاه‌ها گردآوری شد و برای ارزیابی دقت داده‌های ماهواره‌ای CHIRPS مورد استفاده قرار گرفت. مقایسه بین داده‌های زمینی و داده‌های متناظر CHIRPS در مقیاس ماهانه انجام شد که نتایج آن در **جدول ۳** ارائه شده است. نتایج ارائه شده در **جدول ۳** بیانگر میانگین شاخص‌های آماری محاسبه شده برای کل ایستگاه‌ها است. به عبارت دیگر، پس از محاسبه شاخص‌های ارزیابی برای هر ایستگاه به صورت مجزا، مقادیر نهایی **جدول ۳** از طریق میانگین‌گیری از نتایج چهار ایستگاه به دست آمده‌اند تا عملکرد کلی داده‌های CHIRPS در سطح حوضه مورد مطالعه ارزیابی شود.

1- RMSE: Root Mean Square Error

2- MAE: Mean Absolute Error

3- MSE: Mean Square Error

4- NSE: Nash-Sutcliffe Model Efficiency

جدول ۳- نتایج ارزیابی دقت داده‌های CHIRPS در منطقه مورد مطالعه

Table 3- Accuracy assessment results of CHIRPS data in the study area

منبع داده Data Source	نش-سایتیف NSE (%)	میانگین قدر مطلق خطا MAE (%)	میانگین توان دو خطا MSE (%)	بایاس BAIAS (mm)	همبستگی Correlation (-)
CHIRPS	70.00	31.36	19.42	-00.09	0.71

پایین بودن قدرمطلق مقدار بایاس به معنای دقت بالاتر مدل در برآورد میانگین واقعی مشاهدات است. بنا بر نتایج، مدل Gaussian Processes کمترین مقدار بایاس را دارد (تقریباً ۰/۰۴) که بیانگر نزدیکی بیشتر نتایج پیش‌بینی‌شده توسط این مدل به میانگین مقادیر واقعی است. در مقابل، مدل Random SubSpace بیشترین مقدار بایاس را نشان می‌دهد (۰/۱۹) و بیانگر انحراف سیستماتیک بیشتر در پیش‌بینی‌های این مدل می‌باشد. بایاس مثبت به معنای بیش‌برآورد و بایاس منفی به معنای کم‌برآورد است. در شکل ۲ (دیگرام تیلور) برای مقایسه واضح‌تر مدل‌ها آورده شده است.


نمودار تیلور به‌منظور ارزیابی همزمان عملکرد مدل‌ها از نظر انحراف معیار، ضریب همبستگی و خطای میانگین مربعات خطا نسبت به داده‌های مشاهداتی به‌کار گرفته شد. در این نمودار، نقطه مرجع (Observed) نشان‌دهنده داده‌های مشاهداتی است که دارای ضریب همبستگی برابر با یک و مقدار میانگین مربعات خطا برابر با صفر می‌باشد. فاصله هر مدل از این نقطه، بیانگر میزان خطای آن نسبت به مشاهدات است. محور افقی در نمودار تیلور بیانگر انحراف معیار است که نشان‌دهنده دامنه تغییرات متغیر مورد بررسی می‌باشد. این پارامتر یک ویژگی آماری از سری زمانی بوده و نباید با شاخص‌های خطای مدل نظیر میانگین مربعات خطا اشتباه گرفته شود. ضریب همبستگی در نمودار تیلور به‌صورت زاویه‌ای نمایش داده می‌شود، به‌طوری که زاویه بین هر نقطه مدل و محور افقی متناظر با مقدار ضریب همبستگی آن مدل با داده‌های مشاهداتی است. مقادیر بزرگ‌تر ضریب همبستگی نشان‌دهنده تطابق بهتر الگوی تغییرات مدل با مشاهدات می‌باشند. در این نمودار، داده‌های مشاهداتی برابر با سری زمانی بارش ماهانه استخراج‌شده از پایگاه داده CHIRPS بوده است که به‌عنوان مرجع ارزیابی عملکرد مدل‌ها در نظر گرفته شد. لازم به ذکر است که این ارزیابی برای دوره آزمون مطالعه، شامل دو سال پایانی داده‌ها، انجام شده است. با توجه به نمودار، مدل M5Rules نزدیک‌ترین موقعیت را به نقطه‌ی مرجع دارد، که نشان‌دهنده دقت بالا، همبستگی قوی و انطباق مناسب با پراکندگی داده‌های واقعی است.

براساس این نتایج، مقدار R^2 برابر ۰/۷۱ نشان‌دهنده توان نسبتاً مناسب CHIRPS در توضیح تغییرات زمانی بارش در ایستگاه‌ها است. مقدار NSE حدود ۷۰ درصد نیز عملکرد قابل قبول این مجموعه داده در بازتولید الگوی بارش ماهانه را تأیید می‌کند. همچنین مقادیر MAE و MSE به‌ترتیب برابر با ۳۱/۳۶ و ۱۹/۴۲ درصد نشان می‌دهند که اگرچه همخوانی کلی مناسب است، اما بخشی از خطا باقی می‌ماند. مقدار BIAS منفی (۰/۰۹-) نیز حاکی از آن است که CHIRPS در مجموع تمایل اندکی به کم‌برآوردی بارش نسبت به داده‌های ایستگاهی دارد. با این حال، با توجه به گستردگی منطقه، پراکندگی ایستگاه‌ها و شرایط خشک و نیمه‌خشک حوضه، دقت به‌دست‌آمده قابل قبول بوده و استفاده از داده‌های CHIRPS برای تحلیل‌های بعدی در حوضه آبریز توجیه‌پذیر است.

عملکرد مدل‌های منفرد

در این بخش، عملکرد ۱۵ مدل یادگیری ماشین به‌صورت جداگانه برای پیش‌بینی بارش ماهانه در منطقه مورد مطالعه (حوضه آبریز دریاچه نمک) بررسی شده است. ارزیابی مدل‌ها بر اساس داده‌های آزمون (ژانویه ۲۰۲۲ تا دسامبر ۲۰۲۴) انجام شده و از شاخص‌هایی همچون ضریب همبستگی، ریشه میانگین مربع خطا (RMSE)، میانگین قدرمطلق خطا (MAE) استفاده گردیده است. در ادامه در جدول ۴ نتایج پیش‌بینی مدل‌ها آورده شده است.

نتایج جدول ۴ نشان می‌دهد که؛ عملکرد مدل‌ها نه تنها به میزان خطای کلی (MAE و MSE) بلکه به ترکیب بایاس سیستماتیک و پراکندگی خطاها وابسته است. مدل‌هایی مانند M5Rules و Additive Regression دارای بایاس کم، پراکندگی پایین و میانه قدرمطلق خطای کوچک هستند که نشان‌دهنده پیش‌بینی دقیق و پایدار است. در مقابل، مدل‌هایی مانند IBk با پراکندگی بالای خطا و بایاس قابل توجه، علی‌رغم میانه خطای نسبتاً پایین، برخی پیش‌بینی‌های پرت داشته و MSE بالاتری ثبت کرده‌اند. میانه قدرمطلق خطاها شاخص ناپارامتری خطا است که حساسیت کمتری به نقاط پرت دارد و نشان می‌دهد که خطای غالب مدل‌ها در بیشتر نمونه‌ها چقدر است. بنابراین این مجموع شاخص‌ها تصویر کامل‌تر و دقیق‌تری از عملکرد مدل‌ها ارائه می‌دهد.



شکل ۲- نمودار تیلور عملکرد مدل‌ها در پیش‌بینی بارش ماهانه طی دوره آزمون

Figure 2- Taylor diagram of the performance of the models monthly precipitation prediction during the test period

می‌شود، عملکرد قابل قبولی دارند، اما در مواجهه با ماه‌های با رفتار غیرخطی یا پراکندگی شدید داده‌ها عملکرد ضعیف‌تری نشان می‌دهند. در مجموع، بهتر عمل کردن برخی مدل‌ها نتیجه ترکیبی از توانایی آن‌ها در مدیریت غیرخطی بودن داده‌ها، میزان حساسیت به نقاط پرت، قابلیت تعمیم‌پذیری و نحوه یادگیری الگوهای زمانی است. این تحلیل کمک می‌کند تا تفاوت مدل‌ها از دیدگاه علمی و بر اساس ماهیت آماری داده‌های بارش توضیح داده شود.

ترکیب مدل‌ها با وزن‌دهی ساده (میانگین ساده)

در مدل‌های ترکیبی، هر الگوریتم می‌تواند بخشی از فرآیند یادگیری و پیش‌بینی را بر اساس ویژگی‌های خاص خود انجام دهد. به عبارت دیگر، الگوریتم‌های مختلف دارای توانایی‌های متفاوتی در استخراج الگوهای داده هستند؛ به‌طوری‌که برخی مدل‌ها در شناسایی روابط غیرخطی پیچیده عملکرد بهتری دارند، در حالی که برخی دیگر در تعمیم‌پذیری و کاهش خطای پیش‌بینی مؤثرتر عمل می‌کنند. ترکیب این مدل‌ها می‌تواند با بهره‌گیری همزمان از نقاط قوت آن‌ها موجب بهبود عملکرد نهایی شود. در این پژوهش ترکیب‌های مختلفی از مدل‌ها مورد بررسی قرار گرفت تا مشخص شود کدام ترکیب قادر است خطای پیش‌بینی را کاهش داده و دقت مدل را افزایش دهد. با توجه به تعداد مدل‌های مورد استفاده، در مجموع ۱۰۵ حالت مختلف از ترکیب مدل‌ها ایجاد شد که بررسی همه آن‌ها در متن مقاله

پس از آن، مدل‌های Additive Regression و Random Forest نیز عملکرد قابل قبولی داشته‌اند. در مقابل، مدل‌هایی مانند IBk و RBF Regressor در فاصله دورتری از نقطه مرجع قرار دارند که نشان‌دهنده خطای بیشتر و همبستگی ضعیف‌تر آن‌ها است. نتایج حاصل از ارزیابی مدل‌ها نشان می‌دهد که تفاوت در عملکرد آن‌ها ناشی از ویژگی‌های الگوریتمی و نحوه یادگیری الگوهای موجود در داده‌های بارش است. مدل‌هایی که ساختار مبتنی بر درخت تصمیم دارند (نظیر جنگل تصادفی) معمولاً توانایی بالایی در شناسایی روابط غیرخطی و تعامل میان متغیرها دارند و در داده‌هایی با نوسان‌های شدید و رفتارهای غیرخطی، عملکرد پایدارتر و مقاوم‌تری نشان می‌دهند. این ویژگی سبب شده تا این مدل‌ها در بسیاری از ماه‌ها خطای کمتری نسبت به سایر روش‌ها داشته باشند. از سوی دیگر، مدل‌های شبکه عصبی مانند MLP قادرند الگوهای پیچیده‌تری را در داده‌ها بیاموزند، اما عملکرد آن‌ها به مقدار داده، ساختار شبکه و تنظیم پارامترها بسیار حساس است. در داده‌های بارش ماهانه که از نظر حجم محدود بوده و رفتارهای ناگهانی و غیرایستا دارند، حساسیت این مدل‌ها می‌تواند منجر به نوسان در دقت پیش‌بینی شود. با این حال، در ماه‌هایی که الگوی بارش دارای ساختار قابل یادگیری است، مدل MLP نتایج بسیار خوبی ارائه می‌دهد. مدل‌های خطی یا ساده‌تر در شرایطی که رابطه میان ورودی و خروجی کمتر پیچیده است یا تغییرات نسبتاً منظم‌تری مشاهده

نهایت ۱۲ مدل ترکیبی برتر از میان ۱۰۵ حالت که کارایی بالایی داشته‌اند آورده شده است؛ که در **جدول ۵** نمایش داده شده است.

جدول ۵ نشان می‌دهد که؛ مقایسه عملکرد مدل‌های منفرد و بهترین ترکیب هر مدل را از نظر شاخص نش-ساتکلیف (NSE) نشان می‌دهد. همان‌طور که مشخص است؛ در تمامی موارد، مقدار NSE برای ترکیب مدل‌ها بالاتر از حالت منفرد است. این موضوع بیانگر آن است که؛ ترکیب ساده دو مدل می‌تواند به‌طور معناداری دقت پیش‌بینی را افزایش دهد. بیشترین بهبود مربوط به مدل‌هایی است؛ که در حالت منفرد عملکرد ضعیف‌تری داشته‌اند، از جمله IBk که به تنهایی NSE ۳۴/۳ را دارد و پس از ترکیب شدن با مدل Decision Table عملکرد آنها به ۷۴/۴ می‌رسد و RBF Regressor که به تنهایی NSE ۴۷/۷ را داشته‌اند با ترکیب شدن با مدل Decision Table، NSE به ۸۲/۴ دست می‌یابند در همچنین، مدل‌هایی در حالت منفرد نیز عملکرد خوبی داشتند، در ترکیب نیز دقت بالاتری حفظ کرده‌اند مانند Additive Regression با NSE ۷۵/۲ پس از ترکیب شدن با مدل M5Rules به عملکرد ۸۷/۰ می‌رسد (M5Rules نیز به تنهایی عملکرد ۸۰/۰ را داشته است). این یافته‌ها اثبات می‌کند که رویکرد ترکیب دو به دو، نه تنها ضعف برخی مدل‌ها را جبران می‌کند، بلکه می‌تواند پایداری دقت پیش‌بینی را نیز افزایش دهد.

MAE برای مدل‌های ترکیبی نشان می‌دهد؛ که ترکیب Additive Regression - M5Rules با مقدار MAE برابر با ۱۵/۵، کمترین میزان خطای مطلق را دارد. این مسئله بیانگر آن است که این مدل، در پیش‌بینی بارش‌ها، به‌طور میانگین کمترین انحراف از مقادیر واقعی را داشته است. مدل‌های Decision Table - M5Rules و Additive Regression - M5P نیز با MAE های نزدیک به این مقدار، در رتبه‌های دوم و سوم قرار دارند

امکان‌پذیر نیست؛ از این‌رو تنها نتایج مهم‌ترین و کاراترین ترکیب‌ها ارائه شده است. لازم به ذکر است که؛ در روش‌های ترکیب مدل‌ها، انتخاب مدل‌ها صرفاً بر اساس بهترین عملکرد منفرد آنها انجام نمی‌شود. در بسیاری از موارد، مدل‌هایی که به‌صورت جداگانه دقت بالایی دارند ممکن است الگوی خطای مشابهی داشته باشند و در نتیجه ترکیب آن‌ها به بهبود قابل توجهی در نتایج منجر نشود. در مقابل، ترکیب مدل‌هایی که دارای الگوهای خطای متفاوت یا مکمل هستند می‌تواند منجر به کاهش خطای کلی شود. به بیان دیگر، در شرایطی که یک مدل در برخی زمان‌ها دچار بیش‌برآورد و مدل دیگر کم‌برآورد باشد، ترکیب خروجی آن‌ها می‌تواند این خطاها را تا حدی خنثی کرده و عملکرد بهتری نسبت به هر مدل به‌صورت منفرد ارائه دهد. بر همین اساس، در این پژوهش ترکیب‌های مختلفی از مدل‌ها مورد بررسی قرار گرفت تا ترکیبی که بیشترین توانایی در کاهش خطا و بهبود دقت پیش‌بینی دارد شناسایی شود.

در این مرحله، به‌منظور افزایش دقت پیش‌بینی، مدل‌های منتخب به‌صورت دو به دو با یکدیگر ترکیب شدند. در هر ترکیب، مقدار نهایی پیش‌بینی‌شده، میانگین حسابی خروجی دو مدل پایه بود. این رویکرد منجر به تولید ۱۰۵ حالت ترکیبی مختلف شد. میانگین حسابی یکی از ساده‌ترین و در عین حال پرکاربردترین روش‌ها در ترکیب مدل‌ها محسوب می‌شود و به‌دلیل توانایی آن در کاهش اثر خطاهای منفرد مدل‌ها، می‌تواند منجر به بهبود پایداری و دقت پیش‌بینی شود. در این روش، مقدار پیش‌بینی نهایی از طریق میانگین‌گیری از خروجی مدل‌های منتخب به‌دست می‌آید.

هدف از این بخش بررسی این موضوع بود که؛ آیا ترکیب مدل‌ها می‌تواند عملکرد بهتری نسبت به مدل‌های منفرد ارائه دهد یا خیر؟ برای این منظور، شاخص‌های ارزیابی ضریب همبستگی، MAE، MSE، NSE، BIAS برای تمام ترکیب‌ها محاسبه گردید. در

جدول ۵- معیارهای ارزیابی ۱۲ ترکیب برتر مدل‌ها

Table 5- Evaluation metrics of the top 12 model combinations

مدل MODEL	میانگین خطای مطلق MAE (%)	میانگین مربعات خطا MSE (%)	شاخص نش-ساتکلیف NSE (-)	همبستگی Correlation (-)	بایاس BAIAS (mm)
Gaussian Processes -Additive Regression	18.41	06.00	0.846	0.878	-0.119
Gaussian Processes -Decision Table	21.91	06.91	0.824	0.892	-0.213
Gaussian Processes -M5Rules	23.30	07.51	0.809	0.939	-0.135
Random Forest-Additive Regression	18.10	06.90	0.825	0.885	-0.187
Random Forest-M5Rules	21.61	07.71	0.803	0.944	-0.203
RBF Regressor-Decision Table	21.52	06.63	0.831	0.680	-0.049
Linear Regression -Additive Regression	22.18	07.59	0.808	0.852	-0.235
SMOreg -Decision Table	20.63	06.31	0.838	0.755	-0.039
LWL-M5Rules	19.76	07.81	0.801	0.685	-0.173
Additive Regression-M5Rules	15.55	05.08	0.873	0.832	-0.015
Additive Regression-M5P	0.18.02	06.20	0.841	0.768	-0.020
Decision Table-M5Rules	17.80	06.61	0.831	0.856	-0.272

این مدل‌ها توانسته‌اند با حفظ دقت بالا، پیش‌بینی‌هایی کم‌خطا در اغلب بازه‌های زمانی ارائه دهند. در مقابل، ترکیب Gaussian Processes - M5Rules با MAE برابر با ۰/۲۳۳، بیشترین خطای مطلق را داشته و عملکرد نسبتاً ضعیف‌تری در این شاخص نشان داده است. شاخص MSE که به خطاهای بزرگ‌تر حساس‌تر است، روندی مشابه با MAE را نشان می‌دهد. مدل Additive Regression - M5Rules با MSE برابر با ۰/۰۵ بهترین عملکرد را از نظر کمترین میزان خطای مربعی دارد. مدل‌های Additive Regression - M5P و Gaussian Processes - Additive Regression نیز با مقادیر نزدیک، عملکرد نسبتاً خوبی از خود نشان داده‌اند. در این شاخص نیز، مدل Gaussian Processes - M5Rules با MSE برابر با ۰/۰۷۵ در رتبه پایین‌تری قرار گرفته و بیانگر آن است که برخی از پیش‌بینی‌های این مدل دارای خطاهای بزرگ‌تری بوده‌اند. عملکرد ضعیف‌تر مدل Gaussian Processes - M5Rules در شاخص MSE به این دلیل است که این مدل در برخی نمونه‌ها دچار خطاهای نسبتاً بزرگ‌تری شده است. ترکیب ساختاری این مدل، که شامل قواعد M5Rules و فرآیندهای گاوسی است. در نتیجه، اگرچه عملکرد کلی مدل مناسب است، اما وجود چند پیش‌بینی با انحراف زیاد باعث افزایش MSE و قرار گرفتن آن در رتبه پایین‌تر شده است. نمودار ضریب همبستگی نشان می‌دهد که؛ مدل‌های ترکیبی مبتنی بر درختان تصمیم به‌ویژه ترکیب Random Forest - M5Rules بالاترین میزان تطابق زمانی را با داده‌های واقعی داشته‌اند. این مدل‌ها قادرند نوسانات غیرخطی و تغییرات ناگهانی بارش را بهتر دنبال کنند، زیرا ساختار درختی آن‌ها الگوهای شاخه‌ای و تغییرات رژیمی را به‌خوبی بازنمایی می‌کند. در مقابل، ترکیب‌هایی که شامل مدل‌های مبتنی بر توابع شعاعی یا همسایگی بوده‌اند (مانند RBF Regressor - Decision Table)، همبستگی پایین‌تری با سری زمانی مشاهده‌شده داشته‌اند. دلیل این موضوع، ویژگی ذاتی این مدل‌ها در هموارسازی خروجی است؛ این دسته مدل‌ها تمایل دارند تغییرات تند و نوسانات ریزمقیاس بارش را تعدیل کنند، بنابراین تطابق زمانی آن‌ها با رفتار واقعی بارش کاهش می‌یابد. مدل‌های درختی الگوهای غیرخطی و نقاط شکست را بهتر تشخیص می‌دهند، در حالی که مدل‌های مبتنی بر توابع پایه رفتار هموارتری ارائه می‌کنند و نوسانات واقعی را کمتر منعکس می‌سازند.

وزن‌دهی به روش BruteForce


در این روش از صفر تا یک به هر مدل با گام ۰/۰۱ وزن داده می‌شود؛ به‌طوری‌که مجموع وزن مدل‌ها، یک می‌شود. تمام حالت‌های تحلیل مقایسه‌ای ارائه شده در زیر، تفاوت‌های عملکردی بین دو رویکرد میانگین‌گیری ساده (Simple Average) و

BruteForce را بر اساس شاخص ضریب نش-ساتکلیف بررسی می‌کند. در این روش تمام ترکیب‌های ممکن از وزن‌ها بررسی می‌شود تا بهترین حالت پیدا شود. شکل ۳ نتایج وزن‌دهی ساده در مقابل وزن‌دهی به روش BruteForce را نشان می‌دهد.

بررسی عملکردی در شکل ۳، تفاوت کارایی بین دو استراتژی ترکیب مدل‌ها، یعنی روش میانگین‌گیری ساده (Simple Average) و روش وزن‌دهی بهینه (BruteForce) را به خوبی آشکار می‌سازد. در نگاه کلی، مشاهده می‌شود که روش BruteForce با اختصاص وزن‌های بهینه به ترکیب‌های دوگانه مدل‌ها، توانسته است مقادیر شاخص NSE را در اکثر خانه‌های ماتریس بهبود ببخشد. با مقایسه دقیق‌تر دو نمودار، مشخص است که؛ در روش میانگین‌گیری ساده، رنگ‌های تیره‌تر (بنفش و سرمه‌ای) که نشان‌دهنده NSE پایین هستند، به‌ویژه در ترکیب‌هایی که شامل مدل‌های ضعیف‌تری همچون RBF Regressor و IBk می‌شوند، بیشتر دیده می‌شود. این موضوع نشان می‌دهد که در روش میانگین‌گیری ساده، ضعف‌های یک مدل به‌طور مستقیم بر خروجی نهایی ترکیب اثر منفی می‌گذارد. در مقابل، در نمودار مربوط به رویکرد BruteForce، بخش بزرگی از ماتریس به طیف رنگی زرد و سبز روشن متمایل شده است که نشان‌دهنده ارتقای سطح دقت به محدوده NSE بالای ۰/۸۰ است. به‌عنوان مثال، ترکیب مدل M5Rules با سایر الگوریتم‌ها در روش Brute Force به‌طور مداوم مقادیری NSE بالای ۰/۸۴ را ثبت کرده است، در حالی‌که در روش میانگین‌گیری ساده، این مقادیر نوسان بیشتری دارند. این برتری به این دلیل است که الگوریتم BruteForce با جستجوی سیستماتیک، وزن مدل‌های دارای خطای بالا را کاهش داده و بر وزن مدل‌های دقیق‌تر در ترکیب نهایی می‌افزاید. در مجموع، نتایج نشان می‌دهد که اگرچه میانگین‌گیری ساده روشی سریع و بدون پیچیدگی محاسباتی است، اما استفاده از روش‌های وزن‌دهی هوشمند مانند BruteForce می‌تواند به‌طور قابل توجهی خطاهای هم‌پوشان را خنثی کرده و عملکرد سیستم‌های ترکیبی را به سطحی بالاتر از تک‌تک مدل‌های پایه ارتقا دهد.

جمع‌بندی تحلیل نتایج

تحلیل جامع نتایج به‌دست‌آمده از مدل‌های منفرد و ترکیبی نشان می‌دهد که؛ دقت پیش‌بینی بارش ماهانه نه‌تنها به نوع الگوریتم مورد استفاده، بلکه به نحوه تعامل و هم‌پوشانی خطاهای مدل‌ها وابسته است. نتایج مدل‌های منفرد حاکی از آن است که الگوریتم‌های مبتنی بر قواعد و درخت تصمیم، به‌ویژه M5Rules و Additive Regression، توانایی بالاتری در بازنمایی رفتار غیرخطی و نوسانات زمانی بارش دارند؛ موضوعی که در مقادیر بالاتر شاخص نش-ساتکلیف و خطای کمتر آن‌ها مشهود است.



شکل ۳- مقایسه روش Brute Force و میانگین ساده

Figure 3- Comparison of the Brute Force method and simple averaging

نتیجه‌گیری

نتایج این پژوهش نشان داد که داده‌های CHIRPS قادرند الگوی زمانی بارش ماهانه را در حوضه مورد مطالعه با دقت قابل‌قبولی بازنمایی کنند. مقادیر شاخص‌های ارزیابی حاکی از آن است که؛ این داده‌ها می‌توانند به‌عنوان منبع ورودی مناسب برای مدل‌های پیش‌بینی بارش مورد استفاده قرار گیرند. این موضوع نشان می‌دهد که؛ در شرایط محدودیت داده‌های ایستگاهی، استفاده از محصولات ماهواره‌ای می‌تواند نقش مؤثری در بهبود تحلیل‌های هیدرولوژیکی و توسعه مدل‌های پیش‌بینی ایفا کند. همچنین استفاده از رویکردهای ترکیب مدل‌ها می‌تواند دقت پیش‌بینی بارش ماهانه را نسبت به مدل‌های منفرد بهبود دهد. عملکرد بهتر مدل ترکیبی بیانگر آن است که؛ مدل‌های مختلف توانایی استخراج جنبه‌های متفاوتی از الگوهای زمانی بارش را دارند و ترکیب آن‌ها موجب کاهش خطاهای فردی مدل‌ها و افزایش پایداری پیش‌بینی می‌شود. این نتیجه با برخی مطالعات اخیر که به برتری روش‌های ensemble در مسائل پیش‌بینی بارش اشاره کرده‌اند هم‌راستا است (Ghosh et al., 2023; Lin et al., 2025). بنابراین می‌توان بیان کرد که بهره‌گیری هم‌زمان از داده‌های CHIRPS و رویکردهای ترکیب مدل‌ها، چارچوبی کارآمد برای بهبود پیش‌بینی بارش ماهانه در حوضه‌های دارای محدودیت داده‌های زمینی فراهم می‌کند.

ارزیابی دقت داده‌های CHIRPS با استفاده از چندین شاخص آماری شامل شاخص نش-ساتکیف (NSE)، میانگین قدر مطلق خطا (MAE)، میانگین مربعات خطا (MSE) و شاخص بایاس (BIAS) نشان داد؛ که این پایگاه داده توانایی مناسبی در بازنمایی تغییرات زمانی بارش ماهانه دارد. ترکیب این شاخص‌ها بیانگر آن است که داده‌های CHIRPS علاوه بر داشتن همبستگی مناسب با داده‌های ایستگاهی، از نظر میزان خطا و سوگیری نیز عملکرد قابل‌قبولی دارند و می‌توانند به‌عنوان ورودی قابل اعتماد برای مدل‌های پیش‌بینی بارش مورد استفاده قرار گیرند. در مرحله مدل‌سازی، مقایسه عملکرد ۱۵ مدل مختلف یادگیری ماشین نشان داد که؛ توان پیش‌بینی مدل‌ها، تفاوت معناداری با یکدیگر دارد. در میان مدل‌های منفرد، الگوریتم‌های M5Rules، Additive Regression و Random Forest عملکرد بهتری نسبت به سایر مدل‌ها از خود نشان دادند. این برتری را می‌توان به توان بالای این مدل‌ها در شناسایی روابط غیرخطی، استخراج قواعد تصمیم‌گیری و کاهش خطاهای ساختاری نسبت داد. نتایج به‌دست‌آمده نشان می‌دهد که مدل‌های مبتنی بر درخت و قواعد، برای مدل‌سازی رفتار پیچیده و ناپایدار بارش ماهانه در مناطق خشک، کارایی بالاتری دارند.

همچنین یافته‌های اصلی پژوهش نشان داد که ترکیب مدل‌های

با این حال، نتایج نشان داد که حتی مدل‌هایی با عملکرد مناسب در حالت منفرد، در برخی بازه‌های زمانی دچار بایاس یا پراکندگی خطا می‌شوند. ترکیب دو به دوی مدل‌ها موجب کاهش این نارسایی‌ها شده و از طریق جبران متقابل خطاها، پایداری پیش‌بینی‌ها را افزایش داده است. توزیع مقادیر شاخص NSE برای ۱۰۵ ترکیب مختلف نشان داد که بخش قابل‌توجهی از ترکیب‌ها عملکردی بهتر از مدل‌های پایه داشته‌اند که بیانگر عمومی بودن مزیت رویکرد ترکیبی و عدم وابستگی آن به یک مدل خاص است.

مقایسه روش میانگین‌گیری ساده و وزن‌دهی BruteForce نشان داد که؛ اگرچه وزن‌دهی بهینه می‌تواند در برخی ترکیب‌ها منجر به بهبود بیشتر دقت شود، اما میانگین‌گیری ساده نیز بدون افزایش پیچیدگی محاسباتی، توانسته است به نتایجی رقابتی و پایدار دست یابد. این موضوع نشان می‌دهد که بهبود عملکرد صرفاً ناشی از افزایش پیچیدگی یا تعداد پارامترها نیست، بلکه از هم‌پوشانی ساختاری و مکمل بودن رفتار مدل‌ها حاصل می‌شود.

به‌طور کلی، برتری مدل‌های ترکیبی نسبت به مدل‌های منفرد را می‌توان با مبانی نظری تجمیع مدل‌ها توضیح داد. ترکیب چند مدل باعث می‌شود هر مدل سهمی از اطلاعات ورودی را که مدل‌های دیگر قادر به استخراج آن نیستند پوشش دهد و در نتیجه خطاهای ساختاری و بایاس مدل‌ها تا حدی یکدیگر را جبران کنند. افزون بر این، از آن‌جا که خطاهای مدل‌ها لزوماً همبستگی کامل ندارند، تلفیق خروجی‌ها منجر به کاهش واریانس پیش‌بینی و افزایش پایداری نتایج می‌گردد. در نهایت، وزن‌دهی بهینه در مدل ترکیبی موجب می‌شود سهم مدل‌هایی که عملکرد بهتری دارند افزایش یافته و مدل‌هایی با خطای بیشتر تأثیر کمتری در خروجی نهایی داشته باشند. مجموعه این عوامل موجب شده است که مدل ترکیبی در این مطالعه دقت بالاتری نسبت به مدل‌های منفرد ارائه دهد. یکی از دغدغه‌های اصلی در استفاده از مدل‌های ترکیبی، خطر بیش‌برازش است. در این پژوهش، برای کاهش این ریسک، چند اقدام اساسی انجام شد: نخست، تفکیک زمانی صریح داده‌ها به دوره آموزش و آزمون مستقل؛ دوم، ارزیابی عملکرد مدل‌ها صرفاً بر اساس داده‌های آزمون؛ و سوم، استفاده از روش میانگین‌گیری ساده که برخلاف ترکیب‌های پیچیده، احتمال بیش‌برازش را کاهش می‌دهد. همچنین پایداری نتایج در شاخص‌های مختلف و کاهش هم‌زمان MAE، MSE و بایاس نشان می‌دهد که بهبود عملکرد مدل‌ها ناشی از یادگیری الگوهای واقعی داده بوده. در مجموع، نتایج این بخش نشان می‌دهد که رویکرد ترکیبی پیشنهادی قادر است بدون ایجاد بیش‌برازش آشکار، دقت و پایداری پیش‌بینی بارش ماهانه را افزایش دهد.

وزن‌دهی مبتنی بر عملکرد مدل‌ها، میانگین وزنی پویا و سایر تکنیک‌های Ensemble، می‌تواند به بهبود دقت پیش‌بینی کمک کند. به کارگیری الگوریتم‌های پیشرفته‌تر یادگیری ماشین و یادگیری عمیق نیز می‌تواند در استخراج الگوهای زمانی پیچیده بارش مؤثر باشد. علاوه بر این، استفاده از متغیرهای ورودی بیشتر شامل پارامترهای هواشناسی و اقلیمی نظیر دما، رطوبت نسبی، فشار هوا و شاخص‌های اقلیمی بزرگ‌مقیاس، در کنار داده‌های سنجش‌ازدور، می‌تواند عملکرد مدل‌ها را بهبود دهد. ارزیابی روش‌های پیشنهادی در مناطق جغرافیایی و اقلیمی مختلف نیز برای بررسی میزان تعمیم‌پذیری مدل‌ها ضروری است. همچنین استفاده از روش‌های پیش‌پردازش داده، انتخاب ویژگی و کاهش ابعاد می‌تواند به کاهش نویز داده‌ها و افزایش دقت پیش‌بینی کمک کند. در نهایت، تحلیل عدم قطعیت مدل‌ها و بررسی حساسیت نتایج نسبت به متغیرهای ورودی می‌تواند به افزایش قابلیت اعتماد و کاربردپذیری نتایج در مطالعات منابع آب و مدیریت اقلیم کمک نماید.

مقایسه عملکرد مدل‌های مختلف نشان داد که؛ برخی از الگوریتم‌های یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر قواعد مانند M5Rules و مدل‌های تقویتی نظیر Additive Regression، توانایی بیشتری در بازنمایی تغییرات زمانی بارش ماهانه دارند. همچنین نتایج نشان داد که استفاده از رویکرد ترکیب مدل‌ها موجب بهبود شاخص‌های ارزیابی نسبت به بسیاری از مدل‌های منفرد شده است. این موضوع بیانگر آن است که ترکیب مدل‌های مختلف می‌تواند با بهره‌گیری از قابلیت‌های مکمل آن‌ها، دقت پیش‌بینی را افزایش داده و پایداری نتایج را در مدل‌سازی بارش ماهانه بهبود بخشد.

یادگیری ماشین به‌صورت دو به دو، به‌طور کلی منجر به بهبود قابل توجه دقت پیش‌بینی نسبت به مدل‌های منفرد می‌شود. این بهبود ناشی از هم‌پوشانی نقاط قوت مدل‌ها و کاهش اثر خطاهای سیستماتیک هر یک از الگوریتم‌ها است. در میان تمامی ترکیب‌های بررسی‌شده، مدل ترکیبی Additive Regression - M5Rules با دستیابی به مقادیر شاخص نش-ساتکلیف ۰/۸۸، به‌عنوان بهترین ساختار پیش‌بینی شناسایی شد. کاهش قابل توجه خطا و بایاس پایین این مدل نشان‌دهنده پایداری و قابلیت اعتماد بالای آن در پیش‌بینی بارش ماهانه است. مقایسه این مدل با بهترین مدل‌های منفرد نیز نشان داد که حتی الگوریتم‌هایی با عملکرد مطلوب در حالت منفرد، در قالب ترکیبی می‌توانند دقت بالاتری ارائه دهند.

از منظر مدیریت منابع آب، نتایج این پژوهش اهمیت ویژه‌ای دارد. پیش‌بینی دقیق بارش ماهانه یکی از ورودی‌های اساسی در مدل‌های هیدرولوژیکی، مدیریت مخازن، برنامه‌ریزی تخصیص آب و ارزیابی خشکسالی است. بهبود دقت این پیش‌بینی‌ها می‌تواند منجر به کاهش عدم قطعیت در تصمیم‌گیری‌های مدیریتی، افزایش بهره‌وری بهره‌برداری از منابع آب و بهبود ارزیابی سناریوهای آینده اقلیمی شود. در حوضه‌هایی نظیر دریاچه نمک که با کمبود داده‌های زمینی مواجه‌اند، تلفیق داده‌های CHIRPS با مدل‌های ترکیبی یادگیری ماشین می‌تواند به‌عنوان یک چارچوب عملی و قابل تعمیم برای پشتیبانی از مدیریت پایدار منابع آب مورد استفاده قرار گیرد. با توجه به نتایج به‌دست‌آمده و محدودیت‌های موجود در این پژوهش، پیشنهاد می‌شود در مطالعات آینده از دوره‌های زمانی طولانی‌تر برای آموزش و به‌ویژه ارزیابی مدل‌ها استفاده شود تا پایداری و قابلیت تعمیم نتایج در شرایط اقلیمی مختلف بهتر بررسی گردد. همچنین بررسی و مقایسه روش‌های مختلف وزن‌دهی در مدل‌های ترکیبی، مانند روش‌های

References

1. Abdollahi, M., Abedi, K.J., & Matinzadeh, M. (2024). The effect of the sub-basins area and methods of calculating concentration time on the simulation of urban runoff volume using SewerGEMS software (Case study: Shahrekord). <https://doi.org/10.47176/jwss.28.3.49834>
2. Abinaya, P., & Janani, N. (2020). Rainfall forecasting using Weka data mining tool. *International Research Journal of Engineering and Technology*, 7(03).
3. Abishek, B., Priyatharshini, R., Eswar, M.A., & Deepika, P. (2017). Prediction of effective rainfall and crop water needs using data mining techniques. *2017 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR)*. <https://doi.org/10.1109/TIAR.2017.8273722>
4. Amrehn, M., Mualla, F., Angelopoulou, E., Steidl, S., & Maier, A. (2018). The random forest classifier in WEKA: Discussion and new developments for imbalanced data. *arXiv preprint arXiv:1812.08102*. <https://doi.org/10.48550/arXiv.1812.08102>
5. Beck, H.E., Pan, M., Roy, T., Weedon, G.P., Pappenberger, F., Van Dijk, A.I., Huffman, G.J., Adler, R.F., & Wood, E.F. (2019). Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. *Hydrology and Earth System Sciences*, 23(1), 207–224. <https://doi.org/10.5194/hess-23-207-2019>, 2019
6. Babaei Hesar, S., & Ghazavi, R. (2014). Comparison of TS and ANN models with the results of emission scenarios in rainfall prediction. *Journal of Soil and Water*. <https://doi.org/10.22067/jsw.v0i0.10261>
7. Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197–227. <https://doi.org/10.1007/s11749-016-0481-7>

8. Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189–215. <https://doi.org/10.1016/j.neucom.2019.10.118>
9. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
10. Dong, X., Yu, Z., Cao, W., Shi, Y., & Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14(2), 241–258. <https://doi.org/10.1007/s11704-019-8208-z>
11. Fürnkranz, J., Gamberger, D., & Lavrač, N. (2012). *Foundations of Rule Learning*. Springer. <https://doi.org/10.1007/978-3-540-75197-7>
12. Fagan, M.E., & DeFries, R.S. (2024). Remote sensing and image processing. In S. M. Scheiner (Ed.), *Encyclopedia of Biodiversity* (3rd ed., pp. 432–445). Academic Press. <https://doi.org/10.1016/B978-0-12-822562-2.00060-8>
13. Fallah-Ghalhari, Gh.A., Mousavi Baygi, M., & Habibi Nokhandan, M. (2009). Results compression of Mamdani fuzzy interface system and artificial neural networks in the seasonal rainfall prediction (Case study: Khorasan region).
14. Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., & Hoell, A. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific Data*, 2(1), 1–21. <https://doi.org/10.1038/sdata.2015.66>
15. Fikileni, S., & Wolski, P. (2022). Framework for implementation of the Pitman-WR2012 model in seasonal hydrological forecasting: A case study of Kraai River, South Africa. *Water SA*, 48(1), 62–74. <https://doi.org/10.17159/WSA/2022.V48.I1.3891>
16. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://doi.org/10.4258/hir.2016.22.4.351>
17. Ghosh, S., Gourisaria, M.K., Sahoo, B., & Das, H. (2023). A pragmatic ensemble learning approach for rainfall prediction. *Discover Internet of Things*, 3(13). <https://doi.org/10.1007/s43926-023-00044-3>
18. Haddadi, A., & Yazdi, M. (2025). Performance assessment of the extreme gradient boosting machine model in forecasting precipitation depth to improve precipitation estimation accuracy in data-scarce regions. *Journal of Irrigation and Water Engineering*. <https://doi.org/10.22034/iwrr.2025.543507.2944>
19. Holmes, G., Hall, M., & Frank, E. (1999). Generating rule sets from model trees. *Australian Joint Conference on Artificial Intelligence* (pp. 1–12). Springer. https://doi.org/10.1007/3-540-46695-9_1
20. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning: with Applications in R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4614-7138-7>
21. Kumar, P.S., & Swathi, M.N. (2023). Rainfall prediction using ada boost machine learning ensemble algorithm. *Journal of Advanced Applied Scientific Research*, 5(4), 67–81. <https://doi.org/10.46947/joaasr542023682>
22. Kuncheva, L.I. (2014). *Combining Pattern Classifiers: Methods and Algorithms* (2nd ed.). John Wiley & Sons. <https://doi.org/10.1109/TNN.2007.897478>
23. Mahjoobi, E., & Rafiei, F. (2025). Exploring the potential of geospatial data: An in-depth. In *Exploring Remote Sensing-Methods and Applications* (p. 113). <https://doi.org/10.5772/intechopen.1006999>
24. Lin, S.-S., Zhu, K.-Y., Wang, C.-Y., Yang, C.-P., & Liu, M.-Y. (2025). Ensemble Learning-Based Soft Computing Approach for Future Precipitation Analysis. *Atmosphere*, 16(6), 669. <https://doi.org/10.3390/atmos16060669>
25. Oswal, N. (2019). Predicting rainfall using machine learning techniques. *arXiv preprint arXiv:1910.13827*. <https://doi.org/10.48550/arXiv.1910.13827>
26. Omary, A., Wedyan, A., Zghoul, A., Banihani, A., & Alsmadi, I. (2012). An interactive predictive system for weather forecasting. *2012 International Conference on Computer, Information and Telecommunication Systems (CITS)*. <https://doi.org/10.1109/CITS.2012.6220375>
27. Patel, A., Keriwala, N., Soni, N., Goel, U., Bhoj, R., Adhyaru, Y., & Yadav, S. (2023). Rainfall prediction using machine learning techniques for Sabarmati River Basin, Gujarat, India. *Journal of Engineering Science & Technology Review*, 16(1). <https://doi.org/10.25103/jestr.161.13>
28. Ramani, K., Reddy, M.S., Bhavani, K., Feeza, S., & Baves, V.S. (2024). Optimization of rainfall prediction using satellite data through machine learning and deep learning algorithms. *2024 IEEE International Conference on Information Technology, Electronics and Intelligent Communication Systems (ICITEICS)*. <https://doi.org/10.1109/ICITEICS61368.2024.10625624>
29. Rezaei, M., Nohtani, M., Moghaddamnia, A., Abkar, A., & Rezaei, M. (2014). Performance evaluation of Statistical Downscaling Model (SDSM) in forecasting precipitation in two arid and hyper arid regions. *Journal of Soil and Water*. <https://doi.org/10.22067/jsw.v0i0.23119>
30. Rahman, A.-u., Abbas, S., Gollapalli, M., Ahmed, R., Aftab, S., Ahmad, M., Khan, M.A., & Mosavi, A. (2022). Rainfall prediction system using machine learning fusion for smart cities. *Sensors*, 22(9), 3504. <https://doi.org/10.3390/s22093504>

31. Schulz, E., Speekenbrink, M., & Krause, A. (2018). A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions. *Journal of Mathematical Psychology*, 85, 1–16. <https://doi.org/10.1016/j.jmp.2018.03.001>
32. Salahi, A., Ashrafzadeh, A., & Vazifedoust, M. (2024a). Assessing the forecasting accuracy of intense precipitation events in Iran using the WRF model. *Earth Sciences Informatics*, 17, 2199–2211. <https://doi.org/10.1007/s12145-024-01274-x>
33. Salahi, A., Ashrafzadeh, A., & Vazifedoust, M. (2024b). Remote sensing-based precipitation forecasting using cloud optical characteristics: threshold optimization and evaluation in Northern and Western Iran. *Natural Hazards*, 120, 3661–3675. <https://doi.org/10.1007/s11069-023-06352-9>
34. Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1249. <https://doi.org/10.1002/widm.1249>
35. Tuysuzoglu, G., Birant, K.U., & Birant, D. (2023). Rainfall prediction using an ensemble machine learning model based on K-stars. *Sustainability*, 15(7), 5889. <https://doi.org/10.3390/su15075889>
36. Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019). A brief review of nearest neighbor algorithm for learning and classification. In *2019 International Conference on Intelligent Computing and Control Systems (ICCS)* (pp. 1255–1260). IEEE. <https://doi.org/10.1109/ICCS45141.2019.9065747>
37. Tukey, J.W. (1977). Exploratory Data Analysis. https://doi.org/10.1007/978-3-031-20719-8_2
38. Velasco, L.C., Aca-ac, J.M., Cajés, J.J., Lactuan, N.J., & Chit, S.C. (2022). Rainfall forecasting using support vector regression machines. *International Journal of Advanced Computer Science and Applications*, 13(3). <https://doi.org/10.14569/IJACSA.2022.0130329>
39. Wang, Y., & Witten, I.H. (1997). Induction of model trees for predicting continuous classes. *Proceedings of the Poster Papers of the European Conference on Machine Learning* (pp. 48–53). <https://hdl.handle.net/10289/1183>
40. Wu, Y., Wang, H., Zhang, B., & Du, K.L. (2012). Using radial basis function networks for function approximation and classification. *ISRN Applied Mathematics*. <https://doi.org/10.5402/2012/324194>
41. Xu, J., & Zheng, Y. (2024). Remote sensing data analysis for urban planning and land use change. *Trans. Environment Energy Earth Science*, 3, 20–25. <https://doi.org/10.62051/gwpmk5m73>

Depth Assessment of Soil Properties Using an Integrated Effect Size–Based and Multivariate Approach (Case Study: Soils of Razavi Khorasan Province)

N. Mazloom^{1*} – M. Zangiabadi¹

1- Soil and Water Research Department, Khorasan-Razavi Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Mashhad, Iran

(*- Corresponding Author Email: n.mazloom@areeo.ac.ir)

Received: 06 February 2026

Revised: 06 April 2026

Accepted: 15 April 2026

Available Online: 15 April 2026

How to cite this article:

Mazloom, N., & Zangiabadi, M. (2026). Depth assessment of soil properties using an integrated effect size–based and multivariate approach (Case study: Razavi Khorasan Province). *Journal of Water and Soil*, 39(6), 573-587. (In Persian with English abstract). <https://doi.org/10.22067/jsw.2026.97726.1524>

Introduction

Soil is a fundamental natural resource that underpins ecosystem functioning, agricultural productivity, water regulation, and biogeochemical cycling. Vertical heterogeneity of soil properties along the profile reflects the combined influence of biological inputs, pedogenic processes, and land management. Soil depth strongly controls the distribution of organic matter, nutrients, soluble salts, and textural components, thereby affecting root development, nutrient uptake, and crop resilience under environmental stresses such as drought.

Most previous studies relied primarily on classical statistical tests and comparisons of mean values between layers. While useful for detecting statistically significant differences, these approaches provide limited information on the magnitude, direction, and functional relevance of depth-related changes. In highly variable and non-normally distributed soil systems, reliance on p-values alone can lead to overinterpretation of minor differences or underestimation of ecologically important gradients.

Recent advances emphasize effect size metrics and uncertainty estimation to quantify soil variability more robustly. Non-parametric indices, such as the rank-biserial effect size, allow depth-driven changes to be quantified independent of sample size and distributional assumptions. This study focuses on providing a comprehensive depth-oriented assessment of soil physicochemical properties using effect size–based approaches and classification into depth stability and management-relevant categories.

Materials and Methods

Soil samples were collected from agricultural fields of Razavi Khorasan Province of Iran at two depths: 0–30 cm (surface) and 30–60 cm (subsurface), using a paired design to minimize spatial heterogeneity. A wide range of physicochemical properties was analyzed, including organic carbon, available P and K, exchangeable cations, EC, pH, carbonate parameters, and selected micronutrients.

Paired non-parametric tests were applied for each variable, and the rank-biserial effect size (r_{rb}) was calculated to quantify the magnitude and direction of depth-related changes. Bootstrap resampling was used to estimate 95% confidence intervals. Based on effect size magnitude and confidence intervals, variables were classified into stable, quasi-stable, and depth-sensitive categories, which were further translated into practical management-oriented classes.

Results and Discussion

Depth-sensitive properties included organic carbon, available phosphorus, potassium, and manganese, all exhibiting large effect sizes and pronounced accumulation in the surface layer. The enrichment of organic carbon



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.97726.1524>

reflects concentrated biological inputs, crop residue return, and intensified microbial activity in the topsoil, whereas its sharp decline with depth indicates restricted vertical transfer and limited subsoil biological functioning. Phosphorus accumulation in the surface layer is consistent with its low mobility and strong fixation in calcareous soils, underscoring the importance of depth-aware phosphorus management strategies to enhance root access in deeper horizons. The marked differences in potassium likely result from the combined effects of crop uptake, mineral weathering, and partial leaching, highlighting the necessity for root-zone-oriented monitoring and fertilization practices. Among micronutrients, manganese showed the greatest depth sensitivity, reflecting its responsiveness to redox dynamics and pH variations, and indicating potential risks of localized deficiency or toxicity within the soil profile.

Copper and bicarbonate demonstrated moderate effect sizes, suggesting measurable but less pronounced depth-related variation. In contrast, clay, silt, pH, TNV, Zn, and Ca exhibited small effect sizes, indicating relative structural stability across depths. Sodium and chloride remained largely unchanged, implying that salinity distribution is relatively uniform within the studied profile and not strongly stratified under current conditions.

The classification of variables into depth-stability and management-priority categories provides a practical framework for translating statistical outputs into agronomic decision-making. Overall, the findings reveal that reliance on surface soil analysis alone can lead to incomplete or potentially misleading interpretations of nutrient status. Depth-aware management, including precision placement technologies and fertilizer banding systems, can improve nutrient use efficiency, enhance subsoil fertility, and reduce environmental losses, thereby contributing to more resilient soil-plant systems under semi-arid conditions.

Conclusion

By integrating paired depth-wise comparisons, PERMANOVA, and nonparametric effect size metrics, this study provides a robust framework for assessing vertical soil heterogeneity beyond conventional p-value-based approaches. The results showed pronounced and practically meaningful depth-related differences for key chemical properties, particularly soil organic carbon, available phosphorus, potassium, and manganese, while physical properties and basic indicators such as pH, clay, silt, and calcium carbonate exhibited limited variation. These patterns reflect the concentration of biological activity and management inputs in surface layers and the relative chemical depletion of deeper horizons, which constrains root development, nutrient uptake, and drought resilience in agricultural systems of Razavi Khorasan Province. Overall, the findings highlight that soil fertility assessments based solely on surface sampling can be misleading and underscore the need for targeted, depth-oriented soil management to improve nutrient use efficiency and enhance the sustainability of soil-plant systems, particularly under water-limited conditions.

Acknowledgements

The authors would like to express their sincere appreciation to the Soil and Water Research Department of the Khorasan Razavi Agricultural and Natural Resources Research and Education Center for their support in conducting this study. The authors also gratefully acknowledge the valuable cooperation and technical assistance provided by the laboratory staff.

Keywords: Effect size, Fertility management, PERMANOVA, Soil depth

ارزیابی عمقی ویژگی‌های خاک با استفاده از رویکرد تلفیقی مبتنی بر اندازه اثر و تحلیل چندمتغیره (مطالعه موردی: خاک‌های استان خراسان رضوی)

نجمه مظلوم^۱* - مهدی زنگی آبادی^۱

تاریخ دریافت: ۱۴۰۴/۱۱/۱۷

تاریخ پذیرش: ۱۴۰۵/۰۱/۲۶

چکیده

توزیع عمقی ویژگی‌های فیزیکوشیمیایی خاک از عوامل تعیین‌کننده حاصلخیزی و تاب‌آوری سیستم‌های زراعی است، با این حال در بسیاری از مطالعات، ارزیابی این تغییرات به مقایسه‌های سطحی و معنی‌داری آماری محدود شده‌است. پژوهش حاضر با رویکردی نوآورانه و فراتر از آزمون‌های کلاسیک، حساسیت عمقی متغیرهای حاصلخیزی خاک را در اراضی کشاورزی استان خراسان رضوی (۳۲۸ نقطه) بررسی می‌کند. بدین منظور، نیم‌رخ خاک در دو عمق ۰-۳۰ و ۳۰-۶۰ سانتی‌متر با تلفیق تحلیل چندمتغیره و شاخص اندازه اثر رتبه‌ای دووجهی با بازه‌های اطمینان ۹۵ درصد ارزیابی شد. مجموعه‌ای از ویژگی‌ها شامل عناصر پرمصرف و کم‌مصرف، پ‌هاش خاک، هدایت الکتریکی، کربن آلی و بافت خاک اندازه‌گیری و اثر عمق بر ساختار کلی داده‌ها با استفاده از آزمون پرمناو بررسی شد. نتایج نشان داد که عمق خاک اثر معنی‌داری بر ترکیب ویژگی‌های خاک دارد و برخی متغیرها، به‌ویژه کربن آلی، فسفر و پتاسیم قابل جذب و منگنز، دارای اندازه اثر بزرگ و حساسیت عمقی بالا هستند؛ در مقابل، متغیرهایی مانند سدیم تغییرات عمقی ناچیزی نشان دادند. طبقه‌بندی متغیرها بر اساس شدت اثر و پایداری عمقی، آشکار ساخت که تجمع عناصر پرمصرف عمدتاً به لایه سطحی محدود شده و لایه‌های زیرین از نظر کیفیت حاصلخیزی در وضعیت ضعیف‌تری قرار دارند. این یافته‌ها ضمن برجسته‌کردن محدودیت اتکای صرف به نمونه‌برداری سطحی، ضرورت گذار از مدیریت یکنواخت به سمت مدیریت عمق‌محور و هدفمند را نشان می‌دهد. به‌طور کلی، چارچوب تحلیلی ارائه‌شده در این مطالعه، با تأکید بر شدت واقعی و اهمیت عملی تغییرات عمقی، مبنایی کاربردی برای طراحی برنامه‌های تغذیه‌ای مبتنی بر نیم‌رخ خاک، افزایش کارایی مصرف نهاده‌ها و ارتقای پایداری تولید در سیستم‌های زراعی را فراهم می‌کند.

واژه‌های کلیدی: اندازه اثر، پرمناو، عمق خاک، مدیریت حاصلخیزی خاک

مقدمه

این میان، عمق خاک یکی از مهم‌ترین ابعاد ناهمگنی خاک محسوب می‌شود که کنترل‌کننده توزیع عمودی عناصر غذایی، مواد آلی، املاح محلول و ویژگی‌های بافتی در نیم‌رخ خاک است (Richter & Markewitz, 1995). لایه‌های سطحی خاک معمولاً تحت تأثیر مستقیم ورودی‌های زیستی، بقایای گیاهی، فعالیت میکروبی و عملیات مدیریتی قرار دارند، در حالی که لایه‌های زیرسطحی بیشتر بازتاب‌دهنده فرآیندهای بلندمدت و کند خاک‌زایی مانند شست‌وشوی عمقی، انتقال مواد، تجمع ثانویه املاح و واکنش‌های شیمیایی آهسته‌تر هستند

خاک به‌عنوان یکی از بنیادی‌ترین منابع طبیعی، نقشی اساسی در عملکرد اکوسیستم‌ها، تنظیم چرخه‌های زیست‌ژئوشیمیایی، ذخیره‌سازی کربن، تغذیه گیاه و مدیریت منابع آب ایفا می‌کند. ویژگی‌های فیزیکی و شیمیایی خاک حاصل برهم‌کنش پیچیده عواملی نظیر اقلیم، ماده مادری، توپوگرافی، زمان و مدیریت هستند و این ویژگی‌ها در مقیاس‌های مکانی و عمقی مختلف تغییر می‌کنند (Jenny, 1994).

۱- بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان خراسان رضوی، سازمان تحقیقات، آموزش و ترویج کشاورزی، مشهد، ایران

(*) - نویسنده مسئول: (Email: n.mazloom@areeo.ac.ir)

(Nakagawa & Cuthill, 2007; 1994). از این رو، گزارش اندازه اثر، به‌ویژه در مطالعات مقایسه‌ای عمقی که انتظار می‌رود بسیاری از تغییرات تدریجی و با بزرگی محدود باشند، از اهمیت ویژه‌ای برخوردار است. از سوی دیگر، خاک یک سامانه ذاتاً چندمتغیره است و رفتار آن حاصل برهم‌کنش هم‌زمان مجموعه‌ای از ویژگی‌های فیزیکی، شیمیایی و زیستی است. بنابراین، بررسی اثر عمق خاک صرفاً بر اساس متغیرهای منفرد نمی‌تواند تصویر کاملی از ساختار و عملکرد سیستم خاک ارائه دهد. روش‌های تحلیل چندمتغیره غیرپارامتری، مانند آزمون پرمانوا^۱ مبتنی بر ماتریس‌های بی‌تشابهی (نظیر فاصله بری-کورتیس^۲)، این امکان را فراهم می‌کنند که تفاوت کلی ساختار ویژگی‌های خاک بین عمق‌های مختلف بدون نیاز به فرض نرمال بودن داده‌ها ارزیابی شود. با این حال، نتایج این روش‌ها اغلب بدون پیوند سیستماتیک با اندازه اثر متغیرهای منفرد تفسیر می‌شوند و اطلاعات محدودی درباره جهت و شدت تغییرات هر ویژگی ارائه می‌دهند.

با وجود پیشرفت‌های روش‌شناختی، هنوز خلأ قابل‌توجهی در مطالعاتی وجود دارد که به‌طور هم‌زمان از تحلیل‌های زوجی ناپارامتری، شاخص‌های اندازه اثر، برآورد عدم قطعیت و تحلیل‌های چندمتغیره برای ارزیابی تغییرات عمقی خاک استفاده کنند (Anderson, 2001; Legendre & Legendre, 2012). به‌ویژه، چارچوبی یکپارچه که بتواند هم تفاوت‌های کلی سیستم خاک را در سطح چندمتغیره و هم شدت و پایداری تغییرات هر متغیر را به‌صورت کمی و تفسیرپذیر ارزیابی کند، در ادبیات علوم خاک به‌ندرت ارائه شده است (Anderson & Walsh, 2013). این خلأ روش‌شناختی، استخراج پیام‌های مدیریتی شفاف مبتنی بر حساسیت عمقی ویژگی‌های خاک را با چالش مواجه ساخته است. در سال‌های اخیر، تأکید فزاینده‌ای بر استفاده از رویکردهای داده‌محور مبتنی بر اندازه اثر، برآورد عدم قطعیت و نمایش‌های تصویری استنباطی در علوم مختلف شکل گرفته است (Wasserstein et al., 2016; Cumming, 2025; Wasserstein et al., 2019). این رویکردها امکان تمایز میان وجود تفاوت آماری و اهمیت واقعی تفاوت را فراهم کرده و به درک عمیق‌تری از فرآیندهای حاکم بر تغییرات خاک منجر می‌شوند. در این میان، استفاده از طراحی‌های زوجی در مطالعات عمقی، به‌ویژه زمانی که نمونه‌برداری از اعماق مختلف یک نقطه یا نیم‌رخ خاک انجام می‌شود، می‌تواند اثر تغییرپذیری مکانی را کاهش داده و تمرکز تحلیل را بر تغییرات واقعی ناشی از عمق قرار دهد (Montgomery, 2017; Sokal & Rohlf, 1987).

چارچوبی یکپارچه که بتواند به‌صورت هم‌زمان تفاوت کلی سیستم خاک در سطح چندمتغیره و نیز شدت، جهت و پایداری تغییر هر ویژگی

(Buol et al., 2011). این تمایز فرآیندی سبب می‌شود که برخی ویژگی‌های خاک نسبت به عمق حساسیت بالایی نشان دهند، در حالی که سایر ویژگی‌ها پایداری نسبی خود را در امتداد نیم‌رخ خاک حفظ کنند. با این حال، تشخیص و کمی‌سازی این تفاوت‌ها همواره ساده نیست و به‌شدت به چارچوب تحلیلی مورد استفاده وابسته است. مطالعات متعددی به بررسی تغییرات عمقی ویژگی‌های فیزیکی، شیمیایی و زیستی خاک پرداخته‌اند و نشان داده‌اند که محتوای آلی ماده خاک و عناصر غذایی نظیر نیتروژن و فسفر معمولاً در لایه‌های سطحی بیشینه بوده و با افزایش عمق کاهش می‌یابد (Okolo et al., 2023; Zhou et al., 2020)؛ الگویی که به تجمع بقایای گیاهی و شدت فعالیت زیستی در سطح خاک نسبت داده می‌شود. الگوهای مشابهی نیز برای سایر ویژگی‌های خاک از جمله pH، هدایت الکتریکی و عناصر کم‌مصرف گزارش شده است (Dhakad et al., 2020; Getnet et al., 2025). این یافته‌ها اهمیت بررسی عمقی خاک را در مطالعات کیفیت خاک، پایداری اکوسیستم‌ها و مدیریت منابع برجسته می‌سازد و نشان می‌دهد که تحلیل تغییرات عمقی باید فراتر از مقایسه‌های ساده میانگین‌ها بوده و کل ساختار داده‌ها را در نظر بگیرد (Legendre & Legendre, 2012). با این وجود، بخش عمده‌ای از مطالعات تغییرات عمقی خواص خاک عمدتاً بر آزمون‌های کلاسیک معنی‌داری آماری و مقایسه میانگین‌ها متکی بوده‌اند. اگرچه این رویکردها در شناسایی تفاوت‌های آماری مفید هستند، اما به‌تنهایی قادر به بیان شدت، جهت و اهمیت اکولوژیکی یا مدیریتی این تفاوت‌ها نیستند. در بسیاری از موارد، تفاوت‌هایی که از نظر آماری معنی‌دار گزارش می‌شوند، دارای اندازه اثر^۱ کوچک بوده و از منظر عملکردی اهمیت محدودی دارند. اتکای صرف به مقادیر احتمال (p-value)، به‌ویژه در داده‌های خاک که اغلب غیرنرمال، ناهمسان و دارای پراکندگی بالا هستند، می‌تواند منجر به برداشت‌های اغراق‌آمیز از نقش عمق خاک در کنترل ویژگی‌های سیستم خاک شود (Wasserstein et al., 2019). پژوهش حاضر با هدف پر کردن این شکاف طراحی شده است و می‌کوشد با تلفیق تحلیل‌های زوجی ناپارامتری، شاخص‌های اندازه اثر، برآورد عدم قطعیت و تحلیل‌های چندمتغیره، تصویری جامع و کمی از تغییرات عمقی سیستم خاک ارائه دهد.

یکی از نقدهای اساسی به رویکردهای کلاسیک در علوم خاک، بی‌توجهی نسبی به اندازه اثر و تمرکز افراطی بر معنی‌داری آماری است (Wasserstein et al., 2016; Wasserstein et al., 2019). در حالی که اندازه اثر امکان کمی‌سازی شدت واقعی تغییرات را مستقل از حجم نمونه فراهم می‌کند و تمایز میان تفاوت‌های آماری و تفاوت‌های معنی‌دار از نظر بوم‌شناختی یا مدیریتی را ممکن می‌سازد (Cohen,

معنی‌داری آماری، اندازه اثر قابل توجهی داشته باشند. متغیرهای با اندازه اثر کوچک، شاخص‌های پایدار و کم‌حساس به عمق هستند، در حالی که متغیرهای با اندازه اثر متوسط تا بزرگ، شاخص‌های حساس به تغییرات عمقی محسوب می‌شوند. ارزیابی اثر عمق بر کیفیت خاک نیازمند رویکردهای چندمتغیره است و تحلیل‌های انجام‌شده سهم نسبی عمق در تغییرات کلی ویژگی‌ها را مشخص می‌کنند. چارچوب نظری تحقیق داده‌محور بوده و نتایج بازتاب‌دهنده روابط واقعی بین داده‌ها و فرآیندهای خاک است.

نرم‌افزار و بسته‌های آماری

کلیه تحلیل‌های این مطالعه با استفاده از نرم‌افزار R (R Core Team, نسخه ۴.۵.۰، ۲۰۲۵) و در محیط نرم‌افزاری RStudio (نسخه ۳.۸۷+۲۰۲۵.۰۹.۰) انجام شد. بسته‌های اصلی مورد استفاده شامل *psych* و *skimr* برای آمار توصیفی، *nortest* برای آزمون نرمالیتی، *effectsize* و *bayestestR* برای محاسبه اندازه اثر و تحلیل‌های بیزی، *vegan* برای تحلیل‌های چندمتغیره مبتنی بر فاصله، *factoextra* و *ggplot2* برای ترسیم نتایج، و *DiagrammeR* برای طراحی نمودارهای مفهومی بودند.

طراحی مطالعه، پیش‌پردازش و کنترل کیفی داده‌ها

استان خراسان رضوی بین مدار جغرافیایی ۳۳ درجه و ۵۲ دقیقه تا ۳۷ درجه و ۴۲ دقیقه عرض شمالی از خط استوا و ۵۶ درجه و ۱۹ دقیقه تا ۶۱ درجه و ۱۶ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است. اکثر نواحی استان به جز قسمت‌های محدودی از آن، دارای اقلیم نیمه خشک می‌باشد (Emamian et al., 2021). در این مطالعه، ۳۲۸ نمونه خاک از دو عمق ۰-۳۰ و ۳۰-۶۰ سانتی‌متری اراضی کشاورزی شهرستان‌های مختلف استان به روش تصادفی طبقه‌بندی شده جمع‌آوری شد و از نظر ویژگی‌های فیزیکی، شیمیایی و حاصلخیزی مورد تجزیه آزمایشگاهی قرار گرفت. انتخاب این دو عمق به‌منظور بررسی هم‌زمان فرآیندهای غالب سطحی مانند تجمع ماده آلی و چرخه عناصر غذایی و همچنین محدودیت‌های زیرسطحی نظیر شوری و سدیمی شدن خاک انجام شد. نمونه‌ها پس از انتقال به آزمایشگاه، در شرایط محیطی خشک و کوبیده‌شده و از الک ۲ میلی‌متری عبور داده شدند. متغیرهای اندازه‌گیری‌شده (۲۰ متغیر) شامل پ‌هاش گل اشباع خاک (pH)، هدایت الکتریکی عصاره اشباع (EC)، درصد اشباع (SP) بر اساس وزن خشک و میزان آب لازم برای رسیدن به حالت اشباع، توزیع اندازه ذرات خاک به روش هیدرومتری، محتوای کربن آلی (SOC) به روش والکلی و بلک، فسفر به روش اولسن، پتاسیم قابل جذب با استفاده از فلیم فوتومتر، عناصر کم‌مصرف قابل‌استفاده (Cu)،

را به‌صورت کمی و تفسیرپذیر ارزیابی کند، در ادبیات علوم خاک به‌ندرت گزارش شده است. این خلأ روش‌شناختی، استخراج پیام‌های مدیریتی روشن مبتنی بر حساسیت عمقی ویژگی‌های خاک را با چالش مواجه می‌سازد. بر این اساس، هدف این مطالعه ارائه یک ارزیابی جامع و یکپارچه از تغییرات عمقی ویژگی‌های فیزیکی و شیمیایی خاک بین دو عمق ۰-۳۰ و ۳۰-۶۰ سانتی‌متر با رویکردی مبتنی بر اندازه اثر و تحلیل چندمتغیره است. در این پژوهش، با تلفیق آزمون‌های زوجی ناپارامتری، برآورد اندازه اثر غیرپارامتری و تحلیل‌های چندمتغیره مبتنی بر فاصله بری-کورتیس، تلاش شده است تا تمایز میان تفاوت‌های آماری صرف و تفاوت‌های عملکردی معنی‌دار مشخص شود. علاوه بر این، در مطالعه حاضر شاخصی با عنوان شاخص پایداری عمقی^۱ (DSI) معرفی و به‌کار گرفته شده است که بر پایه اندازه اثر تعریف می‌شود و امکان رتبه‌بندی ویژگی‌های خاک را از نظر حساسیت یا پایداری آن‌ها در امتداد عمق فراهم می‌سازد. این شاخص دیدگاهی فرآیندمحور و کاربردی برای تفسیر الگوهای عمقی خاک ارائه می‌دهد و می‌تواند مبنای علمی دقیق‌تری برای پایش کیفیت خاک، مدیریت پایدار منابع خاک و تصمیم‌گیری‌های کشاورزی و محیط‌زیستی فراهم کند.

مواد و روش‌ها

تئوری تحقیق

این پژوهش بر این فرض نظری استوار است که تغییرات عمقی ویژگی‌های خاک صرفاً به‌عنوان تفاوت‌های آماری ساده بین لایه‌ها قابل تبیین نیستند، بلکه بازتابی از برهم‌کنش فرآیندهای فیزیکی، شیمیایی و زیستی در امتداد نیم‌رخ خاک می‌باشند. از این منظر، عمق خاک به‌عنوان یک گرادینان محیطی پیوسته در نظر گرفته می‌شود که شدت و جهت اثر آن بر متغیرهای خاک می‌تواند بسته به ماهیت فرآیندهای غالب، متفاوت باشد. به‌طور مثال، پژوهشی درباره تأثیر عمق خاک بر ساختار جامعه میکروبی نشان می‌دهد که عمق می‌تواند بخش قابل توجهی از تغییرات کلی جامعه را توضیح دهد و از تحلیل‌های چندمتغیره مانند پرمانوا برای تعیین سهم نسبی عمق در واریانس استفاده می‌شود (Hao et al., 2021). از منظر اکولوژیکی، مطالعات اکوسیستم‌ها نشان می‌دهد که ترکیب داده‌های چندمتغیره باعث آشکار شدن پاسخ‌های عملکردی متنوع به گرادینان عمقی می‌شود و این گرادینان را باید به‌عنوان یک عامل محیطی پیوسته تلقی کرد (Bernard-Verdier et al., 2012).

این مطالعه بر این اساس است که تفاوت‌های عمقی خاک تنها وقتی از نظر اکولوژیکی و مدیریتی معنی‌دار هستند که علاوه بر

(Kerby, 2014) گزارش شد. برای هر r_b بازه اطمینان ۹۵ درصد محاسبه شد و علامت آن نیز نشان‌دهنده جهت تغییر عمقی بود، به طوری که مقادیر مثبت نشان‌دهنده مقادیر بالاتر در لایه سطحی و مقادیر منفی نشان‌دهنده مقادیر بیشتر در لایه زیر سطحی بود. شدت اندازه اثر نیز بر اساس حدود استاندارد ارائه شده برای آزمون‌های غیرپارامتری توسط پرز (Fiel Peres, 2026) به چهار گروه طبقه‌بندی و در تفسیر نمودارها و نتایج مدیریتی استفاده شد:

$$|r| < 0.1 : \text{اثر ناچیز}$$

$$0.1 \leq |r| < 0.3 : \text{اثر کوچک}$$

$$0.3 \leq |r| < 0.5 : \text{اثر متوسط}$$

$$|r| \geq 0.5 : \text{اثر بزرگ}$$

برای بررسی جهت و شدت تغییرات ویژگی‌های خاک بین دو عمق نیز از شاخص احتمال جهت اثر^۵ (PD) در چارچوب آمار بیزی^۶ استفاده شد (Makowski et al., 2019). ابتدا تفاوت زوجی هر متغیر بین دو عمق محاسبه گردید و سپس احتمال مثبت بودن این تفاوت برای هر متغیر محاسبه شد. مقادیر PD نزدیک به ۱ نشان‌دهنده احتمال بالا برای افزایش و مقادیر نزدیک به ۰/۵ نشان‌دهنده تغییرات نامطمئن یا بدون جهت مشخص می‌باشد.

تحلیل تمایز چندمتغیره عمقی پرمانو^۷

برای بررسی تفاوت کلی ساختار خاک بین دو عمق، داده‌ها در یک چارچوب واحد ادغام و عمق به عنوان متغیر طبقه‌ای تعریف شد. تحلیل بر روی متغیرهای عددی منتخب انجام گرفت و ماتریس فاصله نمونه‌ها با استفاده از شاخص بری-کورتیس (Oksanen, 2015) محاسبه شد. تفاوت چندمتغیره بین عمق‌ها با آزمون پرمانو و ۹۹۹ تکرار تصادفی به کمک تابع adonis2 ارزیابی گردید. به منظور بررسی یکنواختی پراکنش گروه‌ها نیز، آزمون پرمدیسپ^۸ اجرا شد که عدم معنی‌داری آن نشان‌دهنده همگنی پراکنش و اعتبار نتایج پرمانو بود (Anderson, 2017).

شاخص پایداری عمقی (DSI)^۹ و ارائه چهارچوب مدیریتی

برای ارزیابی پایداری خاک در عمق، تغییرات لایه سطحی و زیرسطحی به صورت زوجی و بر اساس تفسیر هم‌زمان سه معیار اصلی شامل جهت و اندازه تغییرات (اندازه اثر)، معنی‌داری آماری و رفتار متغیرهای کلیدی خاک بررسی شد. متغیرهایی با اندازه اثر بزرگ و اختلاف معنی‌دار به عنوان نشانه ناپایداری ساختاری یا عملکردی، به ویژه

Fe، Mn و Zn) به روش عصاره‌گیری با DTPA با استفاده از دستگاه جذب اتمی، کاتیون‌ها و آنیون‌های محلول شامل کلسیم و منیزیم محلول به روش تیتراسیون با EDTA، سدیم محلول با دستگاه فلیم‌فوتومتر، کلر محلول با روش موهر و بیکربنات محلول با روش تیتراسیون اسید-باز و نسبت جذب سدیم (SAR) بر اساس غلظت یون‌های سدیم، کلسیم و منیزیم محلول بودند (Sparks et al., 2020). این متغیرها نماینده طیفی از فرایندهای فیزیکی و شیمیایی خاک هستند و امکان ارزیابی پاسخ سیستم خاک به گرادیان عمقی را فراهم می‌کنند. داده‌های مربوط به نتایج آزمایشگاهی، پس از ورود به محیط نرم‌افزار RStudio از نظر ساختار متغیرها، نوع داده (عددی و غیرعددی) و وجود داده‌های مفقود بررسی شدند. متغیرهای غیرعددی (مانند نام شهر) در تحلیل‌های آماری وارد نشدند. برای بررسی الگوی داده‌های مفقود از شاخص‌های گرافیکی و آماری استفاده شد و تحلیل‌ها بر اساس داده‌های کامل انجام گرفت.

آمار توصیفی و بررسی نرمال بودن توزیع داده‌ها

برای هر متغیر خاک، آمار توصیفی شامل میانگین، انحراف معیار، میانه و دامنه تغییرات (حداقل و حداکثر) به صورت جداگانه و برای هر عمق محاسبه شد. نرمال بودن توزیع داده‌ها با آزمون اندرسون-دارلینگ^۱ برای هر متغیر و هر عمق بررسی شد. برای کنترل خطای نوع اول ناشی از انجام آزمون‌های متعدد، مقادیر p با روش کنترل نرخ کشف کاذب FDR^۲ اصلاح شدند. این رویکرد، که به طور گسترده در تحلیل‌های آماری برای تعدیل p -value در چندین آزمون همزمان به کار می‌رود، نسبت به روش‌های سنتی مانند تصحیح بونفرونی، تعادل بهتری بین کشف نتایج واقعی و محدود کردن کشف‌های کاذب فراهم می‌کند (Benjamini & Hochberg, 1995).

مقایسه زوجی عمقی و تحلیل اندازه اثر جهت مقایسه عمقی خاک

با توجه به غیرنرمال بودن داده‌ها و ماهیت زوجی نمونه‌ها، داده‌های دو عمق بر اساس شناسه یکنای نمونه‌ها به صورت زوجی هم‌تراز شدند و از آزمون ناپارامتری ویلکاکسون زوجی^۳ با سطح معنی‌داری آماری برابر با ۰/۰۵ برای مقایسه هر متغیر بین دو عمق استفاده شد. با توجه به محدودیت تفسیر نتایج صرفاً بر اساس معنی‌داری آماری، اندازه اثر به عنوان شاخص اصلی شدت تمایز عمقی محاسبه شد. اندازه اثر اختلاف‌ها به صورت ضریب همبستگی رتبه‌ای دووجهی^۴ (r_{rb})

6- Bayesian statistics framework

7- PERMDISP- Permutational Analysis of Multivariate Dispersions

8- Depth Stability Index

1- Anderson-Darling

2- False Discovery Rate

3- Wilcoxon signed-rank (paired)

4- Rank-biserial correlation, r_{rb}

5- Probability of Direction

(Oliver, 2007). از این رو، استفاده از روش‌های غیر پارامتری و تحلیل‌های مبتنی بر اندازه اثر برای تفسیر معتبر داده‌ها ضروری تشخیص داده شد.

مقایسه غیرپارامتری تغییرات عمقی ویژگی‌های خاک

نتایج آزمون ناپارامتری ویلکاکسون زوجی نشان داد که اغلب ویژگی‌های فیزیکی و شیمیایی خاک بین دو عمق ۳۰-۶۰ و ۳۰-۳۰ سانتی‌متر اختلاف معنی‌دار آماری دارند، به طوری که بیشترین تفاوت‌ها مربوط به ماده آلی، عناصر غذایی قابل جذب و عناصر کم‌مصرف بود (شکل ۱). در مقابل، متغیرهای نسبت جذب سدیم، درصد شن، سدیم و کلر تغییر عمقی معنی‌داری نشان ندادند (شکل ۱ و جدول ۲). این الگو بیانگر ناهمگنی عمودی خاک و تأثیر فرآیندهای زیستی و ژئوشیمیایی وابسته به عمق است. مقادیر بیشتر کربن آلی و فسفر قابل جذب در لایه سطحی احتمالاً ناشی از تجمع بقایای گیاهی، فعالیت میکروبی بیشتر و اثر مستقیم مدیریت زراعی است (Havlin, 2014)، در حالی که تغییرات عناصر کم‌مصرفی مانند آهن و منگنز می‌تواند به شرایط اکسایش-کاهش، واکنش خاک و فرآیندهای انحلال-رسوب در نیم‌رخ خاک مرتبط باشد.

هم‌پوشانی توزیع داده‌ها بین دو عمق نشان می‌دهد که تفسیر صرف بر اساس میانگین یا p-value کافی نیست و استفاده از تحلیل زوجی همراه با اندازه اثر برای درک اهمیت واقعی اختلاف‌ها ضروری است. این نتایج بر لزوم تحلیل جداگانه لایه‌های عمقی خاک و پرهیز از ادغام داده‌های عمقی در مطالعات خاک تأکید می‌کند، زیرا تلفیق لایه‌ها می‌تواند به از دست رفتن اطلاعات اکولوژیکی و مدیریتی مهم منجر شود.

در صورت تشدید فرآیندهایی مانند شوری و سدیمی‌شدن با عمق، تفسیر شدند؛ در حالی که تغییرات کوچک یا غیرمعنی‌دار بیانگر پایداری سامانه خاک تحت مدیریت موجود بود. این رویکرد مبتنی بر اندازه اثر، امکان ارزیابی کاربردی پایداری خاک را فراهم کرده و مبنایی برای طبقه‌بندی ویژگی‌های خاک از نظر اولویت مدیریتی ارائه می‌دهد.

نتایج و بحث

الگوی کلی داده‌ها و ناهمگنی عمقی ویژگی‌های خاک

آمار توصیفی ویژگی‌های فیزیکی و شیمیایی خاک در دو عمق ۳۰-۶۰ و ۳۰-۳۰ سانتی‌متر نشان داد که اغلب متغیرها، به‌ویژه ویژگی‌های شیمیایی شامل هدایت الکتریکی، نسبت جذب سدیم، یون‌های محلول، عناصر کم‌مصرف و عناصر غذایی قابل جذب، دارای دامنه تغییرات وسیع و توزیع‌های نامتقارن هستند (جدول ۱). این ناهمگنی زیاد بازتاب‌دهنده پیچیدگی ذاتی سیستم خاک و تأثیر هم‌زمان فرآیندهای زیستی، شیمیایی و مدیریتی است (Weil & Brady, 2016). در مقابل، برخی ویژگی‌ها مانند اجزای بافت خاک و کربنات کلسیم معادل تغییرات محدودتری در امتداد نیم‌رخ خاک نشان دادند که حاکی از کنترل غالب مواد مادری و فرآیندهای بلندمدت زمین‌شناختی است.

پهناش قلبایی خاک همراه با مقادیر بالای هدایت الکتریکی و نسبت جذب سدیم در هر دو عمق نشان می‌دهد که خاک‌های منطقه عمدتاً قلیایی، شور تا بسیار شور و در مواردی سدیمی هستند. تداوم این ویژگی‌ها در لایه‌های زیرسطحی بیانگر آن است که این محدودیت‌ها در کل پروفیل خاک حضور داشته و می‌تواند ناشی از شرایط اقلیمی، مواد مادری و فرآیندهای تجمع املاح در محیط‌های نیمه‌خشک باشد. این نتایج تأکید می‌کند که ارزیابی کیفیت و حاصلخیزی خاک صرفاً بر اساس داده‌های سطحی، تصویری ناقص از وضعیت واقعی خاک ارائه می‌دهد و تحلیل‌های عمق‌محور برای درک صحیح عملکرد سیستم خاک-گیاه ضروری است.

نرمالیتی داده‌ها و پیامدهای روش‌شناختی

نتایج آزمون اندرسون-دارلینگ با اصلاح نرخ کشف کاذب نشان داد که اغلب متغیرها در هر دو عمق از توزیع نرمال پیروی نمی‌کنند (دامنه p-adj متغیرها بین 10^{-4} تا $8/75 \times 10^{-23}$). این غیرنرمال بودن بیانگر ناهمگنی شدید مکانی خاک‌ها و وجود مقادیر مرزی است که با دامنه تغییرات وسیع و انحراف معیار بالا در آمار توصیفی همخوانی دارد. به‌ویژه غیرنرمال بودن متغیرهایی مانند هدایت الکتریکی، سدیم و نسبت جذب سدیم نشان‌دهنده حضور لکه‌های موضعی با شوری و سدیمی بالا در منطقه است؛ الگویی رایج در خاک‌های شور و نیمه‌خشک که ناشی از ناهمگنی مکانی شدید، مدیریت نامتوازن و فرآیندهای غیرخطی خاک است (Webster & ...)

جدول ۱- آمار توصیفی ویژگی‌های فیزیکی و شیمیایی خاک در دو عمق ۰-۳۰ و ۳۰-۶۰ سانتی‌متر


Table 1- Descriptive statistics of soil properties at 0-30 and 30-60 cm depths

ویژگی‌های خاک Soil variables	عمق: ۰-۳۰ سانتی متر Depth: 0-30 cm			عمق: ۳۰-۶۰ سانتی متر Depth: 30-60 cm		
	Mean $\pm$ SD	Median	Min-Max	Mean $\pm$ SD	Median	Min-Max
پ‌هاس pH	8.0 $\pm$ 0.17	8.0	7.5 – 8.5	8.0 $\pm$ 0.16	8.1	7.6 – 8.8
آهن Fe (mg kg ⁻¹)	4.0 $\pm$ 2.0	3.6	0.2 – 25.2	3.9 $\pm$ 3.0	3.65	0.2 – 48.3
بی کربنات Bicarbonate (meq L ⁻¹)	4.8 $\pm$ 2.0	4.5	1.0 – 15.0	4.4 $\pm$ 1.7	4.1	1.0 – 11.5
پتاسیم قابل جذب Available K (mg kg ⁻¹)	254.6 $\pm$ 122.6	234.6	53.9 – 1059.0	227.1 $\pm$ 118.9	212.5	53.9 – 992.4
درصد اشباع جرمی SP (g g ⁻¹)	34.8 $\pm$ 6.87	34.4	15.2 – 54.7	35.0 $\pm$ 7.49	34.4	17.0 – 62.5
کربنات کلسیم معادل TNV (%)	17.8 $\pm$ 5.18	17.0	3.0 – 39.7	18.2 $\pm$ 5.66	17.3	5.1 – 42.2
درصد رس Clay content (%)	17.6 $\pm$ 7.6	16.8	3.3 – 52.0	18.2 $\pm$ 8.2	17.2	0.0 – 58.0
درصد سیلت Silt content (%)	41.2 $\pm$ 12.49	43.0	0.0 – 65.0	40.0 $\pm$ 12.53	42.3	0.0 – 65.6
درصد شن Sand content (%)	40.5 $\pm$ 16.22	38.8	0.0 – 87.7	41.1 $\pm$ 17.45	38.0	0.0 – 93.0
روی Zn (mg kg ⁻¹)	1.2 $\pm$ 2.37	0.5	0.1 – 16.6	1.4 $\pm$ 3.17	0.4	0.0 – 26.0
سدیم Na (meq L ⁻¹)	39.2 $\pm$ 88.9	11.2	0.2 – 807.4	37.3 $\pm$ 94.3	12.0	0.1 – 1052.2
فسفر قابل جذب Available P (mg kg ⁻¹)	9.0 $\pm$ 7.4	7.2	0.1 – 51.2	6.5 $\pm$ 5.9	4.8	0.0 – 43.6
کلر Cl (meq L ⁻¹)	32.0 $\pm$ 77.3	6.3	0.2 – 662.5	25.5 $\pm$ 54.8	7.5	0.5 – 620.0
کلسیم Ca (meq L ⁻¹)	11.5 $\pm$ 16.5	5.6	0.6 – 136.8	10.0 $\pm$ 12.1	4.8	0.4 – 128.0
ماده آلی OC (%)	0.4 $\pm$ 0.32	0.4	0.0 – 3.9	0.3 $\pm$ 0.23	0.3	0.0 – 1.6
مجموع کلسیم و منیزیم Ca + Mg (meq L ⁻¹)	21.4 $\pm$ 30.4	10.9	0.8 – 254.0	18.1 $\pm$ 19.9	9.9	0.8 – 135.0
منگنز Mn (mg kg ⁻¹)	6.5 $\pm$ 2.8	6.1	1.6 – 29.0	5.3 $\pm$ 2.5	4.8	1.2 – 26.0
منیزیم Mg (meq L ⁻¹)	9.8 $\pm$ 17.5	5.2	0.0 – 213.0	8.1 $\pm$ 9.9	4.6	0.0 – 100.0
نسبت جذب سدیم SAR	9.3 $\pm$ 13.83	5.2	0.1 – 104.2	10.1 $\pm$ 18.00	5.6	0.1 – 219.4
هدایت الکتریکی EC (dS m ⁻¹)	6.1 $\pm$ 11.7	2.3	0.3 – 90.4	5.5 $\pm$ 10.6	2.2	0.3 – 112.1

اندازه اثر و شدت واقعی تمایز عمقی

تحلیل اندازه اثر نشان داد که معنی‌داری آماری لزوماً به معنای اهمیت عملی اختلاف‌ها نیست (جدول ۲). بزرگ‌ترین اندازه اثرها مربوط به کربن آلی، فسفر و پتاسیم قابل جذب و منگنز بود. این عناصر دارای p-value بسیار کوچک (کمتر از ۱۰^{-۸}) و اندازه اثر بزرگ

(۰/۵۸-۰/۷۳) بودند که بیانگر تمایز عمقی واقعی است و از نظر مدیریتی نیز مهم است (شکل ۲، جدول ۲). برای این متغیرها، بازه‌های اطمینان به‌طور کامل از صفر فاصله داشت که بیانگر اثر عمق قوی، پایدار و جهت‌دار است. بنابراین، اختلاف‌های زوجی این متغیرها منسجم بوده و ناشی از چند مشاهده پرت نیست.



شکل ۱- نمودار جعبه‌ای اختلاف توزیع متغیرهای خاک بین دو عمق ۰-۳۰ و ۳۰-۶۰ سانتی‌متر

Figure 1- Boxplot comparison of soil properties showing statistically significant differences between the 0-30 and 30-60 cm soil depths

ns, **, * و * به ترتیب معنی عدم معنی‌داری، معنی‌داری در سطح احتمال ۱ و ۵ درصد.

ns, ***, ** and *: non-significant, significant at $p \leq 0.01$, $p \leq 0.01$ and $p \leq 0.05$, respectively.

کشاورزی ایران عمدتاً در لایه‌های سطحی متمرکز است و توزیع عمقی آن به شدت تحت تأثیر شیوه‌های مصرف کودهای فسفاته و مدیریت خاک قرار دارد (Jalali et al., 2023). تفاوت عمقی پتاسیم احتمالاً بازتاب برداشت گیاه، ویژگی‌های کانی‌شناسی خاک و فرآیندهای شستشو بوده و ضرورت پایش این عنصر در کل نیم‌رخ خاک و تنظیم کوددهی متناسب با عمق توسعه ریشه را برجسته می‌سازد (Xu et al., 2025). همچنین، اندازه اثر بزرگ منگنز نشان‌دهنده حساسیت زیاد فراهمی این عناصر به تغییرات پهاش خاک و شرایط اکسایش-کاهش است که می‌تواند خطر کمبود آن در لایه‌های زیرسطحی یا سمیت آن را در لایه‌های سطحی خاک افزایش داده و بر لزوم مدیریت دقیق واکنش خاک و مصرف هدفمند عناصر کم‌مصرف تأکید کند (Abbas et al., 2025). تغییرات Cu و بی‌کربنات از منظر عمق معنی‌دار اما با اثر متوسط بودند و اهمیت عملی کمتری نسبت به منگنز، فسفر، پتاسیم و ماده آلی داشتند. درصد رس، سیلت، پهاش خاک، آهک و برخی عناصر مانند روی و کلسیم تغییرات محدودی داشتند و اثر عملی کمی نشان دادند، در حالی که سدیم و کلر تقریباً پایدار بودند و تغییر عمقی تأثیری عملی بر آن‌ها نداشت.


غلظت بیشتر کربن آلی در لایه سطحی بازتاب تمرکز فرآیندهای زیستی، ورودی بقایای گیاهی و اثر مستقیم مدیریت زراعی است، در حالی که کاهش آن در لایه زیرسطحی نشان‌دهنده افت فعالیت میکروبی و محدودیت انتقال عمودی کربن آلی می‌باشد (Cotrufo et al., 2019). این الگو حساسیت بالای ماده آلی به مدیریت خاک را تأیید کرده و بر نقش راهبردهایی نظیر کاهش شخم و افزایش ورودی‌های آلی در پایداری سیستم خاک و گیاه تأکید دارد. نتایج مطالعات دیگر نیز نشان می‌دهد که ذخیره کربن آلی خاک به‌طور معنی‌داری با عمق کاهش می‌یابد و بیشترین سهم آن در لایه‌های سطحی متمرکز است، که این الگو نقش کلیدی فرآیندهای زیستی سطح خاک و مدیریت را در توزیع عمقی کربن آلی تأیید می‌کند (Wiesmeier et al., 2019).

تجمع فسفر در لایه‌های سطحی، ناشی از تحرک محدود و تثبیت قوی آن در خاک، و اندازه اثر بزرگ آن نشان می‌دهد که توزیع عمقی فسفر به شدت تحت تأثیر شیوه مصرف کودهای فسفاته است، به گونه‌ای که مدیریت غیربهینه می‌تواند کارایی مصرف فسفر و دسترسی ریشه‌ها را محدود کند (Vance et al., 2024). نتایج فراتحلیلی جلالی و همکاران در سال ۱۴۰۲ نیز نشان داد که فسفر قابل جذب در خاک‌های

جدول ۲- مقایسه عمقی متغیرهای خاک با مقادیر p، اندازه اثر و بزرگی اثر

Table 2- Depth-wise comparison of soil variables with p-values, effect size, and effect magnitude

Variables متغیرها	p_value مقدار p	p_adj مقدار p تعدیل شده	r_rb اندازه اثر	CI_low حد پایین فاصله اطمینان	CI_high حد بالای فاصله اطمینان	PD جهت تغییرات	Effect magnitude بزرگی اثر
منگنز Mn (mg kg ⁻¹)	1.32E ⁻³⁰	2.78E ⁻²⁹	0.74	0.67	0.79	0.81	Large بزرگ
پتاسیم قابل جذب Available K (mg kg ⁻¹)	2.08E ⁻²²	1.46E ⁻²¹	0.67	0.59	0.73	0.69	Large بزرگ
فسفر قابل جذب Available P (mg kg ⁻¹)	4.08E ⁻²³	4.28E ⁻²²	0.66	0.58	0.72	0.70	Large بزرگ
ماده آلی OC (%)	9.46E ⁻¹⁹	4.97E ⁻¹⁸	0.59	0.50	0.66	0.70	Large بزرگ
مس Cu (mg kg ⁻¹)	3.46E ⁻¹³	1.45E ⁻¹²	0.48	0.38	0.57	0.65	Medium متوسط
بی کربنات Bicarbonate (meq L ⁻¹)	4.59E ⁻⁰⁷	1.61E ⁻⁰⁶	0.36	0.25	0.46	0.51	Medium متوسط
درصد رس Clay content (%)	2.55E ⁻⁰⁴	4.88E ⁻⁰⁴	-0.27	-0.38	-0.15	0.44	Small کوچک
درصد سیلت Silt content (%)	8.55E ⁻⁰⁵	2.56E ⁻⁰⁴	0.26	0.14	0.37	0.58	Small کوچک
اسیدیته pH	1.64E ⁻⁰³	2.46E ⁻⁰³	-0.26	-0.37	-0.14	0.35	Small کوچک
درصد آهک TNV (%)	1.33E ⁻⁰⁴	2.81E ⁻⁰⁴	-0.26	-0.37	-0.14	0.54	Small کوچک
روی Zn (mg kg ⁻¹)	1.11E ⁻⁰⁴	2.81E ⁻⁰⁴	0.26	0.14	0.37	0.59	Small کوچک
کلسیم و منیزیم Ca + Mg (meq L ⁻¹)	1.34E ⁻⁰⁴	2.81E ⁻⁰⁴	0.25	0.13	0.37	0.58	Small کوچک
کلسیم Ca (meq L ⁻¹)	8.73E ⁻⁰⁴	1.53E ⁻⁰³	0.22	0.10	0.34	0.53	Small کوچک
منیزیم Mg (meq L ⁻¹)	9.92E ⁻⁰⁴	1.60E ⁻⁰³	0.22	0.10	0.34	0.55	Small کوچک
آهن Fe (mg kg ⁻¹)	1.93E ⁻⁰³	2.70E ⁻⁰³	0.20	0.08	0.32	0.57	Small کوچک
درصد اشباع SP (%)	8.58E ⁻⁰³	1.13E ⁻⁰²	-0.17	-0.29	-0.04	0.55	Small کوچک
هدایت الکتریکی EC (dS m ⁻¹)	3.47E ⁻⁰²	4.29E ⁻⁰²	0.14	0.01	0.26	0.55	Small کوچک
درصد شن Sand content (%)	7.26E ⁻⁰²	8.03E ⁻⁰²	-0.12	-0.24	0.00	0.52	Small کوچک
نسبت جذب سدیم SAR	6.75E ⁻⁰²	7.88E ⁻⁰²	-0.12	-0.24	0.01	0.54	Small کوچک
کلر Cl (meq L ⁻¹)	1.28E ⁻⁰¹	1.34E ⁻⁰¹	0.10	-0.02	0.22	0.48	Small کوچک
سدیم Na (meq L ⁻¹)	9.32E ⁻⁰¹	9.32E ⁻⁰¹	0.01	-0.12	0.13	0.47	Negligible ناچیز



شکل ۲- اندازه اثر تغییرات عمقی ویژگی‌های خاک با استفاده از اثر رتبه‌ای (r_{rb}) و بازه اطمینان ۹۵٪

خطوط عمودی نقطه‌چین و خط‌چین محدوده اثر احتمالی را نشان می‌دهند، نقطه‌ها نشان‌دهنده اندازه اثر واقعی برای هر ویژگی هستند. شکل‌ها شدت اثر را مشخص می‌کنند: دایره = بزرگ، لوزی = متوسط، مثلث = کوچک، مربع = ناچیز.

Figure 2- Depth-wise effect sizes of soil properties expressed as rank-biserial effect size (r_{rb}) with 95% confidence intervals (Vertical dashed and dotted lines indicate reference thresholds for effect interpretation, while the points represent the actual effect size for each variable. Shapes (circle, diamond, triangle, square) indicate effect magnitude: circle = large, diamond = medium, triangle = small, square = negligible.)

اطمینان و تفسیر عملی نتایج در کنار p-value در علوم رفتاری طبیعی و ارائه می‌دهد. از این رو، اتکا صرف به معنی‌داری آماری لزوماً بیانگر شدت، پایداری یا اهمیت مدیریتی تغییرات عمقی ویژگی‌های خاک نیست و استفاده از شاخص‌های مکمل نظیر اندازه اثر و عدم قطعیت ضروری به نظر می‌رسد. واسرستاین و همکاران نیز به نقد استفاده صرف از p-value به‌عنوان معیار قطعی برای نتیجه‌گیری آماری پرداخته و توصیه می‌کند که نتایج آماری فقط بر اساس آستانه‌های دلخواه (مثل $p < 0.05$) تعبیر نشوند، بلکه باید اندازه اثر، فواصل اطمینان و زمینه علمی تفسیر شوند و p-value به‌عنوان یک کمیت پیوسته و همراه با دیگر شاخص‌ها ارائه گردد تا از برداشت‌های غلط جلوگیری گردد (Wasserstein et al., 2019).

ترکیب اندازه اثر با شاخص احتمال جهت اثر (جدول ۲) نیز نشان داد که متغیرهای دارای اندازه اثر بزرگ، شواهد احتمالاتی قوی‌تری

در مجموع، مطالعات متعددی به بررسی تغییرات عمقی ویژگی‌های فیزیکی و شیمیایی خاک پرداخته‌اند. منابع مشابه نشان داده‌اند که بسیاری از عناصر غذایی و برخی ویژگی‌های شیمیایی خاک بین لایه‌های سطحی و زیرسطحی تفاوت معنی‌دار دارند و این تفاوت‌ها معمولاً با آزمون‌های آماری متداول و مقایسه میانگین‌ها گزارش شده‌اند. با این حال، در اغلب این مطالعات، تمرکز اصلی بر معنی‌داری آماری بوده و ارزیابی شدت واقعی، پایداری عمقی و اهمیت مدیریتی این تفاوت‌ها به‌طور نظام‌مند مورد توجه قرار نگرفته است. شایان ذکر است که مقدار p-value به‌شدت تحت تأثیر حجم نمونه قرار دارد؛ به‌گونه‌ای که با افزایش تعداد نمونه‌ها، حتی اختلاف‌های بسیار کوچک و از نظر عملکردی کم‌اهمیت نیز می‌توانند از نظر آماری معنی‌دار شوند (Cohen, 1994). مطالعه کلاسیک و طنزآمیز کوهن (۱۹۹۴) با وجود قالب طنزآمیز، تأکیدی جدی بر اهمیت استفاده از اندازه اثر، بازه‌های

برای تمایز عمقی دارند، در حالی که برای متغیرهای پایدار، عدم قطعیت همچنان بالاست. این رویکرد فراتر از p-value، امکان اولویت‌بندی ویژگی‌های خاک از نظر اهمیت مدیریتی را فراهم می‌کند. شاخص PD به‌عنوان شواهد مکمل نشان داد که برای بسیاری از متغیرها، مقادیر آن کمتر از آستانه ۰/۹۵ است. این یافته نشان می‌دهد که اگرچه جهت تغییر عمقی مشخص است، اما عدم قطعیت ذاتی داده‌های خاک همچنان قابل توجه است. به‌طور کلی، این نتایج حاکی از آن است که در خاک‌های نیمه‌خشک و دیم، عناصر غذایی مهم در لایه‌های سطحی تجمع می‌یابند و توزیع عمقی آن‌ها می‌تواند بر روی جذب گیاه و عملکرد محصول تأثیر مستقیم داشته باشد. از دیدگاه کاربردی و ترویجی، شناخت چنین الگوهای عمقی برای تعیین میزان و زمان کاربرد کودها و اصلاح‌کننده‌های خاک حیاتی است، به‌ویژه در سیستم‌های کشاورزی دیم و مناطق کم‌آب که مدیریت منابع خاک و عناصر غذایی اهمیت بسیار بالایی دارد.

تحلیل چندمتغیره: عمق به‌عنوان گرادینانی ضعیف اما معنی‌دار

نتایج آزمون پرمنا (جدول ۳) نشان داد که عمق خاک اثر معنی‌داری بر ترکیب کلی ویژگی‌های خاک دارد، هرچند مقدار ضریب تعیین R^2 کوچک بود. این موضوع بیانگر آن است که اگرچه عمق یک گرادینان قابل تشخیص است، اما ناهمگنی مکانی و عوامل مدیریتی سهم غالب‌تری در کنترل تغییرپذیری خاک دارند. غیرمعنی‌دار بودن آزمون پرمدیسپ نیز اعتبار نتایج پرمنا را تأیید کرد.

شاخص پایداری عمقی و طبقه‌بندی مدیریتی متغیرهای خاک


طبقه‌بندی متغیرها بر اساس شاخص پایداری عمقی تصویر کاربردی‌تری از حساسیت واقعی ویژگی‌های خاک ارائه می‌دهد. نتایج حاصل از بررسی شاخص پایداری عمقی نشان داد که ویژگی‌های خاک از نظر شدت و جهت پاسخ به افزایش عمق، رفتارهای کاملاً متمایزی از خود نشان می‌دهند (شکل ۳). این شاخص با اتکا بر اندازه اثر غیرپارامتری و فاصله اطمینان، امکان تفکیک ویژگی‌های پایدار، شبه‌پایدار و حساس به عمق را فراهم کرد و دیدگاهی فراتر از معنی‌داری آماری صرف ارائه داد. بر اساس مقدار مطلق اندازه اثر ($|r_{TB}|$)، متغیرها به چهار گروه طبقه‌بندی شدند که شامل متغیرهای پایدار ($|r| < 0/10$)، با حساسیت کم ($0/30 < |r| < 0/10$)، با حساسیت متوسط

($0/50 < |r| < 0/30$) و با حساسیت زیاد ($|r| > 0/50$) بودند. بر اساس شاخص پایداری عمقی، یون سدیم تنها متغیری بود که در گروه پایدار در امتداد عمق قرار گرفت؛ به‌طوری که اندازه اثر آن ناچیز بوده و فاصله اطمینان نیز تغییرات عمقی معنی‌داری را تأیید نکرد. این الگو بیانگر توزیع نسبتاً یکنواخت سدیم در نیم‌رخ خاک است که می‌تواند ناشی از کنترل آن توسط شرایط ژئوشیمیایی غالب، ترکیب مواد مادری و تعادل‌های تبدیلی در سیستم خاک باشد. در مقابل، متغیرهایی مانند کلر، نسبت جذب سدیم و درصد شن در گروه شبه‌پایدار قرار گرفتند که نشان می‌دهد اگرچه تغییرات عمقی آن‌ها از نظر آماری قابل تشخیص است، اما اندازه اثر محدود آن‌ها بیانگر اهمیت مدیریتی پایین‌تر این تغییرات است. بخش عمده‌ای از ویژگی‌های شیمیایی خاک، از جمله هدایت الکتریکی، کاتیون‌های کلسیم و منیزیم، آهن، روی و بی‌کربنات، در گروه حساس به عمق طبقه‌بندی شدند. این متغیرها عموماً گرایش به تجمع نسبی در لایه‌های زیرسطحی نشان دادند. با این حال، در شرایط اقلیم خشک و نیمه‌خشک، این الگو الزاماً ناشی از شست‌وشوی عمقی فعال نیست، بلکه می‌تواند حاصل برهم‌کنش فرآیندهایی نظیر تخییر بالا، حرکت محدود اما تدریجی محلول خاک، صعود موئینه، و انباشت املاح در افق‌های خاص باشد. بنابراین، تغییرات مشاهده‌شده را باید در چارچوب ویژگی‌های اقلیمی منطقه و دینامیک خاص آب و املاح در خاک‌های خشک تفسیر کرد. در مقابل، برخی ویژگی‌ها از جمله ماده آلی خاک، فسفر و پتاسیم قابل جذب و منگنز، اندازه اثر بزرگ و جهت‌دار نشان دادند و به‌عنوان ویژگی‌های به‌شدت وابسته به لایه سطحی شناسایی شدند. این متغیرها بیشترین حساسیت را نسبت به عمق داشتند و تغییرات آن‌ها عمدتاً بازتاب‌دهنده ورودی‌های زیستی، بقایای گیاهی و فعالیت‌های مدیریتی در لایه‌های سطحی خاک است. از منظر مدیریتی، این ویژگی‌ها مناسب‌ترین شاخص‌ها برای پایش کیفیت خاک و ارزیابی اثر مدیریت سطحی محسوب می‌شوند. ویژگی‌های پایدار یا شبه‌پایدار نیز اولویت کمتری برای مدیریت مبتنی بر عمق دارند و تغییرات آن‌ها را نمی‌توان صرفاً به اثر عمق نمونه‌برداری نسبت داد.

این چارچوب تفسیر مدیریتی مبتنی بر داده، نشان می‌دهد که همه تفاوت‌های آماری الزاماً از نظر عملکردی اهمیت ندارند و تمرکز مدیریت باید بر متغیرهایی با حساسیت واقعی به عمق باشد. این رویکرد چارچوبی کاربردی برای پایش کیفیت خاک، مدیریت کوددهی و ارزیابی پایداری خاک در مقیاس نیم‌رخ فراهم می‌کند.

جدول ۳- نتایج آزمون پرمانوا بر اساس فاصله بری-کور تیس برای بررسی اثر عمق خاک بر الگوی چندمتغیره ویژگی‌های خاک
Table 3- PERMANOVA results based on Bray-Curtis distances evaluating the effect of soil depth on multivariate soil property patterns

عامل Factor	درجه آزادی df	مجموع مربعات Sum of Squares	ضریب تعیین R ²	آماره شبه F Pseudo-F	مقدار p p-value
عمق خاک Depth	1	0.287	0.00791	5.2146	0.001
باقیمانده Residual	654	35.975	0.99209	—	—
کل Total	655	36.262	1.00000	—	—



شکل ۳- تثبیت عمقی و کلاس‌های مدیریتی متغیرهای خاک

(شکل‌ها نشان‌دهنده کلاس مدیریتی هستند: دایره = تجمع در عمق، مثلث = اولویت کم برای مدیریت عمقی، مربع = پایدار در تمام عمق‌ها، لوزی = کنترل سطحی).

Figure 4- Depth stability and management classes of soil variables

(Shapes indicate management class: circle = accumulating at deeper layer, triangle = low priority for depth-specific management, square = stable across depths, diamond = surface-controlled property).

نتیجه‌گیری

معنی‌داری آماری می‌تواند به برداشت‌های ناقص منجر شود. نتایج بیانگر آن بود که متغیرهایی مانند کربن آلی، فسفر، پتاسیم و منگنز دارای تغییرات عمقی معنی‌دار با اندازه اثر قابل توجه هستند، در حالی که برخی ویژگی‌ها نظیر رس، سیلت، پهاش و آهن از پایداری نسبی در نیم‌رخ برخوردارند. الگوی مشاهده‌شده، به‌ویژه تمرکز عناصر غذایی

این مطالعه با تلفیق تحلیل‌های زوجی، پرمانوا و شاخص‌های اندازه اثر غیرپارامتری، چارچوبی فراتر از مقایسات میانگین برای ارزیابی ناهمگنی عمقی خاک ارائه داد و نشان داد که تفسیر صرف مبتنی بر

را در کل ناحیه ریشه منعکس کند. این یافته‌ها بر ضرورت گذار به مدیریت عمق‌محور خاک و کوددهی هدفمند تأکید دارد؛ رویکردی که می‌تواند با بهبود توزیع عناصر غذایی در نیم‌رخ، کارایی مصرف نهاده‌ها و تاب‌آوری سیستم‌های زراعی در برابر تنش خشکی را افزایش دهد. بر اساس نتایج این پژوهش، پیشنهاد می‌شود مطالعات آینده بر (۱) ارزیابی پاسخ گیاه به مدیریت عمق‌محور کوددهی، به‌ویژه برای فسفر، پتاسیم و منگنز، (۲) بررسی ارتباط بین توزیع عمقی عناصر غذایی و توسعه سیستم ریشه، و (۳) تلفیق داده‌های شیمیایی خاک با شاخص‌های زیستی و فیزیکی در نیم‌رخ خاک متمرکز شوند. همچنین توسعه شاخص‌های ترکیبی مبتنی بر اندازه اثر می‌تواند ابزار مؤثری برای رتبه‌بندی محدودیت‌های عمقی خاک و تدوین توصیه‌های مدیریتی دقیق‌تر در مقیاس مزرعه و منطقه فراهم کند.

سپاسگزاری

نویسندگان مراتب قدردانی خود را از بخش تحقیقات خاک و آب مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان خراسان رضوی در راستای انجام این پژوهش ابراز می‌دارند. همچنین از همکاری ارزشمند و زحمات کارکنان آزمایشگاه به‌منظور ارائه پشتیبانی فنی صمیمانه سپاسگزاری می‌شود.

در لایه سطحی و فقر نسبی لایه‌های زیرین، بیش از آنکه ناشی از شست‌وشوی عمقی فعال باشد، تحت تأثیر محدودیت حرکت آب در خاک، تبخیر بالا، تجمع سطحی بقایا و ماهیت مدیریت زراعی در شرایط اقلیم خشک شکل گرفته است و بیانگر آن است که کارکرد مؤثر خاک عمداً به عمق ۳۰-۰ سانتی‌متر محدود شده و لایه‌های زیرین از نظر شیمیایی و زیستی در وضعیت ضعیف‌تری قرار دارند. چنین ساختاری موجب توسعه سطحی سیستم ریشه، کاهش بهره‌برداری گیاه از منابع آب و عناصر غذایی در عمق و افزایش حساسیت سیستم زراعی به تنش خشکی می‌شود؛ به‌گونه‌ای که پایداری تولید، به‌ویژه در سال‌های کم‌بارش، به‌طور جدی کاهش می‌یابد. دسته‌بندی متغیرها بر اساس حساسیت عمقی و کلاس مدیریتی، امکان اولویت‌بندی اقدامات اصلاحی و کوددهی را فراهم می‌کند و نشان می‌دهد که توجه ویژه به عناصر با اندازه اثر بزرگ در نیم‌رخ خاک می‌تواند بهره‌وری و پایداری سیستم خاک-گیاه را بهبود بخشد. این یافته‌ها به‌ویژه در کشاورزی دیم و مناطق کم‌آب، مبنای علمی برای طراحی استراتژی‌های هدفمند مدیریت خاک و کوددهی ارائه می‌کنند. نوآوری اصلی این پژوهش در تفکیک بین معنی‌داری آماری و اهمیت عملکردی تغییرات عمقی و ارائه یک طبقه‌بندی مبتنی بر اندازه اثر برای اولویت‌بندی مدیریتی متغیرهای خاک است؛ به‌گونه‌ای که نشان می‌دهد اتکا به نمونه‌برداری سطحی و کوددهی یکنواخت نمی‌تواند وضعیت واقعی حاصلخیزی خاک

References

1. Abbas, A., Hameed, R., Balooch, S., Khattak, W.A., Raza, M.M., Zulfikar, U., Akbar, R., Malik, U., & Huang, P. (2025). *Manganese dynamics: Effects of pollution and its impact on soil chemistry*. p. 241-257. In S. Saud, S. Fahad, & D. Wang (eds.) *Beneficial elements for remediation of heavy metals in polluted soil*. Elsevier. <https://doi.org/10.1016/B978-0-443-26522-8.00009-X>
2. Anderson, M.J. (2001). A new method for non-parametric multivariate analysis of variance. *Austral ecology*, 26(1), 32-46. <https://doi.org/10.1111/j.1442-9993.2001.01070.pp.x>
3. Anderson, M.J. (2017). Permutational Multivariate Analysis of Variance (PERMANOVA) *Wiley StatsRef: Statistics Reference Online*, 1-15. <https://doi.org/10.1002/9781118445112.stat07841>
4. Anderson, M.J., & Walsh, D.C. (2013). PERMANOVA, ANOSIM, and the Mantel test in the face of heterogeneous dispersions: what null hypothesis are you testing? *Ecological monographs*, 83(4), 557-574. <https://doi.org/10.1890/12-2010.1>
5. Benjamini, Y., & Hochberg, Y. (1995). Controlling the false discovery rate: a practical and powerful approach to multiple testing. *Journal of the Royal statistical society: series B (Methodological)*, 57(1), 289-300. <https://doi.org/10.1111/j.2517-6161.1995.tb02031.x>
6. Bernard-Verdier, M., Navas, M.L., Vellend, M., Violle, C., Fayolle, A., & Garnier, E. (2012). Community assembly along a soil depth gradient: contrasting patterns of plant trait convergence and divergence in a Mediterranean rangeland. *Journal of Ecology*, 100(6), 1422-1433. <https://doi.org/10.1111/1365-2745.12003>
7. Buol, S.W., Southard, R.J., Graham, R.C., & McDaniel, P.A. (2011). *Soil genesis and classification*: John Wiley & Sons. <https://doi.org/10.1002/9780470960622>
8. Cohen, J. (1994). The earth is round ($p < 0.05$). *American psychologist*, 49(12), 997. <https://doi.org/10.1037/0003-066X.49.12.997>
9. Cotrufo, M.F., Ranalli, M.G., Haddix, M.L., Six, J., & Lugato, E. (2019). Soil carbon storage informed by particulate and mineral-associated organic matter. *Nature Geoscience*, 12(12), 989-994. <https://doi.org/10.1038/s41561-019-0484-6>
10. Cumming, G. (2025). New Statistics, The. In: Lovric, M. (eds) *International Encyclopedia of Statistical Science*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-69359-9_704
11. Dhakad, R., Kumar, P., & Sharma, C.K. (2020). Status of soil pH, EC, OC and micronutrients levels in Madhya

- Pradesh: An overview. *Journal of Pharmacognosy and Phytochemistry*, 9(5), 14-12. www.phytojournal.com
12. Emamian, A., Rashki, A., Kaskaoutis, D.G., Gholami, A., Opp, C., & Middleton, N. (2021). Assessing vegetation restoration potential under different land uses and climatic classes in northeast Iran. *Ecological Indicators*, 122, 107325. <https://doi.org/10.1016/j.ecolind.2020.107325>
13. Fiel Peres, F. (2026). Effect sizes for nonparametric tests. *Biochem Med (Zagreb)*, 36(1), 010101. <https://doi.org/10.11613/bm.2026.010101>
14. Getnet, K., Miju, C., Bitew, A., & Atinafu, M. (2025). The Effects of Land Use Types and Soil Depths on Soil Micronutrients, Soil pH, and Organic Carbon in Southern Ethiopia. *Applied and Environmental Soil Science*, 2025(1), 5575783. <https://doi.org/10.1155/aess/5575783>
15. Hao, J., Chai, Y.N., Lopes, L.D., Ordóñez, R.A., Wright, E.E., Archontoulis, S., & Schachtman, D.P. (2021). The Effects of Soil Depth on the Structure of Microbial Communities in Agricultural Soils in Iowa, USA. *Appl Environ Microbiol*, 87(4). <https://doi.org/10.1101/2020.03.31.018416>
16. Havlin, J.L. (2014). Soil fertility and nutrient management. p. 460-469. In Y. Wang (ed.), *Encyclopedia of Natural Resources - Land*, vol 1. Boca Raton: CRC Print. <https://doi.org/10.1081/e-enrl-120047493>
17. Jalali, M., Buss, W., Parviznia, F., & Jalali, M. (2023). The status of phosphorus levels in Iranian agricultural soils—a systematic review and meta-analysis. *Environmental Monitoring and Assessment*, 195(7), 842. <https://doi.org/10.1007/s10661-023-11412-5>
18. Jenny, H. (1994). *Factors of soil formation: a system of quantitative pedology*: Courier Corporation.
19. Kerby, D.S. (2014). The simple difference formula: An approach to teaching nonparametric correlation. *Comprehensive Psychology*, 3. <https://doi.org/10.2466/11.IT.3.1>
20. Legendre, P., & Legendre, L. (2012). p. 419. *Numerical ecology, Developments in Environmental Modelling*. 3rd Edition, Elsevier, Amsterdam.
21. Makowski, D., Ben-Shachar, M.S., & Lüdtke, D. (2019). bayestestR: Describing effects and their uncertainty, existence and significance within the Bayesian framework. *Journal of Open Source Software*, 4(40), 1541. <https://doi.org/10.21105/joss.01541>
22. Montgomery, D.C. (2017). *Design and analysis of experiments*. p. 640. John Wiley & sons.
23. Nakagawa, S., & Cuthill, I.C. (2007). Effect size, confidence interval and statistical significance :a practical guide for biologists. *Biological Reviews*, 82(4), 591-605. <https://doi.org/10.1111/j.1469-185X.2007.00027.x>
24. Okolo, C.C., Gebresamuel, G., Zenebe, A., Haile, M., Orji, J.E., Okebalama, C.B., Eze, C.E., Eze, E., & Eze, P.N. (2023). Soil organic carbon, total nitrogen stocks and CO₂ emissions in top-and subsoils with contrasting management regimes in semi-arid environments. *Scientific Reports*, 13(1), 1117. doi:<https://doi.org/10.1038/s41598-023-28276-x>
25. Oksanen, J. (2015). Vegan: community ecology package. <http://CRAN.R-project.org/package=vegan>, 2, 3.
26. Richter, D.D., & Markewitz, D. (1995). How deep is soil? *BioScience*, 45(9), 600-609. <https://doi.org/10.2307/1312764>
27. Sokal, R.R., & Rohlf, F.J. (1987). *Biostatistics*. Francise & Co, New York, 10, 2088-2092 .
28. Sparks, D.L., Page, A.L., Helmke, P.A., & Loeppert, R.H . (2020) .*Methods of soil analysis, part 3: Chemical methods*: John Wiley & Sons.
29. Vance, C., Gaston, L., Blazier, M., & Beasley, J. (2024). Loblolly Pine Mid-Rotation Phosphorus Fertilization with Poultry Litter Ash or Triple Superphosphate. *Communications in Soil Science and Plant Analysis*, 55(13), 2000-2008. <https://doi.org/10.1080/00103624.2024.2336575>
30. Wasserstein, R.L., & Lazar, N.A. (2016). The ASA Statement on p-Values: Context, Process, and Purpose. *The American Statistician*, 70(2), 129–133. <https://doi.org/10.1080/00031305.2016.1154108>
31. Wasserstein, R.L., Schirm, A.L., & Lazar, N.A. (2019). Moving to a World Beyond “p < 0.05”. *The American Statistician*, 73(sup1), 1-19. <https://doi.org/10.1080/00031305.2019.1583913>
32. Wasserstein, R.L., Schirm, A.L., & Lazar, N.A. (2019). Moving to a world beyond “p< 0.05” (73: 1-19). Taylor & Francis.
33. Webster, R., & Oliver, M.A. (2007). *Geostatistics for environmental scientists*: John Wiley & Sons.
34. Weil, R.R., & Brady, N.C. (2016). *The Nature and Properties of Soils*: 15th Edition, Pearson Education Inc., Columbus.
35. Wiesmeier, M., Urbanski, L., Hobley, E., Lang, B., von Lützow, M., Marin-Spiotta, E., van Wesemael, B., Rabot, E., Lief, M., & Garcia-Franco, N. (2019) .Soil organic carbon storage as a key function of soils-A review of drivers and indicators at various scales. *Geoderma*, 333, 149-162. <https://doi.org/10.1016/j.geoderma.2018.07.026>
36. Xu, Z., Lai, T., Li, S., Si, D., & Zhang, C. (2025). Effective potassium management for sustainable crop production based on soil potassium availability. *Field Crops Research*, 326, 109865. <https://doi.org/10.1016/j.fcr.2025.109865>
37. Zhou, W., Han, G., Liu, M., Zeng, J., Liang, B., Liu, J., & Qu, R. (2020). Determining the distribution and interaction of soil organic carbon, nitrogen, pH and texture in soil profiles: a case study in the Lancangjiang River Basin, Southwest China. *Forests*, 11(5), 532. <https://doi.org/10.3390/f11050532>

Reliability Assessment of Gridded SPEI (SPEIbase) in Iran's Catchments

N. Poodineh¹, H. Nazaripour^{1*}, M. Khosravi¹

1- Department of Physical Geography, Faculty of Geography and Environmental Planning, University of Sistan and Baluchestan, Zahedan, Iran

(*- Corresponding Author Email: h.nazaripour@gep.usb.ac.ir)

Received: 17 February 2026

Revised: 13 April 2026

Accepted: 19 April 2026

Available Online: 19 April 2026

How to cite this article:

Poodineh, N., Nazaripour, H., & Khosravi, M. (2026). Reliability assessment of gridded SPEI (SPEIbase) in Iran's Catchments. *Journal of Water and Soil*, 39(6), 589-610. (In Persian with English abstract).

<https://doi.org/10.22067/jsw.2026.97825.1527>

Introduction

Drought is one of the most complex and costly natural disasters, and its accurate monitoring is essential for water resources management and vulnerability reduction. The Standardized Precipitation-Evapotranspiration Index (SPEI), as a bivariate index, utilizes precipitation and temperature data (to estimate evapotranspiration) and has gained widespread application due to its multiscalar nature and sensitivity to climate change. However, limited access to long-term and uniform station-based data in a country with high climatic diversity and complex topography like Iran poses a significant challenge for accurate drought monitoring. The global gridded database SPEIbase, with a spatial resolution of 0.5 arc degrees, has been developed by integrating satellite data, climate models, and in-situ measurements. This study aims to evaluate the reliability of SPEIbase compared to station-based data across Iran's catchments to assess the feasibility of substituting this database due to its extensive spatial coverage and easier accessibility.

Materials and Methods

Two datasets were used in this research: 1) Station data including monthly precipitation time series and monthly mean temperature from 43 meteorological stations in Iran for the statistical period 1986-2023, obtained from the Iran Meteorological Organization (IRIMO). 2) Gridded SPEIbase data, version 2.11, based on the CRU TS 4.09 dataset, extracted for the same period from the Climatic Research Unit (CRU) at the University of East Anglia. The station-based SPEI was calculated using potential evapotranspiration estimated via the Thornthwaite method at time scales of 1, 3, 6, 9, and 12 months. The SPEIbase index, based on potential evapotranspiration estimated via the FAO-56 Penman-Monteith method, was extracted for the corresponding period. The concordance and agreement between the two indices were evaluated using three statistical methods: 1) Pearson's correlation coefficient to assess linear relationship, 2) Weighted Cohen's Kappa statistic to measure agreement in drought classes (8 classes ranging from extreme drought to extremely wet), and 3) Bland-Altman plots to examine limits of agreement and systematic bias.

Results and Discussion

Findings indicated that the Pearson correlation coefficient between SPEI and SPEIbase fell within the strong correlation range (0.70 to 0.90) for most stations and catchments in Iran. The highest correlations were observed at stations in mountainous areas, such as Khorramabad (0.92), Hamedan (0.87), and Urmia (0.86) at the 12-month scale. Conversely, coastal and lowland stations like Bandar Abbas, Ramsar, and Babolsar showed relatively weaker correlations (0.63 to 0.67) at shorter time scales. Results from the Weighted Cohen's Kappa statistic also demonstrated substantial agreement (0.60 to 0.80) in drought classification between the two indices in



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.97825.1527>

mountainous regions and moderate agreement (0.40 to 0.60) in lowland and coastal areas. Bland-Altman plots revealed narrow limits of agreement and random scatter of points around the mean line, indicating no significant systematic bias. A key finding was the increase in correlation and agreement with increasing time scale; the highest agreement was observed at 9 and 12-month scales (hydrological drought) and the lowest at the 1-month scale (meteorological drought). Bam station, with a mean annual precipitation of approximately 53.7 mm, exhibited the lowest correlation (0.64) and agreement (0.39) at the 12-month scale, possibly due to hyper-arid conditions and limitations of evapotranspiration estimation methods in such climates. Constructed violin plots confirmed the concentration of correlation and kappa coefficients at higher ranges with increasing time scale.

Conclusion

The SPEIbase database demonstrates suitable accuracy for drought monitoring across Iran's catchments and shows high concordance and agreement with station-based data in many regions, particularly mountainous areas. As the time scale increases from 1 to 12 months, correlation and agreement improve, indicating higher reliability of this database for monitoring agricultural and hydrological droughts. In coastal and lowland regions, especially at shorter time scales, caution is recommended when using this database. Given its extensive spatial coverage, appropriate temporal resolution, and free accessibility, SPEIbase can serve as a reliable alternative to station-based data in data-sparse regions or areas with incomplete records. It is suggested that future research calculate station-based SPEI using the FAO-56 Penman-Monteith method to evaluate the impact of the evapotranspiration estimation method on the level of agreement with SPEIbase.

Acknowledgement

The authors would like to thank the Iran Meteorological Organization (IRIMO) for providing the meteorological data used in this research free of charge.

Keywords: Bland and Altman plot, Degree of agreement, Drought, Pearson's correlation coefficient, Weighted Cohen's Kappa

ارزیابی قابلیت اطمینان داده‌های شبکه‌بندی شاخص استاندارد شده بارش - تبخیر و تعرق در حوضه‌های آبریز ایران

نادیا پودینه^۱ - حمید نظری‌پور^{۱*} - محمود خسروی^۱

تاریخ دریافت: ۱۴۰۴/۱۱/۲۸

تاریخ پذیرش: ۱۴۰۵/۰۱/۳۰

چکیده

شاخص استاندارد شده بارش - تبخیر و تعرق (SPEI)، از پرکاربردترین شاخص‌های ارزیابی خشکسالی در سطح جهان به شمار می‌رود. این شاخص، از متغیرهای بارش و دما (به منظور تخمین تبخیر و تعرق) به عنوان داده‌های ورودی خود برای ارزیابی خشکسالی استفاده می‌کند و به این ترتیب به عنوان یک شاخص دومتغیره خشکسالی شناخته می‌شود. محدودیت دسترسی به داده‌های ایستگاهی بلندمدت و یکنواخت در گستره‌هایی با پیچیدگی ناهمواری و تنوع اقلیمی زیاد (به مانند ایران)، چالش جدی برای پایش دقیق شرایط خشکسالی ایجاد می‌کند. در این راستا، پایگاه داده شبکه‌بندی شده جهانی از این شاخص (SPEIbase) مبتنی بر تلفیق داده‌های ماهواره‌ای، مدل‌های اقلیمی و داده‌های اندازه‌گیری شده، توسعه داده شده است. بنابراین، این پژوهش به بررسی سطح توافقی بین SPEI و SPEIbase به عنوان ابزارهای ارزیابی خشکسالی در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه متمرکز است تا قابلیت اطمینان به جایگزینی آن را به دلیل وضوح زمانی و مکانی بالا و دسترسی سریع‌تر فراهم نماید. ارزیابی میزان هماهنگی و توافقی بین SPEI و SPEIbase از طریق آزمون همبستگی خطی پیرسون، آزمون وزن‌دار کاپای کوهن و نمودار بلند-آلتمن انجام گرفته است. شاخص SPEI بر مبنای داده‌های بارش و دمای مقیاس ماهانه از ۴۳ ایستگاه هواشناسی ایران در دوره ۱۹۸۶ تا ۲۰۲۳ و بر پایه برآورد تبخیر و تعرق پتانسیل مبتنی بر معادله تورنتویت محاسبه شده است. شاخص SPEIbase نیز که بر مبنای مجموعه داده‌های سری زمانی اقلیمی نسخه ۴/۰۹ واحد تحقیقات اقلیمی و بر پایه برآورد تبخیر و تعرق پتانسیل مبتنی بر معادله پنمن-مانتیت فائو ۵۶، محاسبه شده برای دوره مشابه استخراج شده است. یافته‌ها بیانگر ضریب همبستگی قوی و توافقی زیاد بین SPEI و SPEIbase در اکثر مناطق ایران است. به‌طور کلی، میزان همبستگی از مقیاس‌های کوتاه‌تر (۱ و ۳ ماهه) به مقیاس‌های بلندتر (۶ و ۱۲ ماهه) افزایش دارد. به عنوان یافته کلی، SPEIbase در بسیاری از مناطق ایران، به‌ویژه در نواحی کوهستانی، قابلیت جایگزینی برای داده‌های ایستگاهی را دارا می‌باشد.

واژه‌های کلیدی: آزمون وزن‌دار کاپای کوهن، خشکسالی، درجه توافقی، ضریب همبستگی پیرسون، نمودار بلند-آلتمن

مقدمه

خشکسالی برای پایش و تعیین کمیت شدت، مدت، فراوانی و گستره مکانی خشکسالی در مقیاس‌های منطقه‌ای و به‌ویژه محلی ضروری هستند. سیستم‌های پایش خشکسالی سامانه‌های اطلاعاتی بی‌درنگ هستند که بر داده‌های شدت خشکسالی متمرکز شده‌اند. آنها برای تعیین شروع و توسعه خشکسالی و تعیین میزان فضایی خشکسالی در هر زمان مفید هستند (Vicente-Serrano et al., 2022). با توجه به تغییرات اقلیمی و افزایش وقوع رخداد‌های حدی مانند خشکسالی‌های شدید،

خشکسالی یکی از پیچیده‌ترین و مخرب‌ترین بلایای طبیعی در سطح جهان بوده و ویرانی زیست‌محیطی و اقتصادی در مناطق مختلف جهان به بار آورده است. خشکسالی به دلیل تأثیرات ناشی از تعامل میان کاهش بارندگی و تقاضای انسانی برای تأمین آب شناخته شده است (Bisht et al., 2023). مجموعه داده‌های با وضوح بالا از معیارهای

۱- گروه جغرافیای طبیعی، دانشکده جغرافیا و برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان، زاهدان، ایران

(*)- نویسنده مسئول: (Email: h.nazaripour@gep.usb.ac.ir)

(Peña-Gallardo et al., 2019; Ahmadalipour et al., 2017). محاسبه SPEI در سطح ایستگاه‌های هواشناسی، نیازمند داده‌های زمانی با دقت بالا شامل بارش ماهانه و دمای هوا (به‌منظور تخمین تبخیر و تعرق) است. در کشورهای گسترده و با تنوع اقلیمی زیاد مانند ایران، محدودیت دسترسی به داده‌های ایستگاهی بلندمدت و یکنواخت، به‌ویژه در مناطق کم‌برخوردار، چالشی جدی در پایش دقیق شرایط اقلیمی ایجاد می‌کند (Raziei et al., 2009). در این راستا، استفاده از پایگاه‌های داده شبکه‌بندی شده جهانی مانند SPEIbase که مبتنی بر تلفیق داده‌های ماهواره‌ای، مدل‌های اقلیمی و داده‌های اندازه‌گیری شده هستند، به‌عنوان جایگزینی مناسب برای نواحی فاقد داده‌های کافی مطرح می‌گردد. با این وجود، دقت این پایگاه داده در مناطق مختلف، خصوصاً در اقلیم‌های خشک، نیمه‌خشک، و کوهستانی ایران، ممکن است متفاوت باشد. بنابراین، ارزیابی عملکرد شاخص SPEI استخراج‌شده از پایگاه‌های شبکه‌بندی شده در مقایسه با داده‌های ایستگاهی، گامی ضروری برای اطمینان از کارایی این منابع در تحلیل‌های منطقه‌ای و تصمیم‌گیری‌های مدیریتی محسوب می‌شود (Nikdad et al., 2023).

چندین پایگاه داده مربوط به پایش خشکسالی در سطح جهانی تهیه شده است. با این حال، شاخص‌های خشکسالی جهانی کنونی تنها با وضوح فضایی درشت‌تر (بیش از ۵۰ کیلومتر) در دسترس هستند (Gebrechorkos et al., 2023). در این بین پایگاه داده شبکه‌بندی شده خشکسالی شاخص استاندارد تبخیر-بارش (SPEI) یک از پایگاه‌های داده با وضوح بالا، می‌باشد که دوره‌ای به نسبت طولانی از ۱۹۸۱ تا ۲۰۲۴ را پوشش می‌دهد. این پایگاه داده بر اساس بارش و تبخیر و تعرق پتانسیل ماهانه از واحد تحقیقات دانشگاه انگلیای شرقی است که از ژانویه ۱۰۹۱ شروع و به محض دسترسی به داده‌های جدید، بروز می‌شود. پایگاه داده SPEI بر اساس تخمین تبخیر و تعرق پتانسیل از معادله پنمن - مانتیث (FAO-56) است. این یک تفاوت عمده با توجه به پایش خشکسالی جهانی SPEI است که از معادله تورنتویت برای برآورد تبخیر و تعرق پتانسیل استفاده می‌کند. روش پنمن - مانتیث یک روش برتر در برآورد تبخیر و تعرق پتانسیل در نظر گرفته می‌شود و بنابراین SPEIbase برای اکثر موارد از جمله تجزیه و تحلیل اقلیم‌شناسی طولانی‌مدت توصیه می‌شود. استفاده از جدیدترین نسخه این پایگاه داده توصیه می‌شود، اما همه نسخه‌های آن در دسترس هستند. SPEI v.2.11 جدیدترین نسخه این پایگاه داده است که از مجموعه داده‌های CRU TS 4.09 که دوره بین ژانویه ۱۹۰۱ تا دسامبر ۲۰۲۴ را در برمی‌گیرد، محاسبه می‌گردد.

با وجود مزیت‌های استفاده از این پایگاه‌ها برای پُرکردن خلأ داده‌ای، میزان تطابق نتایج آن‌ها با داده‌های واقعی ایستگاهی در مناطق مختلف همچنان محل تردید است (Mehran et al., 2015). عملکرد این پایگاه‌ها ممکن است تحت تأثیر شرایط اقلیمی گوناگون کشور،

استفاده از منابع داده‌ای با پوشش زمانی بلندمدت و دقت بالا بیش از پیش اهمیت یافته است (Gebrechorkos et al., 2023). پایش خشکسالی و بررسی تغییرپذیری بارش با هدف برقراری آمادگی در برابر اثرات خشکسالی و ایجاد استراتژی‌های کاهش آسیب‌پذیری سیستم‌های منابع آب هر منطقه، امری ضروری است (Ojha et al., 2021).

یکی از چالش‌های اساسی در مطالعات اقلیم‌شناسی و مدیریت منابع آب، پایش دقیق خشکسالی در مناطق مختلف جغرافیایی به‌ویژه در کشورهایی با ناهمواری پیچیده و تنوع اقلیمی زیاد مانند ایران است. خشکسالی پدیده‌ای پیچیده و چندبعدی است که ارزیابی آن تنها بر پایه یک متغیر (بارش) کافی نیست؛ چرا که تبخیر و تعرق نیز نقش تعیین‌کننده‌ای در تعیین تراز آبی مناطق دارد. در سال‌های اخیر، ابزارهای سنجش خشکسالی از طریق شاخص‌های اقلیمی توسعه چشم‌گیری یافته‌اند. در این میان، شاخص استاندارد شده بارش-تبخیر و تعرق (SPEI)، به‌عنوان ابزاری توسعه‌یافته برای بررسی جامع‌تر خشکسالی، در سال‌های اخیر توجه گسترده‌ای را به خود جلب کرده است. با این حال، دقت آن به شدت وابسته به کیفیت و صحت داده‌های ورودی است (Vicente-Serrano et al., 2010). این شاخص به‌دلیل در نظر گرفتن همزمان دو مؤلفه مهم بارش و تبخیر و تعرق، توانسته است دید بهتری نسبت به شدت و تداوم خشکسالی‌ها ارائه دهد. از این رو، شاخص استاندارد شده بارش-تبخیر و تعرق (SPEI) یک شاخص خشکسالی چندمقیاسی بر اساس داده‌های اقلیمی است که می‌توان از آن برای تعیین شروع، طول مدت و بزرگی شرایط خشکسالی با توجه به شرایط عادی در انواع سیستم‌های طبیعی و مدیریت شده مانند محصولات زراعی، اکوسیستم‌ها، رودخانه‌ها، منابع آبی و غیره استفاده کرد (Nazaripour et al., 2022). شاخص‌های خشکسالی باید از نظر آماری قوی بوده و به راحتی با یک روش محاسباتی واضح و قابل درک محاسبه شوند (Keyantash & Dracup, 2002). تمامی این الزامات توسط SPEI برآورده شده است (Brands et al., 2025). با این حال، یک مزیت مهم SPEI نسبت به سایر شاخص‌های خشکسالی پُرکاربرد که تأثیر تبخیر و تعرق (PET) را بر شدت خشکسالی در نظر می‌گیرند این است که ویژگی‌های چندمقیاسی آن امکان شناسایی انواع مختلف خشکسالی و اثرات آن را در زمینه گرمایش جهانی فراهم می‌کند (Manzano et al., 2019). این ویژگی به‌ویژه در مناطق خشک و نیمه‌خشک که تبخیر و تعرق نقش مهمی در کمبود منابع آبی دارد، اهمیت دوچندان می‌یابد. همچنین، SPEI دارای ماهیت چندمقیاسی است و می‌تواند برای تحلیل خشکسالی در بازه‌های زمانی مختلف (از یک ماهه تا چند ساله) مورد استفاده قرار گیرد، در حالی که شاخص‌هایی مانند PDSI فاقد این انعطاف‌پذیری زمانی هستند. به همین دلیل، SPEI به‌عنوان شاخصی جامع‌تر و حساس‌تر نسبت به تغییرات اقلیمی، در بسیاری از مطالعات اقلیمی و منابع آب توصیه شده است

دانشگاه انگلیای شرقی تهیه شده و از ژانویه ۱۹۰۱ آغاز شده است، و به محض در دسترس قرار گرفتن داده‌های جدید بروز رسانی می‌شود. پایگاه داده SPEIbase شامل مقادیر استاندارد شده برای پیکسل‌های خشکی است. در برخی موارد نادر که امکان دستیابی به تطابق مناسب با توزیع لجستیک - لگاریتمی وجود نداشته، که منجر به مقدار NAN (غیر عددی) در پایگاه داده شده است. پایگاه داده SPEIbase بر اساس برآورد تبخیر و تعرق پتانسیل پنمن - مانیت ۵۶-FAO استوار است. این تفاوت عمده‌ای با پایش جهانی خشکسالی SPEI دارد که از برآورد تبخیر و تعرق پتانسیل تورنت ویت استفاده می‌کند. روش پنمن - مونیت به عنوان روشی برتر شناخته می‌شود، بنابراین SPEIbase برای اکثر کاربردها، از جمله تحلیل‌های اقلیمی بلندمدت، توصیه می‌شود. یک نمونه نقشه جهانی از شاخص شبکه‌بندی شده SPEIbase در (شکل ۲) ارائه شده است. نسخه‌های متفاوتی از این پایگاه داده موجود می‌باشد. در این پژوهش از نسخه بروز این پایگاه داده که SPEIbase ۲.11 نامیده می‌شود، استفاده شده است. این نسخه از پایگاه داده، دوره ژانویه ۱۹۰۱ تا دسامبر ۲۰۲۴ را پوشش می‌دهد و بر مبنای مجموعه داده‌های سری‌های زمانی اقلیمی واحد تحقیقات اقلیمی CRU TC V.4.09 دانشگاه انگلیای شرقی محاسبه شده است. این مجموعه داده در https://crudata.uea.ac.uk/cru/data/hrg/cru_ts_4.09 موجود است. این پروژه با حمایت مالی و علمی چندین نهاد مهم، از جمله شورای تحقیقات محیط‌زیست طبیعی بریتانیا (NERC) و وزارت انرژی ایالات متحده آمریکا، ایجاد شده است. پشتیبانی بلندمدت این مجموعه داده اقلیمی در حال حاضر توسط مرکز ملی علوم جوی بریتانیا (NCAS) تأمین می‌شود.


با بهره‌گیری از تابع `inpolygon` در محیط برنامه‌نویسی متلب، یاخته‌های موجود در گستره ایران استخراج شده‌اند (شکل ۲). با اعمال مرز بین‌المللی، تعداد ۶۲۱ یاخته در درون قلمرو ایران قرار گرفت. بنابراین، یک پایگاه داده جدید به ابعاد `SPEIbase456x621` ایجاد گردید. در این پایگاه داده، سطرها بیانگر زمان و ستون‌ها بیانگر یاخته (مکان) می‌باشند. از آن‌جا که شاخص SPEIbase دارای ویژگی چند مقیاسی می‌باشد، مقیاس‌های ۱، ۳، ۶، ۹ و ۱۲ بر اساس مرور منابع انتخاب گردیدند. استخراج SPEIbase برای ایستگاه‌های هواشناسی با میانگین حداکثر نه نقطه پیرامونی ایستگاه هواشناسی انتخاب شده است. به گونه‌ای که ایستگاه هواشناسی در مرکز این نقاط قرار بگیرد. تعداد یاخته‌های مورد استفاده در ایستگاه‌های هواشناسی واقع در مرزها کاهش می‌یابد. ملاحظات هیدرواقلیمی مانند حوضه‌های آبریز و شرایط توپوگرافی نیز در انتخاب تعداد یاخته‌ها تأثیرگذار بوده است.

مانند اقلیم خشک مناطق مرکزی ایران، یا اقلیم کوهستانی، دچار نوسان شود. از این‌رو، ارزیابی دقت پایگاه SPEIbase در مقایسه با داده‌های زمینی در حوضه‌های آبریز مختلف، گامی حیاتی برای افزایش اعتمادپذیری این داده‌ها در تصمیم‌گیری‌های مدیریتی، مدل‌سازی‌های اقلیمی و برنامه‌ریزی منابع طبیعی به شمار می‌آید. عمده تحقیقات در سالیان اخیر پیرامون ارزیابی پایگاه‌های جهانی بارش شبکه‌بندی شده صورت گرفته است (Imran et al., 2023; Satge et al., 2020). با این وجود، تحقیقات بسیار کمی به ارزیابی دقت پایگاه‌های شبکه‌بندی خشکسالی پرداخته است. در مجموع، خلأ دانش در زمینه ارزیابی دقت پایگاه‌های داده جهانی خشکسالی مانند SPEIbase در مناطق متنوع اقلیمی ایران، از اصلی‌ترین انگیزه‌های انجام این پژوهش به شمار می‌رود. علی‌رغم مزایای بالقوه این پایگاه‌ها در پوشش گسترده و در دسترس بودن داده، عدم شناخت کافی از میزان دقت و قابلیت اعتماد آن‌ها در سطوح محلی، تصمیم‌گیری‌های مدیریتی را با چالش مواجه می‌کند. این پژوهش، با هدف ارزیابی دقت پایگاه SPEIbase عملکرد آن در بازتاب شرایط واقعی خشکسالی در حوضه‌های آبریز مختلف ایران و تحت اقلیم‌های متنوع مورد بررسی قرار دهد تا قابلیت اطمینان آن برای استفاده در مطالعات آینده سنجیده شود.

داده و روش‌شناسی

داده‌های این پژوهش، دو دسته می‌باشند. ۱) دسته نخست شامل سری‌های زمانی مجموع بارندگی ماهانه و میانگین دمای ماهانه از تعداد ۴۳ ایستگاه هواشناسی در دوره ۱۹۸۶ تا ۲۰۲۳ می‌باشند. این داده‌ها با درخواست کتبی از آرشیو سازمان هواشناسی کشور تهیه شده‌اند. این دوره زمانی بیشترین بازه زمانی مشترک برای داده‌های دما و به‌ویژه بارش ثبت شده در ایستگاه‌های هواشناسی ایران است. از طرف دیگر، این بازه زمانی دارای کمترین داده گمشده در سری‌های زمانی دما و بارش می‌باشد. اطلاعات مربوط به ایستگاه‌ها در (جدول ۱) و موقعیت جغرافیایی آن‌ها به همراه حوضه‌های آبریز شش‌گانه ایران در (شکل ۱) نمایش داده شده است.

دسته دوم داده‌ها شامل داده‌های شبکه‌بندی شده شاخص بارش - تبخیر و تعرق است که اصطلاحاً SPEIbase نامیده می‌شود. این پایگاه داده جهانی، اطلاعات بلندمدت و قابل اعتمادی درباره خشکسالی در مقیاس جهانی با قدرت تفکیک ۰/۵ درجه قوسی را ارائه می‌دهد. این پایگاه داده دارای ویژگی چند مقیاسی بوده و مقیاس‌های زمانی شاخص SPEI را بین ۱ تا ۴۸ ماه ارائه می‌کند. این داده‌ها بر اساس اطلاعات ماهانه بارندگی و تبخیر و تعرق پتانسیل از واحد تحقیقات اقلیمی



شکل ۱- موقعیت جغرافیایی حوزه‌های آبریز ایران و ایستگاه‌های هواشناسی مورد مطالعه
Figure 1- Geographical location of Iran's catchments and studied meteorological stations

(Lweendo *et al.*, 2017). روش پنمن- مانتیت از نظر فیزیکی دقیق‌ترین و قابل اعتمادترین روش محسوب می‌گردد (Allen *et al.*, 2000). اما نیازهای داده‌ای آن (مانند دمای هوا، رطوبت نسبی، باد و تابش خالص) استفاده از آن را در مقایسه با سایر روش‌ها دشوارتر می‌سازد. مدل هارگریوز مدلی ساده‌تر است، اما همچنان به دو پارامتر هواشناسی، دما (میانگین، بیشینه و کمینه) و تابش ورودی، نیاز دارد (Tukimat *et al.*, 2012; Hargreaves & Samani, 1985). در حالی که، روش تورنتویت تنها به داده دما نیاز دارد. اگرچه روش تورنتویت به داده‌های کمتری نیاز دارد، اما در مناطقی که با شرایط جغرافیایی اولیه توسعه این روش تفاوت دارند، مقدار PET را بیش از حد برآورد می‌کند (Allen *et al.*, 1998; Tukimat *et al.*, 2012). بنابراین در این مطالعه، با توجه به محدودیت داده‌ها، از روش تورنتویت برای محاسبه تبخیر و تعرق پتانسیل به عنوان ورودی شاخص SPEI در سطح ایستگاه‌های هواشناسی استفاده می‌گردد که بر پایه میانگین ماهانه دما و عرض جغرافیایی ایستگاه هواشناسی استوار است. در حالی که، پایگاه داده شاخص SPEIbase بر اساس برآورد تبخیر و تعرق پتانسیل با استفاده از روش پنمن- مانتیت FAO-56 بنا شده است (Vicente-Serrano *et al.*, 2010). در آخر شاخص SPEI، که حاصل تفاوت بین بارش (P) و PET ماهانه است، با استفاده از معادله (۱) به صورت زیر محاسبه می‌گردد:

$$SPEI_i = P_i - PET_i \quad (1)$$


شاخص استاندارد شده بارش- تبخیر و تعرق با وجود مقبولیت گسترده‌تر، شاخص استاندارد شده بارش (SPI) از بین تمامی شرایط جوی که بر شدت خشکسالی تأثیر می‌گذارند، تنها بارش را در نظر می‌گیرد. شرایط جوی که ممکن است بر وقوع و شدت خشکسالی تأثیر بگذارند شامل بارندگی، دما، سرعت باد و رطوبت می‌باشد. برای اطمینان از شمول یک عنصر جوی دیگر در محاسبات، شاخص استاندارد شده بارش- تبخیر و تعرق (SPEI)، توسط (Vicente-Serrano *et al.*, 2010) ارائه شده است. شاخص SPEI به روشی مشابه SPI محاسبه می‌گردد، اما تغییرات دما را به عنوان بخشی از تحلیل‌های خود لحاظ می‌کند (Lweendo *et al.*, 2017). این شاخص، سادگی، ماهیت چند زمانه‌ای و قابلیت تفسیر آماری شاخص SPI را حفظ نموده و در عین حال توانسته است معیاری جامع‌تر برای سنجش تغییرپذیری اقلیم در یک منطقه ارائه دهد (Tefera *et al.*, 2019). درج تبخیر و تعرق پتانسیل (PET) موجب ایجاد تفاوت محسوسی در مقادیر شاخص می‌شود که تأیید می‌کند SPEI یک شاخص اساساً متفاوت نسبت به SPI ارائه می‌دهد. در نتیجه، SPEI به عنوان جایگزینی برای SPI جهت کمی‌سازی انحراف از نرمال در تراز آب اقلیمی تجمعی و با لحاظ تبخیر و تعرق پتانسیل پیشنهاد می‌شود (Stagge *et al.*, 2015).

معادلات متعددی برای مدل‌سازی تبخیر- تعرق پتانسیل وجود دارد (از قبیل معادله تورنتویت، معادله پنمن- مانتیت، معادله هارگریوز و غیره). با این حال، شاخص SPEI به هیچ معادله خاصی وابسته نیست

جدول ۱- مشخصات اقلیمی و ارتفاعی ایستگاه‌های هواشناسی مورد مطالعه

Table 1- Climatic and altitude characteristics of the studied meteorological stations

ردیف NO.	ایستگاه Station	ارتفاع Elev (m)	بارش P (mm)	دما T (C)	ردیف NO.	ایستگاه Station	ارتفاع Elev (m)	بارش P (mm)	دما T (C)
1	آبادان Abadan	6.6	149.69	26.51	23	مشهد Mashhad	922.2	236.79	15.75
2	اهواز Ahvaz	22.5	215.87	26.42	24	ارومیه Urmia	1328	311.78	11.79
3	اراک Arak	1702.8	300.15	14.23	25	قزوین Qazvin	1279.1	306.31	14.55
4	اردبیل Ardabil	1335.2	272.18	9.63	26	رامسر Ramsar	-20	1249.94	16.83
5	بابلسر Babolsar	-21	906.68	17.90	27	رشت Rasht	-8.6	1308.08	16.73
6	بم Bam	1066.9	53.70	24.15	28	سبزوار Sabzvar	962	180.47	18.51
7	انزلی Anzali	23.6	1743.44	16.88	29	سنندج Sanandaj	1373.4	385.82	14.30
8	بندر لنگه Bandar Lengeh	22.7	121.17	27.26	30	سقز Saqez	1522.8	453.07	11.11
9	بندرعباس Bandar Abbas	9.8	161.90	27.16	31	سراوان Saravan	1182	107.98	22.39
10	بیرجند Birjand	1491	151.31	16.67	32	سمنان Semnan	1127	132.04	18.66
11	بجنورد Bojnurd	1150	248.09	13.58	33	شهرکرد Sharkurd	2048.9	314.59	11.43
12	بوشهر Bushher	9	251.76	25.44	34	شاهرود Shahrud	1325.2	150.83	15.44
13	چابهار Chabahar	8	122.79	26.54	35	شیراز Shiraz	1488	314.32	18.56
14	دزفول Dezful	143	395.28	24.57	36	طیس Tabas	711	79.53	23.03
15	اصفهان Isfahan	1551.9	128.55	17.09	37	تبریز Tabriz	1361		13.44
16	گرگان Gorgan	2	498.79	18.01	38	تهران Tehran	1191		18.38
17	همدان Hamedan	1740.8	303.71	11.90	39	تربت حیدریه Torbat heydarieh	1451		14.50
18	ایران شهر Iranshahr	591.1	105.96	27.20	40	یزد Yazd	1230.2		20.29
19	کرمان Kerman	1754	124.14	16.55	41	زابل Zabol	489.2		22.87
20	کرمانشاه Kermanshah	1318.5	411.35	15.37	42	زاهدان Zahedan	1370		19.10
21	خرم‌آباد Khorramabad	1147.8	479.31	17.04	43	زنجان Zanjan	1659.4		11.58
22	خوی Khoy	1103.4	263.87	12.85					



شکل ۲- نقشه جهانی نمونه از شاخص SPEIbase (سمت چپ) و موقعیت یاخته‌های استخراجی از آن برای ایران (سمت راست)
Figure 2- Global map of the SPEIbase sample (left) and the location of extracted cells from it for Iran (right).

جدول ۲- معیارهای طبقه‌بندی برای شاخص‌های خشکسالی SPEI و SPEIbase

Table 2- Classification criteria for SPEI and SPEIbase

رده	شرح	رده ترتیبی	مقادیر SPEI و SPEIbase
Catagory	Description	Ordinal class	SPEI and SPEIbase values
W3	ترسالی بسیار شدید Extremely wet	8	> 2.00
W2	ترسالی شدید Very wet	7	1.5 to 1.99
W1	ترسالی متوسط Moderately wet	6	1.00 to 1.49
W0	ترسالی خفیف Mildly wet	5	0 to 0.99
D0	خشکسالی خفیف Mild drought	4	0 to -0.99
D1	خشکسالی متوسط Moderate drought	3	-1.0 to -1.49
D2	خشکسالی شدید Severe drought	2	-1.5 to -1.99
D3	خشکسالی خیلی شدید Extreme drought	1	< -2.00

ع ۹ و ۱۲ ماهه با استفاده از بسته SPEI (Beguería & Vicente-
Serrano, 2023) در نرم‌افزار R محاسبه گردیده است. طبقه‌بندی
شاخص SPEI و SPEIbase در (جدول ۲) ارائه شده است.

ارزیابی رابطه خطی بین SPEI و SPEIbase

آزمون رابطه خطی بین SPEI و SPEIbase با استفاده از ضریب
همبستگی پیرسون که ضریب همبستگی گشتاوری نیز نامیده می‌شود،
انجام شد. به نقل از گیوارینا (Giavarina, 2015) ضریب همبستگی
پیرسون پیرسون، رایج‌ترین تکنیک آماری است که برای نشان دادن

که در آن، PET ماهانه با استفاده از معادله تورنت‌ویت (معادله ۲)
به صورت زیر محاسبه می‌شود:

$$PET = 1.6K \left(\frac{10T}{I} \right)^m \quad (2)$$

که در آن PET تبخیر و تعرق پتانسیل ماهانه، T دمای میانگین و
I شاخص گرمایی است که از مجموع ۱۲ مقدار شاخص ماهانه محاسبه
می‌گردد. m یک ضریب وابسته به شاخص گرمایی و K نیز یک فاکتور
تصحیح است که بر اساس ماه و عرض جغرافیایی محاسبه می‌گردد
(Vicente-Serrano et al., 2010).

بر اساس این مفهوم، شاخص SPEI در مقیاس‌های زمانی ۱، ۳،

آماره کاپای کوهن

ارزیابی میزان توافق بین دو یا چند روش سنجش، در رشته‌های مختلف رایج است (Gwet, 2008). آماره کاپا برای اندازه‌گیری توافق در مقیاس اسمی بین جفت‌روش‌های سنجش معرفی شده است (Fleiss, 1971). هنگام ارزیابی میزان توافق بین روش‌ها، آزمون‌های توافق میان دو یا چند روش باید شامل آماری باشد که امکان توافق یا عدم توافق صرفاً بر اساس شانس را در نظر بگیرد. با توجه به اینکه آماره کاپا قابلیت رفع این مسئله را دارد، به‌عنوان یکی از رایج‌ترین آماره‌ها برای این منظور گزارش شده است (Viera & Garrett, 2005). آماره کاپا را می‌توان از کاپای کوهن (Cohen, 1960) و یا کاپای فلیس (Fleiss, 1971) محاسبه کرد. کاپای کوهن برای ارزیابی میزان توافق، زمانی به کار می‌رود که یا دو روش سنجش با یک آزمون واحد وجود داشته باشد، یا یک روش سنجش با دو آزمون؛ در حالی که کاپای فلیس توسعه‌یافته کاپای کوهن برای سه ارزیاب (اندازه‌گیری) یا بیشتر است (Tefera et al., 2019). علاوه بر این، فرض حاکم بر کاپای کوهن این است که روش‌های سنجش به‌طور هدفمند انتخاب و ثابت در نظر گرفته می‌شوند، اما در کاپای فلیس، فرض بر این است که روش‌های سنجش به‌طور تصادفی از یک جمعیت بزرگ‌تر انتخاب شده‌اند. از این رو، بر اساس این مفروضات، آماره کاپای کوهن برای این مطالعه مناسب تشخیص داده شد و به‌منظور آزمون میزان توافق بین SPEI و SPEIbase به‌عنوان ابزارهای ارزیابی خشکسالی مورد استفاده قرار گرفت. اما از آنجا که آماره کاپا با داده‌های ترتیبی یا اسمی به خوبی عمل می‌کند، مقادیر پیوسته هر یک از روش‌های سنجش (یعنی SPEI و SPEIbase) به داده‌های ترتیبی (با ۸ طبقه) تبدیل شدند، همان‌طور که در (جدول ۲) نشان داده شده است. سپس داده‌های تبدیل‌شده هر روش سنجش برای محاسبه میزان توافق با استفاده از آماره کاپای کوهن به کار گرفته شد.

میزان همبستگی قوی جفت‌متغیرها با یکدیگر به کار می‌رود. دامنه ضریب همبستگی پیرسون بین مثبت یک (رابطه خطی مثبت کامل) تا منفی یک (رابطه خطی منفی کامل) متغیر است (جدول ۳). مقدار صفر نشان‌دهنده عدم وجود هرگونه رابطه خطی بین متغیرها است (Adler & Parmryd, 2010). استفاده از ضریب همبستگی پیرسون پیرسون برای توصیف میزان توافق بین متغیرها می‌تواند گمراه‌کننده باشد (Bland & Altman, 2010). از این رو، در مطالعه حاضر، ضریب همبستگی پیرسون پیرسون صرفاً برای آزمون قدرت و جهت رابطه خطی بین دو شاخص خشکسالی در هر مقیاس زمانی مورد استفاده قرار گرفته است.

عبارت ریاضی ضریب همبستگی پیرسون، که با r نشان داده می‌شود بین SPEI و SPEIbase که به‌ترتیب با متغیرهای X و Y نمایش داده شده‌اند، به‌صورت زیر است (رابطه ۳):

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (3)$$

که X_i و Y_i به‌ترتیب نشان‌دهنده داده‌های نقطه‌ای در مجموعه داده‌های مربوط به متغیرهای $X(SPEI)$ و $Y(SPEIbase)$ می‌باشند. $\bar{X}$ و $\bar{Y}$ نیز به‌ترتیب میانگین (میانگین حسابی) مجموعه داده‌های متغیرهای $X(SPEI)$ و $Y(SPEIbase)$ می‌باشند. صورت کسر نمایان‌گر کوواریانس بین SPEI و SPEIbase بوده که میزان تغییرات همزمان این دو متغیر را اندازه‌گیری می‌کند. مخرج کسر حاصل‌ضرب انحراف معیارهای SPEI و SPEIbase بوده که نشان‌دهنده پراکندگی (تغییرپذیری) هر متغیر به‌صورت جداگانه است.

ارزیابی توافق میان SPEI و SPEIbase

جدول ۳- تفسیر مقادیر ضریب همبستگی پیرسون (Schober et al., 2018)

Table 3- Interpretation of Pearson Correlation Coefficient values (Schober et al., 2018)

قدر مطلق مقدار ضریب همبستگی	سطح همبستگی
Range of absolute correlation coefficient	Strength of correlation
$0 \leq r < 0.1$	همبستگی بسیار ضعیف (بدون رابطه) Very weak correlation (No correlation)
$0.1 \leq r < 0.30$	همبستگی ضعیف Weak correlation
$0.30 \leq r < 0.50$	همبستگی متوسط Moderate correlation
$0.50 \leq r < 0.70$	همبستگی نسبتاً قوی Fairly strong correlation
$0.70 \leq r < 0.90$	همبستگی قوی Strong Correlation
$0.90 \leq r \leq 1.00$	همبستگی بسیار قوی Very Strong Correlation

وزن دار است. چنانچه تعداد طبقات (r) برابر ۲ باشد، کاپای ساده، کاپای خطی و کاپای مربعی در آن صورت هم مقدار (برابر) می شوند. مقادیر کاپا معمولاً از ۱- تا ۱+ متغیر است. مقادیر بالای کاپا نشان دهنده سطوح توافق قوی تر است. هنگامی که کاپا برابر با ۱ باشد، توافق کامل وجود دارد؛ کاپای برابر با صفر نشان می دهد که توافق به اندازه ای است که صرفاً بر اساس شانس انتظار می رود؛ و کاپای کمتر از صفر بیانگر توافقی ضعیف تر از حد مورد انتظار بر اساس شانس است؛ این حالت به ندرت رخ می دهد (جدول ۴).

نمودار بلند-آلتمن

به طور کلی درست است که هیچ دو روش متفاوتی نمی توانند دقیقاً نتیجه یکسانی ارائه دهند، به گونه ای که در هیچ نقطه ای تفاوتی در مقادیر خود نداشته باشند (Bland & Altman, 2010). از این رو، هنگام مقایسه میان روش ها، هدف آن است که دانسته شود نتایج دو روش تا چه میزان با یکدیگر تفاوت دارند. نمودار بلند-آلتمن، که از آن با عنوان نمودار اختلاف یا تفاوت نیز یاد می شود، بینشی در مورد سطح توافق میان روش ها فراهم می کند. این یک روش گرافیکی انتخابی به منظور مقایسه دو اندازه گیری بوده و در آن تفاوت بین جفت مقادیرها بر روی محور y در برابر میانگین همان جفت مقادیرها بر روی محور x نمایش داده می شود. این نمودار حدود توافق را تعیین می کند و با محاسبه میانگین و انحراف معیار تفاوت ها، میزان توافق میان دو اندازه گیری کمی را به صورت عددی بیان می کند؛ موضوعی که به درک دامنه توافق بین روش ها کمک می کند (Giavarina, 2015; Watson & Petrie, 2010).

برخلاف کاپای ساده که تمامی عدم توافقات را به یک اندازه در نظر می گیرد، کاپای وزن دار با اختصاص وزن های متفاوت به درجات مختلف عدم توافق، شدت انحراف بین طبقات را نیز در محاسبه لحاظ می کند. این ویژگی برای متغیرهای ترتیبی مانند طبقات خشکسالی که فاصله بین آن ها از نظر معنایی یکسان نیست، مناسب تر بوده و تخمین واقع بینانه تری از میزان توافق ارائه می دهد (Warrens, 2013). فرض کنید r بیانگر تعداد طبقات و $\pi_{ij} = (i, j = 1, 2, \dots, r)$ بیانگر نسبت آزمودنی های باشد که به ترتیب توسط ارزیابی اول در طبقه i و ارزیابی دوم در طبقه j طبقه بندی شده اند. کاپای کوهن غیروزی (ساده) از طریق زیر محاسبه می گردد:

$$\kappa = \frac{O - E}{1 - E} = \frac{\sum_{i=1}^r \pi_{ii} - \sum_{j=1}^r \pi_j + \pi + j}{1 - \sum_{j=1}^r \pi_j + \pi + j} \quad (4)$$

که در آن، $O = \sum_{i=1}^r \pi_{ii}$ توافق مشاهده شده نسبی بین ارزیابان و $E = \sum_{j=1}^r \pi_j + \pi + j$ احتمال فرضی توافق شانس است. فرض کنید w_{ij} یک وزن مربعی $w_{ij}^q = 1 - \frac{(i-j)^2}{(r-1)^2}$ یا یک وزن خطی $w_{ij}^l = 1 - \frac{|i-j|}{|r-1|}$ باشد، کاپای وزن دار معمولاً به صورت زیر تعریف می شود:

$$\kappa_w = \frac{O_w - E_w}{1 - E_w} = \frac{\sum_{i=1}^r \sum_{j=1}^r w_{ij} \pi_{ii} - \sum_{j=1}^r \sum_{i=1}^r w_{ij} \pi_i + \pi + j}{1 - \sum_{j=1}^r \sum_{i=1}^r w_{ij} \pi_i + \pi + j} \quad (5)$$

که در آن، $O_w = \sum_{i=1}^r \sum_{j=1}^r w_{ij} \pi_{ii}$ توافق مشاهده شده وزن دار بین ارزیابان و $E_w = \sum_{j=1}^r \sum_{i=1}^r w_{ij} \pi_i + \pi + j$ توافق مورد انتظار

جدول ۴- تفسیر مقادیر آماره کاپای کوهن وزن دار (Landis & Koch, 1977)
Table 4- Interpretation Cohen's weighted kappa (Landis & Koch, 1977)

مقادیر کاپا	سطح توافق
Kappa value	Level of agreement
$\kappa < 0$	کمتر از شانس توافق Less than chance agreement
$0 \leq \kappa < 0.20$	توافق اندک Slight agreement
$0.20 \leq \kappa < 0.40$	توافق نسبی Fair agreement
$0.40 \leq \kappa < 0.60$	توافق متوسط Moderate agreement
$0.60 \leq \kappa < 0.80$	توافق زیاد Substantial agreement
$0.80 \leq \kappa < 1.00$	توافق تقریباً کامل Near perfect agreement
1	توافق کامل Perfect agreement

نتایج و بحث

مقدار ضریب همبستگی خطی پیرسون برای ارزیابی میزان همخوانی و هماهنگی بین دو شاخص SPEI و SPEIbase از طریق برنامه‌نویسی در محیط نرم‌افزار R-Studio انجام گرفته است. این ضریب همبستگی برای هر یک از مقیاس‌های زمانی ۱، ۳، ۶، ۹ و ۱۲ ماهه انجام گرفته است. نمونه‌ای از خروجی این محاسبات در (شکل ۳) برای ایستگاه نمونه (مشهد) نمایش داده شده است. نتایج عددی این محاسبات در جدول‌های ۵ تا ۹ به تفکیک مقیاس‌های زمانی آورده شده است. مازاد بر این، بیان تصویری مقایسه سری‌های زمانی از شاخص SPEI و SPEIbase نیز مقیاس‌های زمانی متناظر، انجام شده است. نمونه‌ای از خروجی این محاسبات در (شکل ۴) برای ایستگاه نمونه (مشهد) نمایش داده شده است. ضریب کاپای کوهن وزن‌دار جهت ارزیابی میزان توافق بین وضعیت‌های خشکسالی منتج از شاخص‌های SPEI و SPEIbase نیز از طریق برنامه‌نویسی در محیط نرم‌افزار MATLAB برای هر یک از مقیاس‌های زمانی ۵ گانه انجام گرفته است. نتایج عددی این محاسبات نیز در (جدول ۵)، (جدول ۶)، (جدول ۷)، (جدول ۸) و (جدول ۹) به تفکیک مقیاس‌های زمانی آورده شده است. بیان گرافیکی تحلیل توافق نیز از طریق ترسیم نمودارهای بلند-آلتمن در در محیط نرم‌افزار MATLAB فراهم شده است. نمونه‌ای از خروجی نمودارهای تفاوت در (شکل ۵) برای ایستگاه نمونه (مشهد) نمایش داده شده است. چنانچه در این نمودارها، نقاط به‌طور تصادفی و بدون الگوی خاص در اطراف خط میانگین پراکنده باشند، نشانه‌ای از توافق توافق خوب بین شاخص‌های SPEI و SPEIbase در نمایش وضعیت خشکسالی می‌باشد. علاوه بر این، خط میانگین اختلاف‌ها (بایاس) نیز نبایستی صفر باشد. زیرا همان‌طور که قبلاً بیان شد هیچ دو روش متفاوت، نمی‌توانند دقیقاً نتیجه یکسانی ارائه دهند.

با این حال، این که چه میزان تفاوت میان روش‌ها قابل قبول بوده و به‌عنوان توافق در نظر گرفته شود، موضوعی است که به قضاوت شخصی بستگی دارد (Bland & Altman, 2010).

مراحل تولید نمودار بلند-آلتمن با جایگزینی x و y به ترتیب با SPEI و SPEIbase به شرح زیر است:

۱. محاسبه اختلاف بین دو اندازه‌گیری برای هر آزمودنی (معادله ۶).

$$d_i = X_i - Y_i \quad (6)$$

که در آن X_i و Y_i اندازه‌گیری‌های حاصل از دو روش مختلف برای موضوع i می‌باشند که SPEI و SPEIbase هستند.

۲. محاسبه میانگین هر دو اندازه‌گیری برای هر موضوع (معادله ۷):

$$\bar{M}_i = \frac{X_i + Y_i}{2} \quad (7)$$

۳. رسم اختلاف‌ها ($d_i = \text{SPEI}_i - \text{SPEIbase}_i$) روی محور y و در مقابل میانگین ($\bar{M}_i = (\text{SPEI}_i + \text{SPEIbase}_i)/2$) روی محور x .


۴. محاسبه میانگین اختلاف یا اربیی (معادله ۸):

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n d_i \quad (8)$$

۵. محاسبه انحراف معیار اختلاف‌ها (معادله ۹):


$$S_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2} \quad (9)$$

۶. محاسبه حدود توافق، این حدود معمولاً برابر با ± 1.96 برابر انحراف معیار اختلاف‌ها در نظر گرفته می‌شود. بنابراین حدود بالایی از توافق برابر $\bar{d} + (1.96 \times S_d)$ و حدود پایینی از توافق برابر $\bar{d} - (1.96 \times S_d)$ می‌باشد. سپس این محدوده‌ها به‌صورت خطوط افقی در نمودار بلند-آلتمن رسم می‌شوند.




شکل ۳- مقدار ضریب همبستگی بین SPEI و SPEIbase در مقیاس‌های زمانی مختلف در ایستگاه نمونه (مشهد)

Figure 3- The correlation coefficient value between SPEI and SPEIbase at different time scales at the sample station (Mashhad)



شکل ۴- سری زمانی شاخص‌های SPEI و SPEIbase در مقیاس‌های زمانی متناظر در ایستگاه نمونه (مشهد)

Figure 4- Time series of SPEI and SPEIbase indices at corresponding time scales at the sample station (Mashhad)



شکل ۵- نمودارهای بلند-آلتمن بین SPEI و SPEIbase در مقیاس‌های زمانی متناظر در ایستگاه نمونه (مشهد)

Figure 5- Bland-Altman plots between SPEI and SPEIbase at corresponding time scales in the sample station (Mashhad)

ارتفاع زیاد) و جلگه‌ای (کم ارتفاع) می‌باشند. میزان همبستگی خطی پیروسون بین مقادیر SPEI و SPEIbase در ایستگاه‌های در مناطق کوهستانی (به‌مانند، خوی، اردبیل و زنجان) قرار دارند در تمامی مقیاس‌های زمانی همواره در محدوده همبستگی قوی قرار دارد. در

حوضه آبریز دریای خزر به‌عنوان حوضه آبریز شماره (۱) از تقسیمات حوضه‌های آبریز ایران، در نوار شمالی ایران و پُربارش‌ترین حوضه آبریز می‌باشد که نقش کلیدی در تأمین منابع آبی آن دارد. ایستگاه‌های واقع در این حوضه آبریز ترکیبی از موقعیت کوهستانی

(به‌عنوان مثال، ۱ ماهه) بیانگر خشکسالی هواشناسی، مقیاس‌های میانی (به‌عنوان مثال، ۶ ماهه) بیانگر خشکسالی کشاورزی و مقیاس‌های بلندتر (به‌عنوان مثال، ۱۲ ماهه) بیانگر خشکسالی هیدرولوژیکی می‌باشند.

مقابل، میزان همبستگی در بین ایستگاه‌های که در سواحل دریای خزر و در مناطق جلگه‌ای کم‌ارتفاع (به‌مانند، انزلی، رشت، رامسر، بابلسر و گرگان) قرار دارند اندکی کاهش یافته؛ ولیکن همواره بین دامنه همبستگی نسبتاً قوی و قوی در نوسان می‌باشد. میزان همبستگی بین شاخص‌های SPEI و SPEIbase در مقیاس‌های زمانی بلندتر نسبت به مقیاس‌های زمانی کوتاه‌تر افزایش می‌یابد. مقیاس‌های زمانی کوتاه

جدول ۵- خلاصه آزمون‌های هماهنگی و توافق بین SPEI و SPEIbase یک ماهه در حوضه‌های آبریز ایران
Table 5- Summary of correlation and agreement tests between SPEI and SPEIbase at the 1-month scale over Iranian catchments

Station ایستگاه	Catchment No. شماره حوضه	Kappa (κ^*) ضریب کاپا	Perarson (r^{**}) ضریب پیرسون	Bland-Altman (Range) دامنه بلند- آلتمن
Khoy	1	0.64	0.76	Upper= +1.51 , Lower= -1.21
Ardabil		0.58	0.71	Upper= +1.60 , Lower= -1.30
Zanjan		0.57	0.75	Upper= +1.55 , Lower= -1.19
Anzali		0.57	0.70	Upper= +1.56 , Lower= -1.38
Rasht		0.63	0.77	Upper= +1.42 , Lower= -1.25
Ramsar		0.53	0.63	Upper= +1.79 , Lower= -1.53
Babolsar		0.52	0.67	Upper= +1.79 , Lower= -1.40
Gorgan		0.52	0.66	Upper= +1.76 , Lower= -1.50
Bojnurd	2	0.54	0.67	Upper= +1.71 , Lower= -1.09
Sanandaj		0.56	0.76	Upper= +1.91 , Lower= -1.04
Kermanshah		0.61	0.78	Upper= +1.87 , Lower= -0.92
Khoramabad		0.56	0.76	Upper= +1.82 , Lower= -1.01
Dezful		0.47	0.60	Upper= +2.25 , Lower= -1.35
Ahvaz		0.56	0.72	Upper= +1.99 , Lower= -1.07
Sahrkourd		0.53	0.36	Upper= +2.02 , Lower= -1.34
Abadan		0.55	0.71	Upper= +2.01 , Lower= -1.07
Boshehr		0.54	0.60	Upper= +2.93 , Lower= -2.01
Shiraz		0.50	0.67	Upper= +2.02 , Lower= -1.25
Bandar lengheh		0.42	0.61	Upper= +2.37 , Lower= -1.13
Bandar Abbas		0.34	0.59	Upper= +2.49 , Lower= -1.21
Bandar Chabahar	3	0.44	0.63	Upper= +2.21 , Lower= -1.39
Tabriz		0.69	0.79	Upper= +1.55 , Lower= -1.08
Urmia		0.67	0.79	Upper= +1.59 , Lower= -1.08
Saqez	4	0.59	0.71	Upper= +1.79 , Lower= -1.12
Semnan		0.62	0.76	Upper= +1.65 , Lower= -1.08
Shahrud		0.58	0.69	Upper= +1.75 , Lower= -1.41
Sabzvar		0.62	0.68	Upper= +1.71 , Lower= -1.44
Torbat Heydarieh		0.63	0.75	Upper= +1.56 , Lower= -1.33
Tabas		0.56	0.74	Upper= +1.99 , Lower= -1.08
Birjand		0.52	0.72	Upper= +1.85 , Lower= -1.30
Bam		0.51	0.67	Upper= +2.17 , Lower= -1.17
Iranshahr		0.54	0.71	Upper= +1.94 , Lower= -1.26
Kerman		0.55	0.75	Upper= +2.05 , Lower= -1.00
Yazd		0.53	0.70	Upper= +2.04 , Lower= -1.07
Isfahan		0.55	0.72	Upper= +1.91 , Lower= -1.10
Hamedan		0.65	0.81	Upper= +1.51 , Lower= -0.95
Qazvin		0.64	0.77	Upper= +1.50 , Lower= -1.15
Tehran		0.64	0.76	Upper= +1.62 , Lower= -1.20
Arak		0.50	0.63	Upper= +1.99 , Lower= -1.42
Zabol	5	0.58	0.74	Upper= +1.78 , Lower= -1.13
Zahedan		0.55	0.67	Upper= +2.00 , Lower= -1.40
Saravan		0.54	0.71	Upper= +1.97 , Lower= -1.31
Mashhad	6	0.67	0.79	Upper= +1.45 , Lower= -1.17

مقیاس‌های زمانی کوتاه (۱ و ۳ ماهه) در دامنه همبستگی نسبتاً قوی و در مقیاس‌های زمانی بلندتر (۶، ۹ و ۱۲ ماهه) در دامنه همبستگی قوی قرار دارد. بنابراین، میزان همبستگی بین مقادیر SPEI و SPEIbase در ایستگاه‌های کم‌ارتفاع، عرض جغرافیایی پایین و موقعیت‌های جلگه‌ای و همچنین ایستگاه‌های بسیار مرتفع در مقیاس‌های زمانی کوتاه (خشکسالی هواشناسی و کشاورزی) چندان قوی نمی‌باشد.

نتایج آماره کاپای کوهن وزن‌دار نیز توافقی‌های متفاوت را در بیان وضعیت خشکسالی در حوضه آبریز خلیج فارس و دریای عمان نشان می‌دهد. مقادیر آماره کاپای کوهن در مقیاس‌های زمانی در دامنه متفاوت از توافق نوسان دارد. مقدار آماره کاپای کوهن در ایستگاه‌های اقلیم کوهستانی در دامنه توافق زیاد و در ایستگاه‌های اقلیم جلگه‌ای گرم در دامنه توافق متوسط قرار دارد. در ایستگاه‌های سندج، کرمانشاه و خرم‌آباد توافق در مقیاس‌های زمانی کوتاه (۱ ماهه) در محدوده متوسط و در مقیاس‌های زمانی بلندتر (۳، ۶، ۹ و ۱۲ ماهه) در محدوده توافق زیاد قرار دارد. وضعیت توافق بین SPEI و SPEIbase در ایستگاه‌های دزفول و اهواز در نمایش وضعیت خشکسالی هرچند در دامنه توافق متوسط قرار دارد، اما به شدت نزدیک به دامنه توافق زیاد می‌باشد. طبق نتایج نمودارهای بلند-آلتمن (محدوده بالا و پایین یعنی محدوده‌ای که انتظار می‌رود ۹۵٪ از تفاوت‌های بین مقادیر SPEI و SPEIbase در آن محدوده قرار بگیرند) نیز برای بررسی اعتبار و قابلیت اعتماد به شاخص‌های SPEI و SPEIbase نیز در **جدول ۵** تا ۹ آورده شده است. قدر مطلق دامنه بالا (اعداد مثبت) بزرگتر از مقادیر دامنه پایین می‌باشد که به معنی آن است که انحرافات مثبت بزرگ‌تر و گسترده‌تر از انحرافات منفی می‌باشد. این وضعیت در سایر حوضه‌های آبریز نیز مشهود بود. به این مفهوم که SPEIbase وضعیت‌های خفیف، متوسط و شدید خشکسالی بیان شده در شاخص SPEI را با وضعیت‌های متوسط، شدید و خیلی‌شدید بیان می‌کند.

حوضه آبریز دریاچه ارومیه به‌عنوان حوضه آبریز شماره (۳) از تقسیمات حوضه‌های آبریز ایران، در شمال‌غرب ایران و یک حوضه آبریز بسته می‌باشد. ایستگاه‌های این حوضه آبریز (تبریز، ارومیه و سقز) در موقعیت کوهستانی (ارتفاع بالای ۱۰۰۰ متر) و عرض جغرافیایی بالا قرار دارند. مقادیر ضریب همبستگی بین شاخص‌های SPEI و SPEIbase در هر سه ایستگاه هواشناسی و همچنین مقیاس‌های زمانی ۵ گانه (۱، ۳، ۶، ۹ و ۱۲ ماهه) در محدوده همبستگی قوی قرار دارند. به‌عنوان نمونه، این مقادیر برای ایستگاه ارومیه، در مقیاس‌های ۱، ۳، ۶، ۹ و ۱۲ ماهه به‌ترتیب ۰/۷۹، ۰/۸۴، ۰/۸۵، ۰/۸۵ و ۰/۸۶ می‌باشد (**جدول ۵** تا ۹). به مانند سایر حوضه‌های آبریز، میزان همبستگی در مقیاس‌های زمانی بلندتر نسبت به مقیاس‌های زمانی کوتاه‌تر افزایش می‌یابد.

مقادیر آماره کاپای کوهن وزن‌دار در راستای ارزیابی توافق بیان وضعیت خشکسالی بین SPEI و SPEIbase در مقیاس‌های زمانی در دامنه متفاوت از توافق نوسان دارد. به طور کلی، مقدار آماره کاپای کوهن در ایستگاه‌های اقلیم کوهستانی در دامنه توافق زیاد و در ایستگاه‌های اقلیم جلگه‌ای معتدل در دامنه توافق متوسط قرار دارد. این نتایج کمی توسط نمودارهای تفاوت (نشان داده نشده) نیز تقویت و تأیید می‌گردد. زیرا در همه نمودارها، نقاط به طور تصادفی و بدون الگوی خاص در اطراف خط میانگین پراکنده بوده و نشانه‌ای از توافق خوب بین دو شاخص در بیان وضعیت خشکسالی می‌باشند. خط میانگین اختلاف‌ها (بایاس) نیز صفر نبوده و نشان می‌دهد که یکی از روش‌ها به‌طور نظام‌مند بیشتر یا کمتر اندازه‌گیری می‌کند. بنابراین یک خطای نظام‌مند هرچند جزئی بین این روش اندازه‌گیری خشکسالی وجود دارد. محدوده توافق بین دو روش در تمامی مقیاس‌های اندازه‌گیری اختلاف چندان ناداشته و باریک می‌باشند؛ بنابراین اختلاف چندان بین شاخص شاخص SPEI و SPEIbase در نمایش خشکسالی وجود ندارد.

حوضه آبریز حوضه آبریز خلیج فارس و دریای عمان به‌عنوان حوضه آبریز شماره (۲) از تقسیمات حوضه‌های آبریز ایران، در نوار جنوبی ایران کشیده‌ترین حوضه آبریز ایران می‌باشد. بالاترین تفاوت ارتفاعی و عرض جغرافیایی و تنوع اقلیمی را در بین سایر حوضه‌های آبریز دارا می‌باشند. ایستگاه‌های واقع در این حوضه آبریز نیز ترکیبی از موقعیت کوهستانی (ارتفاع زیاد) و جلگه‌ای (کم ارتفاع) می‌باشند. میزان همبستگی خطی پیرسون بین مقادیر SPEI و SPEIbase در ایستگاه‌های غربی حوضه با عرض جغرافیایی بالاتر (به مانند، سندج، کرمانشاه و خرم‌آباد)، همواره در تمامی مقیاس‌های زمانی در دامنه همبستگی قوی قرار دارند. این میزان از همبستگی با افزایش مقیاس زمانی، بیشتر نیز می‌گردد؛ به گونه‌ای که این میزان همبستگی در ایستگاه خرم‌آباد در مقیاس زمانی ۱۲ ماهه در محدود همبستگی بسیار قوی قرار دارد. میزان همبستگی در مقیاس‌های زمانی کوتاه (۱ و ۳ ماهه) در ایستگاه هواشناسی شهرکرد که مرتفع‌ترین ایستگاه هواشناسی حوضه محسوب می‌گردد در دامنه همبستگی متوسط و در مقیاس‌های زمانی بلندتر (۶، ۹ و ۱۲ ماهه) در دامنه همبستگی قوی قرار داد. دلیل اُفت میزان همبستگی در ایستگاه هواشناسی شهرکرد (به‌ویژه در مقیاس‌های زمانی کوتاه) می‌تواند تابعی از ارتفاع زیاد و اقلیم برفی (Raziei, 2017) متأثر از آن باشد. میزان همبستگی بین مقادیر SPEI و SPEIbase در ایستگاه هواشناسی شیراز که از لحاظ عرض جغرافیایی در میانه حوضه آبریز قرار دارد، تقریباً در تمامی مقیاس‌های زمانی در دامنه همبستگی قوی قرار دارد. میزان همبستگی بین مقادیر SPEI و SPEIbase در ایستگاه‌های کم‌ارتفاع، عرض جغرافیایی پایین و موقعیت‌های جلگه‌ای (به مانند آبادان، بوشهر، بندر لنگه، بندر عباس و بندر چابهار) متفاوت می‌باشد. به گونه‌ای که میزان همبستگی در در

نیز بین وضعیت‌های خشکسالی در آماره کاپای کوهن وزن دار مشاهده می‌گردد. زیرا، مقادیر آماره کاپای کوهن در تمامی مقیاس‌های زمانی در دامنه $+0/6$ تا $+0/80$ بوده که بیان گر توافق زیاد می‌باشد. محدوده باریک توافق در تمامی مقیاس‌های زمانی طبق نمودارهای اختلاف نیز بررسی شده است.

مقدار آماره کاپای کوهن وزن دار به همراه خلاصه نمودارهای تفاوت، برای ارزیابی توافق در بیان وضعیت خشکسالی بین SPEI و SPEIbase در حوضه آبریز دریاچه ارومیه در مقیاس‌های زمانی متفاوت در جدول‌های ۵ تا ۹ آورده شده است. مشابه توافق قوی بین SPEI و SPEIbase در آزمون‌های همبستگی خطی پیرسون، یک توافق زیاد

جدول ۶- خلاصه آزمون‌های هماهنگی و توافق بین SPEI و SPEIbase سه‌ماهه در حوضه‌های آبریز ایران

Table 6- Summary of correlation and agreement tests between SPEI and SPEIbase at the 3-month scale over Iranian catchments

Station ایستگاه	Catchment No. شماره حوضه	Kappa (κ^*) ضریب کاپا	Perarson (r^{**}) ضریب پیرسون	Bland-Altman (Range) دامنه بلند-آلتمن
Khoy	1	0.69	0.80	Upper= +1.48 , Lower= -1.08
Ardabil		0.62	0.71	Upper= +1.67 , Lower= -1.22
Zanjan		0.66	0.81	Upper= +1.47 , Lower= -1.00
Anzali		0.58	0.69	Upper= +1.65 , Lower= -1.38
Rasht		0.67	0.75	Upper= +1.54 , Lower= -1.29
Ramsar		0.44	0.56	Upper= +2.00 , Lower= -1.66
Babolsar		0.53	0.65	Upper= +1.91 , Lower= -1.40
Gorgan		0.53	0.67	Upper= +1.78 , Lower= -1.39
Bojnurd	2	0.52	0.71	Upper= +1.73 , Lower= -1.28
Sanandaj		0.61	0.81	Upper= +1.81 , Lower= -0.84
Kermanshah		0.62	0.84	Upper= +1.71 , Lower= -0.64
Khoramabad		0.63	0.82	Upper= +1.70 , Lower= -0.79
Dezful		0.46	0.60	Upper= +2.32 , Lower= -1.31
Ahvaz		0.56	0.73	Upper= +2.03 , Lower= -1.01
Sahrkourd		0.57	0.42	Upper= +1.92 , Lower= -1.18
Abadan		0.54	0.69	Upper= +2.15 , Lower= -1.10
Boshehr		0.55	0.65	Upper= +3.03 , Lower= -2.06
Shiraz		0.55	0.70	Upper= +1.95 , Lower= -1.17
Bandar lengeh		0.49	0.69	Upper= +2.25 , Lower= -0.87
Bandar Abbas		0.41	0.64	Upper= +2.43 , Lower= -0.97
Bandar Chabahar	3	0.47	0.67	Upper= +2.17 , Lower= -1.15
Tabriz		0.72	0.82	Upper= +1.55 , Lower= -0.93
Urmia		0.62	0.84	Upper= +1.55 , Lower= -0.89
Sagez	4	0.64	0.71	Upper= +1.81 , Lower= -1.01
Semnan		0.64	0.78	Upper= +1.69 , Lower= -0.94
Shahrud		0.62	0.72	Upper= +1.75 , Lower= -1.24
Sabzvar		0.65	0.72	Upper= +1.67 , Lower= -1.29
Torbat Heydari		0.68	0.79	Upper= +1.47 , Lower= -1.17
Tabas		0.53	0.72	Upper= +2.09 , Lower= -1.00
Birjand		0.60	0.77	Upper= +1.77 , Lower= -1.06
Bam		0.45	0.65	Upper= +2.32 , Lower= -1.05
Iranshahr		0.51	0.71	Upper= +2.08 , Lower= -1.21
Kerman		0.56	0.76	Upper= +2.10 , Lower= -0.89
Yazd		0.50	0.71	Upper= +2.11 , Lower= -0.94
Isfahan		0.46	0.70	Upper= +2.01 , Lower= -1.09
Hamedan		0.66	0.84	Upper= +1.47 , Lower= -0.78
Qazvin		0.68	0.82	Upper= +1.44 , Lower= -0.99
Tehran		0.66	0.79	Upper= +1.61 , Lower= -0.99
Arak		0.53	0.64	Upper= +2.01 , Lower= -1.33
Zabol	5	0.54	0.76	Upper= +1.88 , Lower= -0.99
Zahedan		0.63	0.71	Upper= +2.02 , Lower= -1.20
Saravan		0.54	0.71	Upper= +1.95 , Lower= -1.38
Mashhad	6	0.74	0.82	Upper= +1.39 , Lower= -1.03

۵۰ میلی‌متر از جمله کم‌بارش‌ترین نقاط ایران می‌باشد و به شدت به منابع آب فرامرزی وابسته است. میزان همبستگی بین مقادیر شاخص‌های SPEI و SPEIbase در ایستگاه زابل به ترتیب، ۰/۷۴، ۰/۷۶، ۰/۸۱، ۰/۸۳ و ۰/۸۴ می‌باشد. این مقادیر برای ایستگاه هواشناسی زاهدان به ترتیب ۰/۶۷، ۰/۷۱، ۰/۷۷، ۰/۸۳ و ۰/۸۵ و برای ایستگاه هواشناسی سراوان به ترتیب ۰/۷۱، ۰/۷۱، ۰/۷۵، ۰/۸۰ و ۰/۸۳ می‌باشد. این ضرایب همبستگی در هر سه ایستگاه هواشناسی و همچنین مقیاس‌های زمانی ۵ گانه (۱، ۳، ۶، ۹ و ۱۲ ماهه) در محدوده همبستگی قوی قرار دارند. میزان همبستگی بین شاخص‌های SPEI و SPEIbase در مقیاس‌های زمانی بلندتر نسبت به مقیاس‌های زمانی کوتاه‌تر افزایش می‌یابد. مشابه توافق قوی بین SPEI و SPEIbase در آزمون همبستگی خطی پیرسون، یک توافق زیاد نیز بین وضعیت‌های خشکسالی در آماره کاپای کوهن وزن‌دار مشاهده می‌گردد. زیرا، مقادیر آماره کاپای کوهن وزن‌دار در تمامی مقیاس‌های زمانی در دامنه ۰/۶+ تا ۰/۸۰+ بوده که بیان‌گر توافق زیاد می‌باشد. مقدار آماره کاپای کوهن در مقیاس‌های زمانی کوچکتر (مانند ۱ و ۳) که عمدتاً بیانگر خشکسالی هواشناسی می‌باشند در محدوده مرز توافق زیاد می‌باشد. بنابراین در حوضه آبریز مرزی شرق توافق شاخص‌های SPEI و SPEIbase در نمایش وضعیت خشکسالی‌ها (بوژه خشکسالی‌های کشاورزی و هیدرولوژیکی) زیاد می‌باشد. نمودارهای تفاوت نیز بیانگر سطح بالایی از همخوانی بین شاخص‌های SPEI و SPEIbase در حوضه آبریز مرزی شرق در تمامی مقیاس‌های مورد بررسی بوده است. بنابراین، این نمودارها این نتیجه را تقویت می‌کنند که هر دو شاخص، ارزیابی‌های قابل مقایسه‌ای از خشکسالی در حوضه آبریز مرزی شرق ارائه می‌دهند.

حوضه آبریز قره‌قوم به عنوان حوضه آبریز شماره (۶) از تقسیمات حوضه‌های آبریز ایران، کوچک‌ترین حوضه آبریز ایران و یک حوضه فرامرزی در شمال شرق می‌باشد. ایستگاه هواشناسی مشهد، نماینده این حوضه آبریز می‌باشد. میزان همبستگی بین مقادیر شاخص‌های SPEI و SPEIbase در مقیاس‌های ۱، ۳، ۶، ۹ و ۱۲ ماهه به ترتیب، ۰/۷۹، ۰/۸۲، ۰/۸۵، ۰/۸۷ و ۰/۸۶ می‌باشد. این ضرایب همبستگی در محدوده همبستگی قوی قرار داشته و میزان آن از مقیاس‌های زمانی کوتاه (۱ و ۳ ماهه) به مقیاس‌های زمانی طولانی‌تر (۶، ۹ و ۱۲ ماهه) افزایش می‌یابد. مقدار آماره کاپای کوهن وزن‌دار به همراه خلاصه نمودار تفاوت، برای بیان توافق بین وضعیت خشکسالی بین SPEI و SPEIbase در حوضه آبریز قره‌قوم در مقیاس‌های زمانی متفاوت در جدول‌های ۵ تا ۹ آورده شده است.

این نمودارها بیانگر سطح بالایی از همخوانی بین شاخص‌های SPEI و SPEIbase در حوضه آبریز دریاچه ارومیه در تمامی مقیاس‌های مورد بررسی بوده است. بنابراین، نمودارهای بلند-آلتن این نتیجه را تقویت می‌کنند که هر دو شاخص ارزیابی‌های قابل مقایسه‌ای از خشکسالی در حوضه آبریز دریاچه ارومیه ارائه می‌دهند. در همه نمودارها، نقاط به‌طور تصادفی و بدون الگوی خاصی در اطراف خط میانگین پراکنده بوده؛ بنابراین اختلاف چندانی بین شاخص شاخص SPEI و SPEIbase در بیان وضعیت خشکسالی وجود ندارد.

حوضه آبریز فلات مرکزی ایران به‌عنوان حوضه آبریز شماره (۴) از تقسیمات حوضه‌های آبریز ایران، بزرگ‌ترین حوضه آبریز ایران و بیش از نیمی از مساحت کشور را شامل می‌شود. این حوضه آبریز، کم‌بارش‌ترین، گرم‌ترین و تنها حوضه آبریز کاملاً محصور ایران می‌باشد. میزان همبستگی بین مقادیر شاخص‌های SPEI و SPEIbase در اغلب ایستگاه‌های هواشناسی این حوضه آبریز در دامنه همبستگی قوی دارد. علاوه بر آن، میزان همبستگی از مقیاس‌های زمانی کوتاه (۱ و ۳) به مقیاس‌های زمانی طولانی‌تر (۶، ۹ و ۱۲) نیز افزایش می‌یابد. میزان همبستگی بین مقادیر شاخص‌های SPEI و SPEIbase در ایستگاه هواشناسی بم در مرکز فلات مرکزی ایران، در دامنه همبستگی نسبتاً قوی قرار داشته و میزان آن از مقیاس‌های زمانی کوتاه (۱ و ۳ ماهه) به مقیاس‌های زمانی طولانی‌تر (۶، ۹ و ۱۲ ماهه) بر خلاف سایر ایستگاه‌ها، کاهش می‌یابد. ایستگاه بم با میانگین بارش حدود ۵۰ میلی‌متر از جمله کم‌بارش‌ترین نقاط ایران می‌باشد. شرایط مشابه، در ایستگاه هواشناسی اصفهان نیز با درجه شدت پایین‌تر، نمود دارد. توافق در بیان وضعیت خشکسالی توسط شاخص‌های SPEI و SPEIbase در تمامی ایستگاه‌های حوضه آبریز فلات مرکزی ایران نیز در تمامی مقیاس‌های زمانی توسط آزمون کاپای کوهن وزن‌دار و نمودار بلند-آلتن بررسی و خلاصه نتایج آن در جدول‌های ۵ تا ۹ آورده شده است. نتایج آماره کاپای کوهن نیز توافق‌های متفاوت را در بین نمایش وضعیت خشکسالی در حوضه آبریز فلات مرکزی ایران نشان می‌دهد. مقادیر آماره کاپای کوهن در مقیاس‌های زمانی در دامنه متفاوت از توافق نوسان دارد. مقدار آماره کاپای کوهن در ایستگاه‌های بم، طبس، ایرانشهر، کرمان، یزد، اصفهان و اراک در دامنه توافق متوسط و در سایر ایستگاه‌ها، در دامنه توافق زیاد قرار دارد.

حوضه آبریز مرزی شرق ایران به‌عنوان حوضه آبریز شماره (۵) از تقسیمات حوضه‌های آبریز ایران، یک حوضه فرامرزی در نوار شرقی ایران یکی از حوضه‌های آبریز بسته و خشک شناخته می‌شود. ایستگاه‌های هواشناسی زابل، زاهدان و سراوان در درون این حوضه آبریز قرار دارند. ایستگاه زابل در موقعیت دشتی با میانگین بارش حدود

جدول ۷- خلاصه آزمون‌های هماهنگی و توافق بین SPEI و SPEIbase شش‌ماهه در حوضه‌های آبریز ایران

Table 7- Summary of correlation and agreement tests between SPEI and SPEIbase at the 6-month scale over Iranian catchments

Station ایستگاه	Catchment No. شماره حوضه	Kappa (κ^*) ضریب کاپا	Perarson (r^{**}) ضریب پیرسون	Bland-Altman (Range) دامنه بلند-آلتمن
Khoy	1	0.69	0.84	Upper= +1.41 , Lower= -0.92
Ardabil		0.57	0.70	Upper= +1.72 , Lower= -1.18
Zanjan		0.65	0.81	Upper= +1.50 , Lower= -0.92
Anzali		0.53	0.65	Upper= +1.74 , Lower= -1.45
Rasht		0.67	0.72	Upper= +1.63 , Lower= -1.34
Ramsar		0.36	0.50	Upper= +2.18 , Lower= -1.78
Babolsar		0.59	0.66	Upper= +1.92 , Lower= -1.36
Gorgan		0.59	0.71	Upper= +1.74 , Lower= -1.27
Bojnurd	2	0.56	0.73	Upper= +1.75 , Lower= -1.17
Sanandaj		0.64	0.82	Upper= +1.79 , Lower= -0.71
Kermanshah		0.68	0.88	Upper= +1.57 , Lower= -0.44
Khoramabad		0.68	0.86	Upper= +1.56 , Lower= -0.61
Dezful		0.47	0.65	Upper= +2.20 , Lower= -1.14
Ahvaz		0.57	0.73	Upper= +2.03 , Lower= -0.97
Sahrkourd		0.69	0.78	Upper= +1.74 , Lower= -0.96
Abadan		0.53	0.68	Upper= +2.18 , Lower= -1.08
Boshehr	3	0.57	0.72	Upper= +3.01 , Lower= -2.06
Shiraz		0.66	0.80	Upper= +1.64 , Lower= -0.90
Bandar lengheh		0.50	0.73	Upper= +2.18 , Lower= -0.72
Bandar Abbas		0.44	0.69	Upper= +2.34 , Lower= -0.79
Bandar Chabahar		0.50	0.74	Upper= +2.06 , Lower= -0.93
Tabriz		0.73	0.84	Upper= +1.55 , Lower= -0.76
Urmia		0.68	0.85	Upper= +1.57 , Lower= -0.76
Sagez		0.69	0.80	Upper= +1.85 , Lower= -0.68
Semnan	4	0.62	0.83	Upper= +1.62 , Lower= -0.72
Shahrud		0.66	0.80	Upper= +1.61 , Lower= -0.97
Sabzvar		0.64	0.78	Upper= +1.61 , Lower= -1.12
Torbat Heydariyeh		0.74	0.83	Upper= +1.43 , Lower= -1.06
Tabas		0.51	0.76	Upper= +2.04 , Lower= -0.76
Birjand		0.65	0.85	Upper= +1.63 , Lower= -0.80
Bam		0.43	0.63	Upper= +2.44 , Lower= -1.03
Iranshahr		0.49	0.72	Upper= +2.11 , Lower= -1.11
Kerman	5	0.59	0.80	Upper= +2.08 , Lower= -0.68
Yazd		0.52	0.72	Upper= +2.13 , Lower= -0.77
Isfahan		0.51	0.70	Upper= +2.04 , Lower= -1.01
Hamedan		0.70	0.86	Upper= +1.45 , Lower= -0.66
Qazvin		0.72	0.83	Upper= +1.43 , Lower= -0.91
Tehran		0.66	0.79	Upper= +1.62 , Lower= -0.99
Arak		0.53	0.61	Upper= +2.08 , Lower= -1.32
Zabol		0.62	0.81	Upper= +1.82 , Lower= -0.77
Zahedan	6	0.68	0.77	Upper= +1.96 , Lower= -0.98
Saravan		0.55	0.75	Upper= +1.91 , Lower= +1.28
Mashhad		0.77	0.85	Upper= +1.35 , Lower= -0.92

ایستگاهی می‌باشد، روش برآورد تبخیر و تعرق پتانسیل مبتنی بر معادله تورنتویت می‌باشد؛ در حالی که در روش SPEIbase روش برآورد تبخیر و تعرق پتانسیل مبتنی بر معادله پنمن-مانتیت FAO-56 می‌باشد. روش پنمن-مانتیت به‌عنوان روشی دقیق‌تر و پیشرفته‌تر شناخته می‌شود. برآورد تبخیر و تعرق بر اساس روش پنمن-مانتیت FAO-56 نیازمند داده‌های هواشناسی کامل‌تر شامل میانگین دما، حداقل دما، حداکثر دما، رطوبت نسبی، بارندگی، سرعت باد و ساعات

مشابه توافق قوی بین SPEI و SPEIbase در آزمون همبستگی خطی پیرسون، یک توافق زیاد بین وضعیت‌های خشکسالی در آماره کاپای کوهن وزن دار مشاهده می‌گردد. زیرا، مقادیر آماره کاپای کوهن وزن دار در تمامی مقیاس‌های زمانی در دامنه $+0.6$ تا $+0.8$ بوده که بیان‌گر توافق زیاد می‌باشد. با وجود اختلاف ماهیت این روش‌ها در نوع برآورد تبخیر و تعرق، یک توافق زیاد بین آن‌ها در نمایش وضعیت خشکسالی وجود دارد. در روش محاسبه SPEI که مبتنی بر داده‌های

مختلف جهت ارزیابی ارتباط تغییر مقیاس‌های زمانی و تغییرات ضرایب همبستگی و توافق ترسیم شده است. همان‌گونه که مشخص است، با افزایش مقیاس زمانی (از ۱ ماهه به ۱۲ ماهه) ضریب همبستگی و کاپا در هر ویلون به طور واضح افزایش می‌یابد. این موضوع تأیید می‌کند که هماهنگی و توافق بین دو شاخص در بازه‌های زمانی بلندمدت بیشتر است.

آفتابی می‌باشد. بنابراین SPEI و SPEIbase شباهت‌های زیاد در پایش خشکسالی و توافق زیاد در بیان وضعیت خشکسالی دارند. به‌عنوان مثال یک رویداد خشکسالی شدید در شاخص SPEI در شاخص SPEIbase نیز به احتمال زیاد به‌عنوان رویداد خشکسالی خیلی شدید شناخته می‌شود.

نمودارهای ویلونی از ضرایب همبستگی پیرسون و ضرایب کاپای کوهن وزن‌دار (شکل ۶) بین SPEI و SPEIbase در مقیاس‌های زمانی

جدول ۸- خلاصه آزمون‌های هماهنگی و توافق بین SPEI و SPEIbase ۹ ماهه در حوضه‌های آبریز ایران

Table 8- Summary of correlation and agreement tests between SPEI and SPEIbase at the 9-month scale over Iranian catchments

Station ایستگاه	Catchment No. شماره حوضه	Kappa (κ^*) ضریب کاپا	Perarson (r^{**}) ضریب پیرسون	Bland-Altman (Range) دامنه بلند-آلتمن
Khoy	1	0.69	0.85	Upper= +1.45 , Lower= -0.84
Ardabil		0.56	0.69	Upper= +1.80 , Lower= -1.13
Zanjan		0.60	0.81	Upper= +1.57 , Lower= -0.87
Anzali		0.53	0.64	Upper= +1.76 , Lower= -1.45
Rasht		0.66	0.69	Upper= +1.74 , Lower= -1.40
Ramsar		0.32	0.44	Upper= +2.33 , Lower= -1.86
Babolsar		0.60	0.69	Upper= +1.86 , Lower= -1.25
Gorgan		0.60	0.74	Upper= +1.72 , Lower= -1.16
Bojnurd	2	0.59	0.74	Upper= +1.79 , Lower= -1.10
Sanandaj		0.62	0.84	Upper= +1.77 , Lower= -0.52
Kermanshah		0.67	0.89	Upper= +1.58 , Lower= -0.25
Khoramabad		0.70	0.90	Upper= +1.46 , Lower= -0.35
Dezful		0.55	0.72	Upper= +2.03 , Lower= -0.87
Ahvaz		0.55	0.74	Upper= +2.01 , Lower= -0.87
Sahrkourd		0.70	0.77	Upper= +1.81 , Lower= -0.90
Abadan		0.56	0.68	Upper= +2.19 , Lower= -1.00
Boshehr		0.62	0.78	Upper= +3.00 , Lower= -2.06
Shiraz		0.69	0.86	Upper= +1.48 , Lower= -0.73
Bandar lengeh		0.49	0.76	Upper= +2.15 , Lower= -0.63
Bandar Abbas		0.44	0.74	Upper= +2.27 , Lower= -0.71
Bandar Chabahar	3	0.59	0.78	Upper= +1.97 , Lower= -0.76
Tabriz		0.70	0.84	Upper= +1.60 , Lower= -0.67
Urmia		0.70	0.85	Upper= +1.66 , Lower= -0.66
Saqez	4	0.70	0.85	Upper= +1.66 , Lower= -0.66
Semnan		0.62	0.85	Upper= +1.59 , Lower= -0.57
Shahrud		0.69	0.85	Upper= +1.49 , Lower= -0.75
Sabzvar		0.64	0.79	Upper= +1.64 , Lower= -1.08
Torbat Heydarieh		0.73	0.85	Upper= +1.43 , Lower= -1.00
Tabas		0.54	0.76	Upper= +2.09 , Lower= -0.67
Birjand		0.67	0.88	Upper= +1.56 , Lower= -0.67
Bam		0.39	0.61	Upper= +2.51 , Lower= -1.04
Iranshahr		0.48	0.76	Upper= +2.04 , Lower= -0.93
Kerman		0.59	0.81	Upper= +2.10 , Lower= -0.61
Yazd		0.51	0.72	Upper= +2.18 , Lower= -0.65
Isfahan		0.52	0.69	Upper= +2.12 , Lower= -0.93
Hamedan		0.65	0.86	Upper= +1.51 , Lower= -0.55
Qazvin		0.67	0.84	Upper= +1.44 , Lower= -0.82
Tehran		0.62	0.80	Upper= +1.62 , Lower= -0.89
Arak		0.51	0.63	Upper= +2.09 , Lower= -1.17
Zabol	5	0.60	0.83	Upper= +1.83 , Lower= -0.72
Zahedan		0.69	0.83	Upper= +1.84 , Lower= -0.75
Saravan		0.60	0.80	Upper= +1.81 , Lower= -1.13
Mashhad	6	0.80	0.87	Upper= +1.34 , Lower= -0.83


جدول ۹- خلاصه آزمون‌های هماهنگی و توافق بین SPEI و SPEIbase دوازده‌ماهه در حوضه‌های آبریز ایران

Table 9- Summary of correlation and agreement tests between SPEI and SPEIbase at the 12-month scale over Iranian catchments

Station ایستگاه	Catchment No. شماره حوضه	Kappa (κ^*) ضریب کاپا	Perarson (r^{**}) ضریب پیرسون	Bland-Altman (Range) دامنه بلند-آلتمن
Khoy	1	0.69	0.85	Upper= +1.47 , Lower= -0.77
Ardabil		0.57	0.69	Upper= +1.85 , Lower= -1.06
Zanjan		0.51	0.80	Upper= +1.66 , Lower= -0.85
Anzali		0.56	0.63	Upper= +1.78 , Lower= -1.46
Rasht		0.62	0.70	Upper= +1.74 , Lower= -1.37
Ramsar		0.25	0.40	Upper= +2.44 , Lower= -1.92
Babolsar		0.62	0.71	Upper= +1.83 , Lower= -1.17
Gorgan		0.62	0.75	Upper= +1.71 , Lower= -1.09
Bojnurd	2	0.55	0.75	Upper= +1.82 , Lower= -1.06
Sanandaj		0.60	0.85	Upper= +1.77 , Lower= -0.41
Kermanshah		0.62	0.90	Upper= +1.62 , Lower= -0.15
Khoramabad		0.70	0.92	Upper= +1.42 , Lower= -0.17
Dezful		0.61	0.78	Upper= +1.92 , Lower= -0.62
Ahvaz		0.55	0.77	Upper= +1.98 , Lower= -0.69
Sahrkourd		0.66	0.76	Upper= +1.87 , Lower= -0.84
Abadan		0.62	0.71	Upper= +2.16 , Lower= -0.82
Boshehr		0.64	0.81	Upper= +3.03 , Lower= -1.99
Shiraz		0.70	0.86	Upper= +1.53 , Lower= -0.67
Bandar lengheh		0.48	0.77	Upper= +2.15 , Lower= -0.55
Bandar Abbas		0.44	0.75	Upper= +2.28 , Lower= -0.65
Bandar Chabahar	3	0.56	0.80	Upper= +1.97 , Lower= -0.64
Tabriz		0.66	0.85	Upper= +1.63 , Lower= -0.56
Urmia		0.72	0.86	Upper= +1.68 , Lower= -0.55
Saqez	4	0.67	0.83	Upper= +1.82 , Lower= -0.55
Semnan		0.63	0.86	Upper= +1.59 , Lower= -0.47
Shahrud		0.70	0.87	Upper= +1.43 , Lower= -0.61
Sabzvar		0.63	0.79	Upper= +1.69 , Lower= -1.07
Torbat Heydarieh		0.73	0.86	Upper= +1.43 , Lower= -0.95
Tabas		0.54	0.78	Upper= +2.10 , Lower= -0.58
Birjand		0.67	0.90	Upper= +1.58 , Lower= -0.621
Bam		0.39	0.64	Upper= +2.50 , Lower= -0.93
Iranshahr		0.47	0.80	Upper= +1.96 , Lower= -0.73
Kerman		0.57	0.83	Upper= +2.08 , Lower= -0.47
Yazd		0.52	0.73	Upper= +2.21 , Lower= -0.54
Isfahan		0.52	0.67	Upper= +2.21 , Lower= -0.89
Hamedan		0.63	0.87	Upper= +1.54 , Lower= -0.45
Qazvin		0.65	0.84	Upper= +1.45 , Lower= -0.75
Tehran		0.60	0.82	Upper= +1.61 , Lower= -0.78
Arak	5	0.48	0.63	Upper= +2.14 , Lower= -1.09
Zabol		0.59	0.84	Upper= +1.85 , Lower= -0.67
Zahedan		0.67	0.85	Upper= +1.79 , Lower= -0.63
Saravan		0.60	0.83	Upper= +1.75 , Lower= -0.98
Mashhad	6	0.80	0.88	Upper= +1.36 , Lower= -0.80

ایستگاه‌ها می‌باشد. اما در مقیاس‌های زمانی بلندمدت، ویلون‌ها باریک‌تر بوده و داده‌ها حول مقادیر بالای ضرایب به‌ویژه ضریب همبستگی متمرکز می‌شوند که نشان‌دهنده قطعیت بیشتر و پراکندگی کمتر بین ایستگاه‌ها می‌باشد. علاوه بر این، شکل توزیع ویلون‌ها در مقیاس بالاتر، نشانه‌ای از کاهش بایاس و افزایش دقت در برآورد همبستگی و توافق می‌باشد.

بنابراین میزان هماهنگی بین مقادیر SPEI و SPEIbase در خشکسالی‌های کشاورزی و به‌ویژه هیدرولوژیکی بسیار بیشتر از خشکسالی‌های هواشناسی می‌باشد. پهنای ویلون بیانگر تراکم توزیع ضرایب همبستگی و کاپا در ایستگاه‌های ۴۳ گانه می‌باشد. در مقیاس‌های زمانی کوتاه‌تر (۱ و ۳ ماهه)، ویلون‌ها معمولاً پهن‌تر بوده و بیانگر پراکندگی بیشتر ضرایب به‌ویژه ضریب همبستگی بین ایستگاه‌ها است. این می‌تواند به‌دلیل تنوع ناهمواری، عرض جغرافیایی و اقلیم



شکل ۶- نمودارهای ویلونی از ضریب همبستگی پیرسون (سمت چپ) و ضریب کاپای کوهن وزن دار (سمت راست) بین SPEI و SPEIbase در مقیاس‌های زمانی مختلف

Figure 6- Violin plots of the Pearson correlation coefficient (left panel) and the weighted Cohen's kappa coefficient (right panel) between SPEI and SPEIbase at different time scales

نتیجه‌گیری

این پژوهش یک رویکرد عملی و قابل اعتماد برای بررسی هماهنگی و توافق میان SPEI و SPEIbase در سطح حوضه‌های آبریز ایران پیاده‌سازی نموده است. برای این منظور، داده‌های دما و بارش ماهانه تعداد ۴۳ ایستگاه هواشناسی در بازه ۱۹۸۶ تا ۲۰۲۳ میلادی از آرشیو سازمان هواشناسی کشور تهیه شده است. این دوره زمانی دارای بیشترین بازه زمانی مشترک برای داده‌های دما و به‌ویژه بارش ثبت شده در ایستگاه‌های هواشناسی ایران بوده و دارای حداقل داده گمشده در سری‌های زمانی نیز می‌باشد. شاخص SPEI بر اساس برآورد تبخیر و تعرق پتانسیل مبتنی بر روش تورنت‌ویت در مقیاس‌های زمانی ۱، ۳، ۶، ۹ و ۱۲ ماهه برای این مجموعه داده محاسبه شده که بیانگر خشکسالی هواشناسی، کشاورزی و هیدرولوژیکی می‌باشد. از سوی دیگر داده‌های شبکه‌بندی شده SPEIbase که بر اساس اطلاعات ماهانه بارندگی و تبخیر و تعرق پتانسیل (مبتنی بر روش پنمن-مانتیت FAO-56) می‌باشد در مقیاس و دوره زمانی مشابه SPEI از واحد تحقیقات اقلیمی دانشگاه انگلیای شرقی تهیه شده است. آزمون همبستگی خطی پیرسون برای بررسی درجه هماهنگی بین مقادیر دو شاخص و از آزمون کاپای کوهن وزن دار و نمودار بلند-آلتمن برای سنجش میزان توافق بین این دو شاخص در پایش وضعیت خشکسالی در گستره ایران استفاده شده است.

یافته‌ها نشان دادند که میزان همبستگی خطی پیرسون بین مقادیر شاخص SPEI محاسباتی برای ایستگاه‌های هواشناسی و شاخص SPEIbase که منتج از داده‌های شبکه‌ای بارش و دمای جهانی بود، در اغلب ایستگاه‌ها و حوضه‌های آبریز ایران، در دامنه همبستگی قوی

(۰/۷۰ تا ۰/۹۰) قرار دارد. این مقدار از همبستگی در برخی از مناطق (مانند خرم‌آباد، همدان و سقز) حتی به آستانه همبستگی بسیار قوی نیز نزدیک شده است. در مقابل، در ایستگاه‌های با ویژگی‌های اقلیمی ساحلی و جلگه‌ای (مانند بندرعباس، چابهار و بابلسر)، همبستگی در مقیاس‌های کوتاه‌تر اندکی کاهش یافته و در سطح متوسط تا نسبتاً قوی قرار داشته است. به‌طور کلی، میزان همبستگی از مقیاس‌های کوتاه‌تر (۱ و ۳ ماهه) به مقیاس‌های بلندتر (۶، ۹ و ۱۲ ماهه) افزایش داشته است. بیان تصویری مقایسه سری‌های زمانی از شاخص‌های خشکسالی نیز یک هماهنگی قوی را در نمایش دوره‌های خشکسالی و ترسالی نشان داد. با این حال، تحلیل‌های کمی‌تر نشان داد که SPEIbase نسبت به SPEI در نمایش مشخصه‌های خشکسالی، به ویژه دوام، متفاوت عمل می‌کند. این تفاوت‌ها شامل آغاز زود هنگام و پایان دیر هنگام خشکسالی در شاخص SPEIbase می‌باشد که دوام خشکسالی را طولانی‌تر برآورد می‌کند. علاوه بر این، به نظر می‌رسد شاخص SPEIbase، نوسانات مقطعی (فصلی) ترسالی را در رویدادهای طولانی‌مدت خشکسالی پسین ادغام نموده و دوام رویدادهای خشکسالی را افزایش می‌دهد. این وضعیت‌های احتمالی، منجر به عدم توافق هر چند اندک میان SPEI و SPEIbase در بیان وضعیت‌های خشکسالی (خشکسالی خیلی شدید، خشکسالی شدید و خشکسالی متوسط) می‌گردد که در آزمون‌های بلند-آلتمن و کاپای کوهن، نمود یافته است. با وجود تفاوت ماهیت این روش‌ها در برآورد تبخیر و تعرق (روش برآورد مبتنی بر معادله تونت‌ویت در SPEI و روش برآورد مبتنی بر معادله پنمن-مانتیت FAO-56 در SPEIbase)، میزان توافق بین این شاخص‌ها در بیان وضعیت‌های خشکسالی در اکثر ایستگاه‌های هواشناسی در دامنه توافق زیاد (بر اساس آزمون کاپای کوهن وزن دار)

ایستگاه‌های هواشناسی گستره ایران می‌تواند همبستگی و توافق میان این روش را افزایش دهد.

تعارض منافع

نویسندگان اعلام می‌کنند که هیچ گونه تعارض منافی در ارتباط با این پژوهش وجود ندارد.

سپاسگزاری

از سازمان هواشناسی کشور که داده‌های هواشناسی را به صورت رایگان در اختیار این پژوهش قرار داد، سپاسگزاری می‌گردد.

قرار دارد. بنابراین SPEI و SPEIbase شباهت‌های زیاد در پایش خشکسالی و توافق زیاد در بیان وضعیت خشکسالی دارند. با این وجود، میزان توافق بین بیان وضعیت‌های خشکسالی در اقلیم‌های کم‌ارتفاع و جلگه‌ای به‌ویژه در مقیاس زمانی کوتاه (خشکسالی هواشناسی) نسبت به ایستگاه‌های مناطق بیابانی و مرتفع اندکی پایین‌تر بوده است. با توجه به تحلیل‌های انجام‌شده، شاخص خشکسالی SPEIbase با دقت مناسب در بسیاری از مناطق ایران، به‌ویژه در حوضه‌های کوهستانی، قابلیت جایگزینی برای داده‌های ایستگاهی را دارد. داده‌های این پایگاه جهانی با توجه به پوشش وسیع مکانی و وضوح زمانی بالا، به‌ویژه برای مناطق فاقد ایستگاه یا با داده‌های ناقص، می‌توانند ابزار مؤثری در پایش خشکسالی باشند. با وجود این، محاسبه SPEI در برپایه معادله برآورد تبخیر و تعرق پتانسیل مبتنی بر معادله پنمن - مانتیث FAO-56 در

References

- Adler, J., & Parmryd, I. (2010). Quantifying colocalization by correlation: the Pearson correlation coefficient is superior to the Mander's overlap coefficient. *Cytometry Part A*, 77(8), 733-742. <https://doi.org/10.1002/cyto.a.20896>
- Ahmadalipour, A., Moradkhani, H., & Demirel, M.C. (2017). A comparative assessment of projected meteorological and hydrological droughts: elucidating the role of temperature. *Journal of Hydrology*, 553, 785-797. <https://doi.org/10.1016/j.jhydrol.2017.08.047>
- Allen, R.G. (2000). Using the FAO-56 dual crop coefficient method over an irrigated region as part of an evapotranspiration intercomparison study. *Journal of Hydrology*, 229(1-2), 27-41. [https://doi.org/10.1016/S0022-1694\(99\)00194-8](https://doi.org/10.1016/S0022-1694(99)00194-8)
- Beguería, S., & Vicente-Serrano, SM. (2023). *SPEI: Calculation of the Standardized Precipitation-Evapotranspiration Index*. <https://spei.csic.es>, <https://github.com/sbegueria/SPEI>
- Bisht, H., LOO, S., Suna, T., Vishnoi, L., Gautam, S., & Singh, D.K. (2023). Drought assessment and trend analysis using SPI and SPEI during southwest monsoon season over Bundelkhand region of Uttar Pradesh, India. *Mausam*, 74(1), 119-128. <https://doi.org/10.54302/mausam.v74i1.3519>
- Bland, J.M., & Altman, D. (2010). Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, 327(8476), 307-310. <https://doi.org/10.1016/j.ijnurstu.2009.10.001>
- Brands, S., Iturbide, M., González-Pardo, J.D., Herrera, S., Bedia, J., Manzanar, R., Rodriguez-Guisado, E., Begueria, S., Vicente-Serrano, S.M., & Gutiérrez, J.M. (2025). Seasonal drought predictions in the Mediterranean using the SPEI index: Paving the way for their operational applicability in climate services. *Climate Services*, 38, 100555. <https://doi.org/10.1016/j.cliser.2025.100555>
- Cohen, J. (1960). A co-efficient of agreement for nominal scales. *Education Psychology Meas*, 20, 111-116. <http://hdl.handle.net/1942/28116>
- Fleiss, J.L. (1971). Measuring nominal scale agreement among many raters. *Psychological Bulletin*, 76(5), 378. <https://doi.org/10.1037/h0031619>
- Gebrechorkos, S.H., Peng, J., Dyer, E., Miralles, D.G., Vicente-Serrano, S.M., Funk, C., Beck, H.E., Asfaw, D.T., Singer, N.B., & Dadson, S.J. (2023). Global high-resolution drought indices for 1981–2022. *Earth System Science Data Discussions*, 2023, 1-28. <https://doi.org/10.5194/essd-15-5449-2023>
- Giavarina, D. (2015). Understanding bland altman analysis. *Biochemia Medica*, 25(2), 141-151. <https://doi.org/10.11613/BM.2015.015>
- Gwet, K.L. (2008). Computing inter-rater reliability and its variance in the presence of high agreement. *British Journal of Mathematical and Statistical Psychology*, 61(1), 29-48. <https://doi.org/10.1348/000711006X126600>
- Hargreaves, G.H., & Samani, Z.A. (1985) Reference crop evapotranspiration from ambient air temperature. *Apply Engineering Agriculture*, 1(2), 96–99. <https://doi.org/10.13031/2013.26773>
- Imran, H.M., Kala, J., Uddin, S., Islam, A.S., & Acharya, N. (2023). Spatiotemporal analysis of temperature and precipitation extremes over Bangladesh using a novel gridded observational dataset. *Weather and Climate Extremes*, 39, 100544. <https://doi.org/10.1016/j.wace.2022.100544>
- Keyantash, J., & Dracup, J.A. (2002). The quantification of drought: an evaluation of drought indices. *Bulletin of the American Meteorological Society*, 83(8), 1167-1180. <https://doi.org/10.1175/1520-0477-83.8.1167>

16. Landis, J.R., & Koch, G.G. (1977). An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers. *Biometrics*, 363-374. <https://doi.org/10.2307/2529786>
17. Lweendo, M.K., Lu, B., Wang, M., Zhang, H., & Xu, W. (2017). Characterization of droughts in humid subtropical region, upper kafue river basin (Southern Africa). *Water*, 9(4), 242. <https://doi.org/10.3390/w9040242>
18. Manzano, A., Clemente, M.A., Morata, A., Luna, M.Y., Beguería, S., Vicente-Serrano, S.M., & Martín, M.L. (2019). Analysis of the atmospheric circulation pattern effects over SPEI drought index in Spain. *Atmospheric Research*, 230, 104630. <https://doi.org/10.1016/j.atmosres.2019.104630>
19. Mehran, A., Mazdiyasi, O., & AghaKouchak, A. (2015). A hybrid framework for assessing socioeconomic drought: Linking climate variability, local resilience, and demand. *Journal of Geophysical Research: Atmospheres*, 120(15), 7520-7533. <https://doi.org/10.1002/2015JD023147>
20. Nazaripour, H., Hamidianpour, M., Khosravi, M., & Vazirimehr, M. (2022). Variability of drought frequency and intensity in Iran using SPEI. *Journal of Water and Soil Science*, 26(4), 233-247. (In Persian). <https://doi.org/10.47176/jwss.26.4.45861>
21. Nikdad, P., Mohammadi Ghaleni, M., & Moghaddasi, M. (2023). Evaluation of actual and potential evapotranspiration in global products across Iran's sub basins. *Iranian Journal of Soil and Water Research*, 54(5), 789-810. <https://doi.org/10.22059/ijswr.2023.357603.669481>
22. Ojha, N., Merlin, O., Suere, C., & Escorihuela, M.J. (2021). Extending the spatio-temporal applicability of DISPATCH soil moisture downscaling algorithm: A study case using SMAP, MODIS and Sentinel-3 data. *Frontiers in Environmental Science*, 9, 555216. <https://doi.org/10.3389/fenvs.2021.555216>
23. Peña-Gallardo, M., Vicente-Serrano, S.M., Hannaford, J., Lorenzo-Lacruz, J., Svoboda, M., Dominguez-Castro, F., Manteta, M., Tomas-Burguera, M., & El Kenawy, A. (2019). Complex influences of meteorological drought time-scales on hydrological droughts in natural basins of the contiguous Unites States. *Journal of Hydrology*, 568, 611-625. <https://doi.org/10.1016/j.jhydrol.2018.11.026>
24. Razinei, T. (2017). Köppen-Geiger climate classification of Iran and investigation of its changes during 20th century. *Journal of the Earth and Space Physics*, 43(2), 419-439. (In Persian). <https://doi.org/10.22059/jesphys.2017.58916>
25. Razinei, T., Saghafian, B., Paulo, A.A., Pereira, L.S., & Bordi, I. (2009). Spatial patterns and temporal variability of drought in western Iran. *Water Resources Management*, 23(3), 439-455. <https://doi.org/10.1007/s11269-008-9282-4>
26. Satgé, F., Hussain, Y., Molina- Carpio, J., Pillco, R., Laugner, C., Akhter, G., & Bonnet, M.P. (2020). Reliability of SM2RAIN precipitation datasets in comparison to gauge observations and hydrological modelling over arid regions. *International Journal of Climatology*, 41(S1). <https://doi.org/10.1002/joc.6704>
27. Schober, P., Boer, C., & Schwarte, L.A. (2018). Correlation coefficients: appropriate use and interpretation. *Anesthesia & Analgesia*, 126(5), 1763-1768. [https://doi.org/10.1016/S0140-6736\(86\)90837-8](https://doi.org/10.1016/S0140-6736(86)90837-8)
28. Stagge, J.H., Tallaksen, L.M., Gudmundsson, L., Van Loon, A.F., & Stahl, K. (2015). Candidate distributions for climatological drought indices (SPI and SPEI). *International Journal of Climatology*, 35(13), 4027-4040. <https://doi.org/10.1002/joc.4267>
29. Tefera, A.S., Ayoade, J.O., & Bello, N.J. (2019). Comparative analyses of SPI and SPEI as drought assessment tools in Tigray Region, Northern Ethiopia. *SN Applied Sciences*, 1(10), 1265. <https://doi.org/10.1007/s42452-019-1326-2>
30. Tukimat, N.N.A., Harun, S., & Shahid, S. (2012). Comparison of different methods in estimating potential evapotranspiration at Muda Irrigation Scheme of Malaysia. *Journal of Agriculture and Rural Development in the Tropics and Subtropics (JARTS)*, 113(1), 77-85. <https://urn.fi/urn:nbn:de:hebis:34-2012091441739>
31. Vicente-Serrano, S.M., Beguería, S., & López-Moreno, J.I. (2010). A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696-1718. <https://doi.org/10.1175/2009JCLI2909.1>
32. Vicente-Serrano, S.M., Peña-Angulo, D., Beguería, S., Domínguez-Castro, F., Tomás-Burguera, M., Noguera, I., Gimeno-Sotelo, L., & El Kenawy, A. (2022). Global drought trends and future projections. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 380(2238). <https://doi.org/10.1098/rsta.2021.0285>
33. Viera, A.J., & Garrett, J.M. (2005). Understanding interobserver agreement: the kappa statistic. *Fam Med*, 37(5), 360-363. PMID: 15883903.
34. Warrens, M.J. (2013). Weighted kappas for 3×3 tables. *Journal of Probability and Statistics*, 2013(1), 325831. <https://doi.org/10.1155/2013/325831>
35. Watson, P.F., & Petrie, A. (2010). Method agreement analysis: a review of correct methodology. *Theriogenology*, 73(9), 1167-1179. <https://doi.org/10.1016/j.theriogenology.2010.01.003>

Research Article

Vol. 39, No. 6, Feb.-Mar. 2026, p. 611-626

Impact of Biochar and Compost Application on Soil Physical and Chemical Characteristics and Water Availability for Sugarcane

A. Karimi^{1*}, E. Zangeneh-Yusefabadi²

1- Department of Agronomy Research, Khuzestan Sugarcane Research and Training Institute, Ahvaz, Iran

(*- Corresponding Author Email: akbar.karimi84@yahoo.com)

2- Department of Irrigation and Drainage Research, Khuzestan Sugarcane Research and Training Institute, Ahvaz, Iran

Received: 18 February 2026

Revised: 10 May 2026

Accepted: 11 May 2026

Available Online: 11 May 2026

How to cite this article:

Karimi, A., & Zangeneh-Yusefabadi, E. (2026). Impact of biochar and compost application on soil physical and chemical characteristics and water availability for the sugarcane plant. *Journal of Water and Soil*, 39(6), 611-626. (In Persian with English abstract). <https://doi.org/10.22067/jsw.2026.97933.1528>

Introduction

One of the main challenges of agricultural soils in arid and semi-arid regions is the low amount of organic matter, which has a negative effect on the physical and chemical properties of the soil. Soil organic matter plays a role in various soil properties and processes, including soil water retention capacity, soil water distribution, soil microbial activity, water and nutrient availability to plants, and subsequently plant nutrition and yield. The application of biochar as an organic amendment is one of the strategies that has received attention in recent years for increasing soil organic matter and improving the physical and chemical attributes of the soil. Another way to improve soil organic matter is compost application to the soil as an organic amendment. The low organic matter in the soils of sugarcane fields in Khuzestan Province and also the optimal amount of biochar and compost application to improve the physical and chemical properties of these soils, have not been studied. Therefore, this study was carried out to investigate the effect of applying different levels of biochar and compost derived from sugarcane green harvest residues on the physical and chemical properties of soil and water availability for sugarcane plants under field condition.

Materials and Methods

This study was conducted under field conditions at Research Station No. 1 of the Khuzestan Sugarcane Research and Training Institute. This experiment was conducted in a randomized complete block design with seven treatments, including control, biochar application at three levels of 5 (B5), 10 (B10), and 15 (B15) t ha⁻¹, and compost application at three levels of 15 (CO15), 30 (CO30), and 45 (CO45) t ha⁻¹, with three replications. For the application of biochar and compost treatments prior to sugarcane planting, the required amounts of each treatment were weighed, manually distributed and incorporated into the soil to an approximately 30 cm depth. Subsequently, sugarcane setts were planted. Soil sampling was conducted at the end of the growth period in different treatments and the physical and chemical properties of the soil were determined. In this study, the effects of different treatments on the soil chemical characteristics (soil pH, EC and organic carbon), soil phosphorus and potassium availability, physical properties (soil bulk density and mean weight diameter of soil aggregates), field capacity, and permanent wilting point (PWP) were measured and water availability for the sugarcane plant was determined.

Results and Discussion

The results indicated that the application of biochar treatments (B10 and B15) and compost treatments (CO30 and CO45) decreased soil pH and bulk density, while significantly increasing mean weight diameter, soil organic



Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2026.97933.1528>

carbon, available phosphorus, available potassium, and plant-available water. The mean weight diameter of soil aggregates in the CO30, CO45, B5, B10, and B15 treatments was 15.8%, 23.7%, 20.2%, 32.5%, and 36.0% higher than that of the control, respectively. The greatest increases in mean weight diameter of soil aggregates and field capacity plant water availability were observed in the B10 and B15 treatments. The amount of plant-available water in B10 and B15 was 38.9% and 37.5% higher than the control, respectively. In addition, the results also indicated a greater effect of biochar treatments on increasing plant-available water compared with compost treatments. Plant available water in B10 treatment was 21.7% higher than CO45 and 26.3% higher than CO30 treatment. The results indicated that there were no significant differences among B10, B15, and CO45 with respect to soil pH, organic carbon, and phosphorus availability. However, the biochar treatments (B10 and B15) were significantly more effective than CO45 in enhancing soil potassium availability, improving soil physical properties, and increasing plant-available water.

Conclusion

Overall, it can be concluded that biochar application at 10 t ha^{-1} and compost application at 45 t ha^{-1} represent the optimal rates for improving soil chemical properties in calcareous soils of sugarcane fields. Furthermore, biochar at 10 t ha^{-1} was the most effective treatment for improving soil physical properties and enhancing water availability for sugarcane.

Keywords: Bulk density, Nutrient availability, Organic amendments, Sugarcane residues, Water availability

تأثیر کاربرد بیوپچار و کمپوست بر ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر

اکبر کریمی^{۱*} - الهام زنگنه یوسف‌آبادی^۲

تاریخ دریافت: ۱۴۰۴/۱۱/۲۹

تاریخ پذیرش: ۱۴۰۵/۰۲/۲۱

چکیده

اصلاح‌کننده‌های آلی خاک می‌توانند در بهبود ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه مؤثر باشند. این پژوهش به‌منظور بررسی تأثیر کاربرد سطوح مختلف بیوپچار و کمپوست تهیه شده از بقایای برداشت سبز نیشکر بر ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر در قالب طرح بلوک‌های کامل تصادفی با هفت تیمار شامل شاهد، کاربرد بیوپچار در سه سطح ۵ (B5)، ۱۰ (B10) و ۱۵ (B15) تن در هکتار و کاربرد کمپوست در سه سطح ۱۵ (CO15)، ۳۰ (CO15) و ۴۵ (CO45) تن در هکتار و در سه تکرار انجام شد. نتایج نشان داد که کاربرد تیمارهای بیوپچار (B10 و B15) و کمپوست (CO30 و CO45) سبب کاهش pH و چگالی ظاهری خاک و افزایش معنی‌دار میانگین وزنی قطر خاکدانه، کربن آلی، فسفر و پتاسیم قابل دسترس خاک و فراهمی آب برای گیاه شدند. تفاوت معنی‌داری میان تأثیر تیمارهای B10، B15 و CO45 بر pH، کربن آلی و فراهمی فسفر در خاک مشاهده نشد، در حالی که تأثیر تیمارهای بیوپچار B10 و B15 در افزایش فراهمی پتاسیم در خاک، بهبود ویژگی‌های فیزیکی خاک و افزایش فراهمی آب برای گیاه به‌طور معنی‌داری بیش‌تر از تیمار CO45 بود. به‌طور کلی، می‌توان نتیجه‌گیری کرد که سطح ۱۰ تن در هکتار بیوپچار و سطح ۴۵ تن در هکتار کمپوست، مقدار مناسب کاربرد آن‌ها به‌منظور بهبود ویژگی‌های شیمیایی خاک در خاک‌های آهکی مزارع نیشکر بود. همچنین کاربرد بیوپچار در سطح ۱۰ تن در هکتار به‌عنوان مناسب‌ترین تیمار جهت بهبود ویژگی‌های فیزیکی خاک و افزایش فراهمی آب برای گیاه نیشکر بود.

واژه‌های کلیدی: آب قابل دسترس، اصلاح‌کننده‌های آلی، بقایای نیشکر، چگالی ظاهری، فراهمی عناصر غذایی

مقدمه

آلی برای بهبود ویژگی‌های فیزیکی و شیمیایی خاک، در خاک‌های مناطق خشک و نیمه‌خشک که ماده آلی کمی دارند، ضروری به‌نظر می‌رسد (Sharma et al., 2025).

کاربرد بیوپچار و کمپوست به‌عنوان اصلاح‌کننده‌های آلی، از جمله راه‌کارهایی است که در سال‌های اخیر برای افزایش ماده آلی خاک و بهبود ویژگی‌های فیزیکی و شیمیایی خاک، مورد توجه قرار گرفته است (Wang et al., 2024; Haufiku et al., 2025; Adetunji & Blanco-Canqui, 2026). بیوپچار یک ماده متخلخل و غنی از کربن

یکی از چالش‌های اصلی خاک‌های کشاورزی در مناطق خشک و نیمه‌خشک، کمبود ماده آلی می‌باشد که اثرات منفی بر ویژگی‌های فیزیکی و شیمیایی خاک دارد (Azim et al., 2024). ماده آلی خاک بر ویژگی‌ها و فرآیندهای مختلف خاک از جمله ظرفیت نگهداشت آب در خاک، توزیع آب در خاک، فعالیت میکروبی خاک، فراهمی عناصر غذایی برای گیاه و به‌دنبال آن در بهبود تغذیه و عملکرد گیاه، نقش دارد (Piccolo & Drosos, 2025). بنابراین کاربرد اصلاح‌کننده‌های

۱- گروه تحقیقات به‌زراعی، مؤسسه تحقیقات و آموزش نیشکر خوزستان، اهواز، ایران
(* - نویسنده مسئول: Email: akbar.karimi84@yahoo.com)

۲- گروه تحقیقات آبیاری و زهکشی، مؤسسه تحقیقات و آموزش نیشکر خوزستان، اهواز، ایران

خوزستان (Karimi et al., 2024a) و اثرات منفی ناشی از آن، بررسی تأثیر کاربرد بیوپچار بر ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر ضروری به نظر می‌رسد. از آنجایی که تاکنون مطالعات چندانی در زمینه مقایسه تأثیر کاربرد سطوح مختلف بیوپچار و کمپوست تهیه شده از بقایای برداشت سبز نیشکر بر ویژگی‌های فیزیکی و شیمیایی خاک‌های آهکی ایران، در شرایط مزرعه‌ای انجام نشده است و همچنین مقدار بهینه کاربرد کمپوست و بیوپچار، در خاک‌های آهکی مزارع نیشکر تعیین نشده است، بنابراین این پژوهش به منظور بررسی تأثیر کاربرد سطوح مختلف بیوپچار و کمپوست بر ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب برای گیاه نیشکر در شرایط مزرعه‌ای انجام شد.

مواد و روش‌ها

تهیه بیوپچار و کمپوست و اندازه‌گیری ویژگی‌های آن‌ها

در این پژوهش از زیست‌توده بقایای برداشت سبز نیشکر (پوشال و سرنی) تهیه شده از کشت و صنعت امام خمینی (ره) خوزستان برای تهیه بیوپچار استفاده شد. بقایای برداشت سبز تهیه شده ابتدا هوا خشک شده و سپس در دمای ۱۰۵ درجه سلسیوس خشک شدند (Singh et al., 2017). فرآیند پیرولیز در کوره الکتریکی در دمای ۳۵۰ درجه سلسیوس با نرخ افزایش دمای ۵ درجه سلسیوس در دقیقه، به مدت ۳ ساعت در شرایط حداقل اکسیژن انجام شد (Karimi et al., 2020; Karimi et al., 2026). کمپوست بقایای برداشت سبز نیشکر در سایت تولید کمپوست کشت و صنعت حکیم فارابی خوزستان تهیه شد. سپس ویژگی‌های بیوپچار و کمپوست مورد استفاده در این پژوهش، اندازه‌گیری شد (Singh et al., 2017) که نتایج آن در جدول ۱ آمده است.

نمونه‌برداری خاک و اندازه‌گیری ویژگی‌های فیزیکی و شیمیایی در نمونه‌ها

این پژوهش در شرایط مزرعه‌ای در ایستگاه تحقیقاتی شماره یک مؤسسه تحقیقات و آموزش نیشکر خوزستان واقع در طول جغرافیایی ۴۸ درجه و ۳۲ شرقی و عرض جغرافیایی ۳۰ درجه و ۵۹ دقیقه شمالی با ارتفاع ۶/۶۰۳ متر از سطح دریا، انجام شد. نمونه‌برداری اولیه از خاک محل انجام آزمایش به روش مرکب از عمق ۰ تا ۳۰ سانتی‌متری انجام شد. نمونه خاک جمع‌آوری شده، هوا خشک شده و از الک ۲ میلی‌متری عبور داده شد. سپس ویژگی‌های فیزیکی و شیمیایی خاک اندازه‌گیری شد (Kroetsch & Wang, 2008). نتایج آنالیز ویژگی‌های خاک مورد مطالعه در جدول ۲ آورده شده است. خاک مورد مطالعه دارای بافت لوم رسی، pH قلیایی، غیر شور، آهکی و دارای ماده آلی کم بود (جدول ۲).

است که از تجزیه حرارتی زیست‌توده‌های مختلف طی فرآیند گرماکافت، در شرایط بدون اکسیژن و یا حداقل اکسیژن تولید می‌شود (Khajavi-Shojaei et al., 2024). نتایج مطالعات مختلف نشان داده است که کاربرد بیوپچار در خاک‌های آهکی سبب افزایش مقدار کربن آلی خاک و فراهمی عناصر غذایی از جمله فسفر و پتاسیم برای گیاه می‌شود (Karimi et al., 2020; Khaji et al., 2025). کاربرد بیوپچار به عنوان یک منبع کربن در خاک به دلیل ساختار متخلخل آن، سبب تشکیل منافذ ثانویه و تغییر اندازه منافذ خاک شده و با بهبود کربن آلی، تخلخل و سطح ویژه خاک، خاکدانه‌سازی خاک را تحت تأثیر قرار داده و منجر به بهبود ساختمان خاک و همچنین افزایش نگهداشت آب در خاک شود (Enebe et al., 2025). کاربرد کمپوست نیز با تأثیر بر ویژگی‌ها و فرایندهای گوناگون خاک می‌تواند ویژگی‌های فیزیکی، شیمیایی خاک را تحت تأثیر قرار داده و در بهبود رشد و عملکرد گیاهان مؤثر باشد (Haufigu et al., 2025). کاربرد کمپوست، می‌تواند از طریق مکانیسم‌های مختلف، فراهمی فسفر و پتاسیم را برای گیاه افزایش دهد (Wang et al., 2024). کمپوست همچنین می‌تواند منبع عناصر غذایی ضروری برای گیاه باشد و آزادسازی عناصر غذایی موجود در ساختار کمپوست در خاک، در بهبود وضعیت عناصر غذایی مؤثر است. کاربرد کمپوست همچنین می‌تواند در بهبود ویژگی‌های فیزیکی و هیدرولیکی خاک از جمله کاهش چگالی ظاهری، خاکدانه‌سازی، افزایش میانگین قطر خاکدانه‌ها، افزایش فراهمی آب برای گیاه، نیز مؤثر است (Ghorbani et al., 2023).

تأثیر کاربرد بیوپچار و کمپوست بر ویژگی‌های فیزیکی و شیمیایی خاک به عوامل مختلفی از جمله نوع و ویژگی‌های آن‌ها، مقدار کاربرد آن‌ها و همچنین ویژگی‌های خاک بستگی دارد (Ghorbani et al., 2023; Albalasmeh et al., 2024; Xiao et al., 2024). ژانگ و همکاران (Zhang et al., 2026) با بررسی تأثیر کاربرد سطوح بیوپچار ۴/۵ و ۹ تن در هکتار بر فراهمی فسفر در یک خاک آهکی گزارش کردند که کاربرد بیوپچار در سطح ۹ تن در هکتار سبب افزایش معنی‌دار فسفر قابل دسترس خاک شد، در حالی که سطح ۴/۵ تن در هکتار بیوپچار اثر معنی‌داری بر فسفر قابل دسترس خاک نداشت. قربانی و امیراحمدی (Ghorbani & Amirahmadi, 2024) گزارش کردند کاربرد بیوپچار در مقادیر کم‌تر از ۵ تن در هکتار و بیش‌تر از ۳۰ تن در هکتار، در مقایسه با کاربرد بیوپچار در سطح ۱۰ تا ۲۰ تن در هکتار تأثیر کم‌تری در افزایش میانگین وزنی قطر خاکدانه‌های خاک دارد.

بقایای برداشت سبز نیشکر (سرنی و برگ) از پسماندهای مهم کشاورزی در استان خوزستان می‌باشد. یکی از راهکارهای مدیریت این بقایا تبدیل آن‌ها به بیوپچار طی فرآیند پیرولیز و یا تبدیل آن‌ها به کمپوست می‌باشد (Khaji et al., 2025). از این‌رو این زیست‌توده جهت تولید بیوپچار و کمپوست استفاده شد. از طرف دیگر با توجه به کمبود ماده آلی در خاک‌های مزارع تحت کشت نیشکر در استان

جدول ۱- برخی ویژگی‌های بیوچار و کمپوست مورد استفاده در این پژوهش
Table 1- Selected properties of the biochar and compost used in this study

نسبت مولی Molar ratio H/C	هیدروژن Hydrogen (%)	پتاسیم Potassium (%)	فسفر Phosphorus (%)	نیتروژن Nitrogen (%)	کربن Carbon (%)	سطح ویژه Specific surface area	چگالی ظاهری Bulk density	هدایت الکتریکی Electrical conductivity (1:10)	pH (1:10)	ویژگی Property
واحد Unit	%	%	%	%	%	m ² g ⁻¹	g cm ⁻³	dS m ⁻¹	-	
0.32	1.43	5.42	1.21	1.79	53.2	56.7	0.23	4.23	6.95	بیوچار Biochar
-	-	2.34	1.08	1.12	26.2	14.7	0.82	3.38	6.82	کمپوست Compost

جدول ۲- برخی ویژگی‌های فیزیکی و شیمیایی خاک مورد مطالعه
Table 2- Selected physical and chemical properties of the studied soil

بافت خاک Soil texture	شن Sand	سیلت Silt	رس Clay	BD	K _{Ava}	P _{Ava}	نیتروژن کل Total N	CCE	OC	هدایت الکتریکی Electrical conductivity	pH	ویژگی Property
-	%	%	%	g cm ⁻³	mg kg ⁻¹	mg kg ⁻¹	%	%	%	dS m ⁻¹	-	واحد Unit
Clay loam	22.5	38.5	39	1.58	124.5	5.24	0.51	46.5	0.43	2.56	7.82	مقدار Value

EC: هدایت الکتریکی عصاره گل اشباع؛ OC: کربن آلی؛ CCE: کربنات کلسیم معادل؛ P_{Ava}: فسفر قابل دسترس؛ K_{Ava}: پتاسیم قابل دسترس؛ BD: چگالی ظاهری

نمونه‌برداری و اندازه‌گیری ویژگی‌های فیزیکی و شیمیایی خاک و آب قابل دسترس برای گیاه

نمونه‌برداری خاک در پایان دوره رشد رویشی گیاه (۱۳ ماه پس از کشت) در تیمارهای مختلف انجام شد و ویژگی‌های فیزیکی و شیمیایی خاک اندازه‌گیری شدند. pH و هدایت الکتریکی در عصاره اشباع خاک (Rhoades, 1996)، اندازه‌گیری شدند. کربن آلی خاک به روش اکسیداسیون تر (Nelson & Sommers, 1996)، فسفر قابل دسترس خاک به روش استخراج با بی‌کربنات سدیم (Olsen et al., 1954)، عصاره‌گیری و غلظت آن به روش رنگ‌سنجی (Murphy & Riley, 1962) با استفاده از دستگاه اسپکتروفتومتر (Apel PD-303 UV)، اندازه‌گیری شد. غلظت پتاسیم قابل دسترس خاک به روش عصاره‌گیری با اسات آمونیوم (Helmke & Sparks, 1996) و با استفاده از دستگاه فلیم فتومتر (Corning 410) اندازه‌گیری شد.

برای ارزیابی پایداری ساختمان خاک، شاخص میانگین وزنی قطر خاکدانه‌ها (MWD) به روش الک‌تر و با استفاده از مجموعه‌ای از الک‌های با قطر ۲، ۱، ۰.۵، ۰.۲۵ و ۰.۱ میلی‌متر (از بالا به پایین) اندازه‌گیری شد. سپس میانگین وزنی قطر خاکدانه‌ها با استفاده از رابطه (۱) محاسبه گردید (Le Bissonnais, 1996):

تیمارهای آزمایشی و روش اجرای پژوهش

آزمایش در قالب طرح بلوک‌های کامل تصادفی با ۷ تیمار شامل ۱- شاهد (C: بدون کاربرد کمپوست و بیوچار)، ۲- کاربرد کمپوست بقایای نیشکر در سطح ۱۵ تن در هکتار (CO15)، ۳- کاربرد کمپوست بقایای نیشکر در سطح ۳۰ تن در هکتار (CO30)، ۴- کاربرد کمپوست بقایای نیشکر در سطح ۴۵ تن در هکتار (CO45)، ۵- کاربرد بیوچار بقایای نیشکر در سطح ۵ تن در هکتار (B5)، ۶- کاربرد بیوچار بقایای نیشکر در سطح ۱۰ تن در هکتار (B10)، ۷- کاربرد بیوچار بقایای نیشکر در سطح ۱۵ تن در هکتار (B15) و در سه تکرار (در مجموع ۲۱ کرت آزمایشی) انجام شد. اندازه هر کرت آزمایشی ۲۷/۵ متر مربع (۵×۵ متر) بود. برای کاربرد تیمارهای بیوچار و کمپوست قبل از کشت گیاه نیشکر، مقدار هر یک از تیمارها با توجه به مساحت کرت‌های آزمایشی وزن شد و به صورت دستی در کف جویچه توزیع شدند و با خاک تا عمق حدود ۳۰ سانتی‌متری مخلوط شدند. سپس کشت قلمه نیشکر به صورت دوردیفه، در کف جویچه در اول شهریور ماه انجام شد (Karimi et al., 2024b; Zanganeh-Yusefabadi et al., 2024). در دوره داشت آبیاری تیمارها به روش سطحی جویچه‌ای انتهابسته انجام شد.

$$MWD = \sum_{i=1}^n \bar{x}_i w_i \quad (1)$$

که در این رابطه $\bar{x}_i$ میانگین قطر خاکدانه‌های باقی‌مانده بر روی الک i (میانگین قطر سوراخ‌های الک بالایی و پایینی)، n تعداد الک‌ها و w_i نسبت وزن خاکدانه‌های روی هر الک به وزن کل خاک به کار برده شده در ابتدای آزمایش پس از کسر ذرات شن و سنگ‌ریزه می‌باشد.

چگالی ظاهری خاک در تیمارهای مختلف، به روش استوانه‌های نمونه‌برداری (Danielson & Sutherland, 1986) اندازه‌گیری شد. رطوبت ظرفیت مزرعه‌ای (FC) و رطوبت نقطه پژمردگی دایم (PWP) در تیمارهای مختلف با استفاده از دستگاه صفحات فشاری تعیین شد (Kirkham, 2014) و آب قابل دسترس برای گیاه (PAW) از اختلاف رطوبت بین رطوبت حد ظرفیت مزرعه و حد پژمردگی دایم با استفاده از رابطه (۲) محاسبه شد.

$$PAW = FC - PWP \quad (2)$$

در این رابطه PAW آب قابل دسترس برای گیاه (درصد)، رطوبت ظرفیت مزرعه (FC) (درصد) و رطوبت نقطه پژمردگی دایم (PWP) (درصد) است.

تجزیه و تحلیل آماری داده‌ها

تجزیه آماری داده‌های این پژوهش با استفاده از نرم‌افزار آماری SAS 9.4 انجام شد. مقایسه میانگین داده‌ها با استفاده از آزمون دانکن و در سطح احتمال ۵ درصد انجام شد. نمودارها نیز در محیط نرم‌افزار Excel رسم شدند.

نتایج و بحث

ویژگی‌های شیمیایی خاک

نتایج تجزیه واریانس داده‌ها نشان داد اثر تیمارهای بیوپار و کمپوست بر pH، کربن آلی، فسفر و پتاسیم قابل دسترس خاک معنی‌دار بود بوده و این در حالی بود که اثر سطوح این ترکیبات بر هدایت الکتریکی خاک معنی‌دار نبود (جدول ۳).

نتایج مقایسه میانگین داده‌ها نشان داد در اثر کاربرد تیمارهای بیوپار و کمپوست، pH خاک کاهش (۰/۰۹ تا ۰/۲۱ واحد) یافت (جدول ۴). بدین ترتیب که بیش‌ترین مقدار pH خاک مربوط به تیمار شاهد (بدون کاربرد بیوپار یا کمپوست) (۷/۸۴) و کم‌ترین مقدار pH خاک مربوط به تیمارهای کاربرد کمپوست در سطح ۴۵ تن در هکتار (۷/۶۷) و کاربرد بیوپار در سطح ۱۵ تن در هکتار (۷/۶۷) بود (جدول ۴). همچنین تفاوت معنی‌داری بین مقدار pH خاک در تیمارهای کاربرد کمپوست در سطح ۳۰ و ۴۵ تن در هکتار و کاربرد بیوپار در سطح ۱۰ و ۱۵ تن در هکتار مشاهده نشد. به‌طور کلی تغییرات تغییرات pH خاک در اثر کاربرد بیوپار و کمپوست قابل توجه نبود، اگرچه از نظر آماری معنی‌دار بود (جدول ۴).

کاهش pH خاک در تیمارهای کاربرد بیوپار و کمپوست می‌تواند به این دلیل باشد که بیوپار و کمپوست دارای گروه‌های عاملی اسیدی بوده و اکسیداسیون آن‌ها در خاک می‌تواند سبب آزاد شدن گروه‌های عاملی اسیدی و به‌دنبال آن کاهش جزئی pH خاک شود (Karimi et al., 2020).

جدول ۳- تجزیه واریانس (میانگین مربعات) تأثیر تیمارها بر ویژگی‌های شیمیایی خاک

Table 3- ANOVA (mean squares) for the effects of treatments on soil chemical characteristics

منابع تغییرات S.O.V.	درجه آزادی Degree of freedom	میانگین مربعات Mean squares				
		په‌اش خاک Soil pH	هدایت الکتریکی خاک Soil lectrical conductivity	کربن آلی خاک Soil organic carbon	فسفر قابل دسترس خاک Soil available P	پتاسیم قابل دسترس خاک Soil available K
بلوک Block	2	0.004 ^{ns}	0.004 ^{ns}	0.002 ^{ns}	0.11 ^{ns}	86.3 ^{ns}
تیمار Treatment	6	0.018 ^{**}	0.002 ^{ns}	0.072 ^{**}	42.5 ^{**}	1699 ^{**}
خطا Error	12	0.002	0.005	0.001	0.25	37.2
ضریب تغییرات C.V (%)		1.61	9.24	5.58	7.86	8.37

^{ns} و ^{**}: به ترتیب غیرمعنی‌دار و معنی‌دار در سطح احتمال ۱ درصد

^{ns} and ^{**}: non-significant and significant at $p \leq 0.01$, respectively

جدول ۴- مقایسه میانگین اثر اصلی تیمارهای کاربرد بیوجار و کمپوست بر ویژگی‌های شیمیایی خاک

Table 4- Comparison of the average main effect of biochar and compost application treatments on soil chemical properties

تیمار	په‌اش خاک	هدایت الکتریکی	کربن آلی
Treatment	Soil pH	EC	Organic carbon
C	7.88 ^a	2.60 ^a	0.45 ^e
CO ₁₅	7.79 ^b	2.50 ^a	0.59 ^d
CO ₃₀	7.74 ^{bcd}	2.79 ^a	0.77 ^{bc}
CO ₄₅	7.67 ^d	2.68 ^a	0.88 ^a
B ₅	7.76 ^{bc}	2.72 ^a	0.75 ^c
B ₁₀	7.69 ^{cd}	2.60 ^a	0.82 ^{ab}
B ₁₅	7.67 ^d	2.43 ^a	0.86 ^a

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C, CO₁₅, CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوجار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅، B₁₀ و B₁₅ به‌ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوجار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.

مشاهده نشد. افزایش کربن آلی خاک در اثر کاربرد بیوجار و کمپوست به‌دلیل مقدار نسبتاً بالای کربن آن‌ها (جدول ۱) و اضافه شدن آن به خاک است که در مطالعات پیشین نیز گزارش شده است. بدین‌ترتیب که مقدار کربن آلی خاک به‌دلیل تأثیرپذیری از کربن بیوجار و کمپوست، افزایش می‌یابد، به‌طوری‌که بخشی از کربن آلی موجود در بیوجار و کمپوست به ذخیره کربن در خاک پیوسته و سبب افزایش کربن آلی خاک خواهد شد و بخشی دیگر از آن پس از افزوده شدن به خاک اکسید می‌شود (Moradi & Karimi, 2020; Karimi et al., 2026).


فسفر و پتاسیم قابل دسترس خاک

نتایج مقایسه میانگین داده‌ها نشان داد که در همه تیمارهای کاربرد بیوجار و کمپوست به‌جز تیمار کاربرد کمپوست در سطح ۱۵ تن در هکتار، غلظت فسفر قابل دسترس خاک به‌طور معنی‌داری بیش‌تر از تیمار شاهد بود (شکل ۱). اگرچه بیش‌ترین غلظت فسفر قابل دسترس خاک مربوط به تیمار کاربرد کمپوست در سطح ۴۵ تن در هکتار بود، با این حال تفاوت غلظت فسفر قابل دسترس خاک در این تیمار با تیمارهای کاربرد بیوجار در سطح ۱۰ و ۱۵ تن در هکتار از نظر آماری معنی‌دار نبود (شکل ۱). افزایش غلظت فسفر قابل دسترس خاک در سه سطح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست در مقایسه با شاهد به‌ترتیب ۱۴/۷، ۱۱۳/۱ و ۱۴۵/۱ درصد بوده و این مقدار افزایش در سه سطح ۵، ۱۰ و ۱۵ تن در هکتار بیوجار نیز به‌ترتیب ۴۴/۱، ۴۴/۴ و ۱۴۳/۳ درصد بود.

همچنین به‌دلیل اکسیداسیون شیمیایی و زیستی و تجزیه مولکول‌های آلی کوچک اصلاح‌کننده‌های آلی مانند بیوجار و کمپوست، کربن آلی محلول خاک افزایش یافته و به‌دنبال آن افزایش فعالیت میکروبی و تولید اسیدهای آلی، می‌تواند در کاهش جزئی pH خاک تیمار شده با اصلاح‌کننده‌های آلی، مؤثر باشد (Amin et al., 2020; Mihoub et al., 2022). انحلال کربنات‌ها و محدود شدن هیدرولیز آن‌ها نیز می‌تواند از دیگر دلایل کاهش pH خاک‌های آهکی تیمار شده با اصلاح‌کننده‌های آلی باشد (Karimi et al., 2026). سایر پژوهشگران نیز کاهش pH خاک‌های آهکی را در اثر کاربرد کمپوست (Luo et al., 2022) و بیوجار (Karimi et al., 2020; Mihoub et al., 2022) گزارش کردند.

نتایج مقایسه میانگین داده‌ها نشان داد تفاوت معنی‌داری بین EC خاک در تیمارهای مختلف وجود نداشت. با وجود این که EC خاک در برخی تیمارها تا حدی کاهش و یا افزایش یافت، اما این تغییرات از نظر آماری معنی‌دار نبود (جدول ۴). با وجود این که در برخی پژوهش‌های پیشین کاهش و یا افزایش EC خاک در اثر کاربرد کمپوست و بیوجار گزارش شده است، اما در این پژوهش تغییرات معنی‌داری مشاهده نشد. این تفاوت در نتایج می‌تواند به‌دلیل شرایط متفاوت پژوهش از جمله ویژگی‌های خاک و اصلاح‌کننده‌های مورد استفاده باشد.

بر اساس نتایج مقایسه میانگین اثر کاربرد همه تیمارهای بیوجار و کمپوست بر کربن آلی خاک نشان داد که کربن آلی خاک در تیمارهای کاربرد بیوجار و کمپوست به‌طور معنی‌داری بیش‌تر (۱/۳۷–۱/۹۶ برابر) از تیمارهای بدون کاربرد بیوجار و کمپوست بود (جدول ۴). تفاوت معنی‌داری بین مقدار کربن آلی خاک در سه تیمار کاربرد کمپوست در سطح ۴۵ تن در هکتار و کاربرد بیوجار در سطح ۱۰ و ۱۵ تن در هکتار



شکل ۱- مقایسه میانگین اثر تیمارهای مختلف بر فسفر قابل دسترس خاک

Figure 1- Mean comparison of treatments effect on soil available P

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C, CO₁₅, CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوچار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅, B₁₀ و B₁₅ به ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوچار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.


کردند کاربرد کمپوست سبب افزایش معنی‌دار غلظت فسفر معدنی قابل دسترس خاک شد. یوان و همکاران (Yuan et al., 2025)، نیز افزایش غلظت فسفر قابل دسترس خاک در اثر کاربرد بیوچارهای تهیه شده از کاه گندم و ذرت در یک خاک آهکی را گزارش کردند.

نتایج مقایسه میانگین داده‌ها نشان داد که در همه سطوح بیوچار و کمپوست غلظت پتاسیم قابل دسترس خاک به‌طور معنی‌داری بیش‌تر از تیمار شاهد بود (شکل ۲). بیش‌ترین غلظت پتاسیم قابل دسترس خاک مربوط به دو تیمار سطوح ۱۰ و ۱۵ تن در هکتار بود که در این دو تیمار پتاسیم قابل دسترس خاک به ترتیب ۴۵/۶ و ۴۸/۷ درصد بیش‌تر از تیمار شاهد بود (شکل ۲). یکی از دلایل افزایش پتاسیم قابل دسترس خاک در اثر کاربرد بیوچار و کمپوست می‌تواند به دلیل آزاد شدن پتاسیم از بیوچار و کمپوست و اضافه شدن آن به خاک باشد. بیش‌تر بودن پتاسیم قابل دسترس خاک در تیمارهای کاربرد بیوچار در مقایسه با تیمارهای کمپوست می‌تواند به دلیل بیش‌تر بودن مقدار پتاسیم بیوچار در مقایسه با کمپوست و احتمالاً اثر بیش‌تر بیوچار بر فعالیت میکروارگانیسم‌های حل‌کننده پتاسیم باشد (جدول ۱). افزایش کربن آلی خاک در اثر کاربرد تیمارهای کمپوست (جدول ۳) و افزایش احتمالی تشکیل اسیدهای آلی و همچنین افزایش فعالیت میکروارگانیسم‌های حل‌کننده پتاسیم در خاک تیمار شده با بیوچار و

به‌طور کلی نتایج نشان‌دهنده تأثیر مثبت و چشم‌گیر کاربرد بیوچار (به‌ویژه تیمارهای B₁₀ و B₁₅) و کمپوست (CO₃₀ و CO₄₅) در افزایش فراهمی فسفر در خاک بود. کاربرد اصلاح‌کننده‌های آلی در خاک، می‌تواند از طریق مکانیسم‌های مختلف فراهمی فسفر را در خاک افزایش دهد (Estrada-Bonilla et al., 2021; Yuan et al., 2025; Adnan et al., 2025). از جمله این‌که مولکول‌های آلی می‌توانند به‌طور اختصاصی توسط مواد معدنی خاک جذب شوند و با فسفر برای مکان‌های جذب رقابت کنند، ماده آلی همچنین می‌تواند روی مکان‌های جذب غیراختصاصی کلوتیدها جذب شود و بار منفی سطح ذرات را افزایش دهد، این عمل، جاذبه الکترواستاتیکی فسفر به خاک را کاهش داده و سبب افزایش غلظت فسفر محلول در خاک می‌شود. مواد آلی در خاک‌های آهکی در اثر واکنش با دی‌کلسیم فسفات رشد کریستال‌های این ترکیب را کاهش داده و سرعت تشکیل اکتاکلسیم فسفات (Ca₈-P) را کاهش می‌دهد. افزون بر این اسیدهای آلی با وزن مولکولی کم (حاصل از تجزیه بیوچار و کمپوست)، می‌توانند از طریق ایجاد کلات با کلسیم، از رسوب فسفر به شکل آپاتیت جلوگیری کنند (Adnan et al., 2025). به‌طور مشابه با نتایج این پژوهش، استرادا-بانیلا و همکاران (Estrada-Bonilla et al., 2021) با انجام مطالعه‌ای در یک خاک تحت کشت نیشکر در برزیل گزارش

از بقایای ذرت در خاک‌های آهکی خوزستان را گزارش کردند. به‌طور مشابه اتر و همکاران (Athar et al., 2025) با انجام پژوهشی گزارش کردند کاربرد کمپوست سبب افزایش پتاسیم قابل دسترس در یک خاک قلیایی شد.

کمپوست و در نتیجه انحلال ترکیبات نامحلول پتاسیم خاک می‌تواند از دیگر دلایل افزایش پتاسیم قابل دسترس خاک در تیمارهای کاربرد بیوجار و کمپوست باشند. کریمی و همکاران (Karimi et al., 2020) نیز افزایش پتاسیم قابل دسترس خاک در اثر کاربرد بیوجار تهیه شده



شکل ۲- مقایسه میانگین اثر تیمارهای مختلف بر پتاسیم قابل دسترس خاک

Figure 2- Mean comparison of treatments effect on soil available K

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C, CO₁₅, CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوجار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅، B₁₀ و B₁₅ به ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوجار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.

جدول ۵- تجزیه واریانس (میانگین مربعات) تأثیر تیمارها بر ویژگی‌های فیزیکی خاک

Table 5- ANOVA (mean squares) for the effects of treatments on soil physical characteristics

منابع تغییرات S.O.V.	درجه آزادی df	میانگین مربعات Mean squares				
		چگالی ظاهری Bulk density	میانگین وزنی قطر خاکدانه Mean weight diameter of aggregates (MWD)	رطوبت ظرفیت مزرعه Field capacity (FC)	رطوبت پژمردگی دائم Permanent wilting point (PWP)	آب قابل دسترس گیاه Plant available water
بلوک Block	2	0.001 ^{ns}	0.002 ^{ns}	0.003 ^{ns}	0.03 ^{ns}	0.006 ^{ns}
تیمار Treatment	6	0.029 ^{**}	0.068 ^{**}	0.068 ^{**}	0.06 ^{ns}	3.798 ^{**}
خطا Error	12	0.001	0.002	0.002	0.011	0.028
ضریب تغییرات C.V (%)		4.72	6.23	5.23	4.12	6.94

^{ns} و ^{**}: به ترتیب غیرمعنی‌دار و معنی‌دار در سطح احتمال ۱ درصد

^{ns} and ^{**}: non-significant and significant at $p \leq 0.01$, respectively.


ویژگی‌های فیزیکی خاک

نتایج تجزیه واریانس داده‌ها نشان داد که اثر تیمار بر ویژگی‌های فیزیکی و هیدرولیکی خاک شامل چگالی ظاهری، میانگین وزنی قطر خاکدانه، رطوبت ظرفیت مزرعه و آب قابل دسترس برای گیاه معنی‌دار بود، در حالی که اثر تیمار بر رطوبت پژمردگی دایم از نظر آماری معنی‌دار نبود (جدول ۵).

میانگین وزنی قطر خاکدانه

نتایج مقایسه میانگین داده‌ها نشان داد که در تمامی سطوح بیوپچار و کمپوست، به جز تیمار کاربرد کمپوست در سطح ۱۵ تن در هکتار، میانگین وزنی قطر خاکدانه به‌طور معنی‌داری بیش‌تر از تیمار شاهد بود (شکل ۳). بیش‌ترین مقدار میانگین وزنی قطر خاکدانه مربوط به دو تیمار B₁₅ و B₁₀ بود و تفاوت معنی‌داری بین این دو تیمار مشاهده نشد. مقدار میانگین وزنی قطر خاکدانه در تیمارهای CO₄₅، CO₃₀، B₅، B₁₀ و B₁₅، به ترتیب ۱۵/۸، ۲۳/۷، ۲۰/۲، ۳۲/۵ و ۳۶/۰ درصد بیش‌تر از این مقدار در تیمار شاهد بود. تأثیر تیمارهای بیوپچار (B₁₀ و B₁₅) در افزایش میانگین وزنی قطر خاکدانه به‌طور معنی‌داری بیش‌تر از تیمارهای کاربرد کمپوست بود (شکل ۳).

تشکیل خاکدانه و پایداری آن، به‌عنوان عوامل مهم در تعیین ساختمان خاک، از جنبه‌های مهم کیفیت فیزیکی خاک هستند



شکل ۳- مقایسه میانگین اثر تیمارهای مختلف بر میانگین وزنی قطر خاکدانه (MWD)

Figure 3- Mean comparison of treatments effect on mean weight diameter of aggregates (MWD)

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C، CO₁₅، CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوپچار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅ و B₁₀ و B₁₅ به‌ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوپچار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.

(Wang et al., 2024). به‌طور کلی کاربرد اصلاح‌کننده‌های آلی در خاک به‌دلایل مختلف از جمله تشکیل خاکدانه‌های پایدار در افزایش پایداری ساختمان خاک مؤثرند. بیوپچار می‌تواند با افزایش کربن آلی خاک از طریق سازوکارهای مختلف سبب افزایش فعالیت میکروبی خاک، افزایش هیف‌های قارچی و تشکیل گلومالین (گلیکوپروتئین مؤثر در پایداری خاکدانه‌ها) توسط قارچ‌های میکوریز و اتصال خاکدانه‌ها در خاک شود. کاربرد بیوپچار می‌تواند خاکدانه‌های درشت (با قطر بیش‌تر از ۲ میلی‌متر) را در خاک افزایش داده و خاکدانه‌های ریز (با قطر کوچک‌تر از ۰/۲۵ میلی‌متر) را در خاک کاهش دهد و بدین ترتیب سبب افزایش میانگین وزنی قطر خاکدانه شود. افزایش میانگین وزنی قطر خاکدانه در اثر کاربرد بیوپچار و کمپوست در خاک‌های با بافت متفاوت توسط سایر پژوهشگران نیز گزارش شده است (Ibrahim et al., 2021; Akpinar et al., 2023). آکپینار و همکاران (Akpinar et al., 2023) با بررسی تأثیر کاربرد بیوپچار تهیه شده از چوب درختان گزارش کردند کاربرد بیوپچار سبب افزایش میانگین وزنی قطر خاکدانه در خاک شد. تأثیر بیوپچار بر میانگین وزنی قطر خاکدانه به ویژگی‌های مختلف خاک، ویژگی‌های بیوپچار و مقدار کاربرد بیوپچار بستگی دارد.

چگالی ظاهری بیوجار مورد استفاده (۰/۲۳ گرم بر سانتی‌متر مکعب) در مقایسه با کمپوست باشد (جدول ۱). بنابراین، افزودن بیوجار به خاک از طریق افزایش سهم ذرات آلی نسبت به معدنی در فاز جامد خاک، سبب کاهش چگالی ظاهری خاک می‌شود. دلیل دیگر کاهش چگالی ظاهری خاک در تیمارهای کاربرد بیوجار و کمپوست، افزایش ماده آلی خاک در اثر کاربرد این تیمارها می‌باشد که سبب بهبود ساختمان خاک، تشکیل خاکدانه‌ها و پایداری آن‌ها می‌گردد و از این طریق چگالی ظاهری خاک کاهش می‌یابد (da Silva Mendes et al., 2021). به‌طور کلی مکانیسم‌های کاهش چگالی ظاهری خاک در اثر کاربرد بیوجار شامل افزایش منافذ درشت خاکدانه‌ها و افزایش حجم منافذ کل در خاک، نفوذ ذرات بیوجار به داخل خاکدانه‌ها و کاهش جرم آن‌ها در واحد حجم و همچنین تشکیل منافذ جدید در خاک در بین ذرات بیوجار و خاک، می‌باشند (Wang et al., 2024). سینگ و همکاران (Singh et al., 2022) با بررسی تأثیر کاربرد بیوجارهای مختلف بر تغییرات چگالی ظاهری خاک گزارش کردند که کاربرد بیوجارهای تهیه شده در دماهای پیرولیز کم و زیاد، به‌طور میانگین چگالی ظاهری خاک را به‌ترتیب ۳۶ و ۱۹ درصد کاهش داد. آن‌ها همچنین گزارش کردند که میان تأثیر بیوجارهای تهیه شده از زیست‌توده‌های مختلف بر چگالی ظاهری خاک، تفاوت معنی‌داری مشاهده نشد. کاهش چگالی ظاهری خاک در اثر کاربرد کمپوست را می‌توان به افزایش حجم منافذ و تخلخل خاک و برهمکنش بین مواد آلی و ذرات خاک نسبت داد، چرا که چگالی کمپوست کم‌تر از خاک می‌باشد (Wang et al., 2024). همچنین بهبود ساختمان خاک و افزایش میانگین وزنی قطر خاکدانه (شکل ۳) از دیگر دلایل کاهش چگالی ظاهری در تیمارهای کاربرد کمپوست باشد. دانگ و همکاران (Dong et al., 2022) با بررسی تأثیر کاربرد کمپوست تهیه شده از بقایای ذرت و کود دامی در یک خاک با بافت لوم گزارش کردند کاربرد کمپوست سبب کاهش معنی‌دار چگالی ظاهری خاک شد.

ضرایب رطوبتی خاک و آب قابل دسترس برای گیاه

نتایج مقایسه میانگین داده‌ها نشان داد که در همه تیمارهای کاربرد بیوجار و کمپوست، به‌جز تیمار کاربرد کمپوست در سطح ۱۵ تن در هکتار، رطوبت ظرفیت مزرعه به‌طور معنی‌داری بیش‌تر از تیمار شاهد بود (شکل ۵). بیش‌ترین مقدار رطوبت ظرفیت مزرعه مربوط به دو تیمار B₁₀ و B₁₅ بود که به‌ترتیب ۱۵/۰ و ۱۳/۹ درصد بیش‌تر از این مقدار در تیمار شاهد بود. نتایج این پژوهش همچنین نشان‌دهنده تأثیر بیش‌تر تیمارهای بیوجار بر افزایش رطوبت ظرفیت مزرعه، در مقایسه با تیمارهای کمپوست بود (شکل ۵).


قربانی و امیراحمدی (Ghorbani & Amirahmadi, 2024) با انجام یک بررسی متا آنالیز گزارش کردند بیش‌ترین تأثیر بیوجار بر میانگین وزنی قطر خاکدانه مربوط به سطح کاربرد ۱۰ تا ۲۰ تن در هکتار بوده است و تأثیر کاربرد سطوح بیش‌تر از ۴۰ تن در هکتار در افزایش میانگین وزنی قطر خاکدانه، کم‌تر از سطوح ۵ تا ۲۰ تن در هکتار بوده است. نتایج این پژوهش نیز نشان داد تیمارهای کاربرد تیمارهای ۱۰ و ۱۵ تن در هکتار بیوجار، بیش‌ترین تأثیر را در افزایش میانگین وزنی قطر خاکدانه داشتند.

کمپوست به‌عنوان یک اصلاح‌کننده از مواد هیومیکی و پلی‌ساکاریدهای برون‌سلولی تشکیل شده است، بنابراین کاربرد کمپوست در خاک، از طریق ایجاد اتصال ذرات معدنی سبب افزایش تشکیل خاکدانه‌های پایدار و کاهش شکستگی و ناپایداری خاکدانه‌ها می‌شود (Sayara et al., 2020; Dong et al., 2022). در واقع تغییرات خاکدانه‌های خاک در اثر کاربرد کمپوست، به‌دلیل سطح ویژه بسیار فعالی است که سبب ایجاد برهمکنش بین میکروآرگانیزم‌های خاک و ریشه‌های موئین گیاه در شرایط بهینه از جمله از نظر رطوبت شده و به‌دنبال آن سبب افزایش پایداری خاکدانه‌های خاک و بهبود ساختمان خاک می‌شود (Sayara et al., 2020). به‌طور مشابه، العمران و همکاران (Al-Omran et al., 2021) با بررسی تأثیر سطوح مختلف کمپوست و بیوجار تهیه شده از برگ‌های نخل بر میانگین وزنی قطر خاکدانه گزارش کردند که کاربرد سطوح مختلف کمپوست و بیوجار سبب افزایش معنی‌دار میانگین وزنی قطر خاکدانه شد. نتایج آن‌ها همچنین نشان داد تأثیر تیمارهای کاربرد بیوجار در افزایش میانگین وزنی قطر خاکدانه به‌طور معنی‌داری بیش‌تر از تیمارهای کاربرد کمپوست بود.

چگالی ظاهری خاک

نتایج مقایسه میانگین داده‌ها نشان داد که در تمامی سطوح بیوجار و کمپوست، چگالی ظاهری خاک کاهش یافت. این کاهش فقط در تیمار کاربرد کمپوست در سطح ۱۵ تن در هکتار از نظر آماری معنی‌دار نبود (شکل ۴). کم‌ترین مقدار چگالی ظاهری مربوط به دو تیمار B₁₀ و B₁₅ بود و تفاوت معنی‌داری بین این دو تیمار مشاهده نشد. مقدار چگالی ظاهری در تیمارهای CO₄₅، CO₃₀، B₅، B₁₀ و B₁₅، به‌ترتیب ۵/۲، ۹/۷، ۸/۴، ۱۴/۹ و ۱۶/۲ درصد کم‌تر از این مقدار در تیمار شاهد بود (شکل ۴).

نتایج این پژوهش نشان داد تیمارهای بیوجار در کاهش چگالی ظاهری خاک، مؤثرتر از تیمارهای کاربرد کمپوست بودند. یکی از دلایل این نتیجه می‌تواند ساختار متخلخل، سطح ویژه زیاد و کم بودن مقدار



شکل ۴- مقایسه میانگین اثر تیمارهای مختلف بر چگالی ظاهری خاک


Figure 4- Mean comparison of treatments effect on soil bulk density

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C, CO₁₅, CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوچار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅، B₁₀ و B₁₅ به ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوچار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.



شکل ۵- مقایسه میانگین اثر تیمارهای مختلف بر رطوبت ظرفیت مزرعه خاک


Figure 5- Mean comparison of treatments effect on soil water content at field capacity (FC)

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند.

C, CO₁₅, CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوچار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅، B₁₀ و B₁₅ به ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوچار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.



شکل ۶- مقایسه میانگین اثر تیمارهای مختلف بر آب قابل دسترس برای گیاه
Figure 6- Mean comparison of treatments effect on plant available water (PAW)

میانگین‌های دارای حروف مشترک در هر ستون بر اساس آزمون دانکن اختلاف معنی‌داری ($P < 0.05$) ندارند. C، CO₁₅، CO₃₀ و CO₄₅: به ترتیب شاهد (بدون کاربرد کمپوست و بیوجار) و تیمارهای سطوح ۱۵، ۳۰ و ۴۵ تن در هکتار کمپوست و B₅، B₁₀ و B₁₅ به‌ترتیب تیمارهای سطوح ۵، ۱۰ و ۱۵ تن در هکتار بیوجار می‌باشند.

Means with similar letter (s) are not significantly different according to the Duncan's test ($p < 0.05$).

C, CO₁₅, CO₃₀ and CO₄₅ are control and compost treatments at 15, 30 and 45 t ha⁻¹ levels respectively and B₅, B₁₀ and B₁₅ are biochar treatments at 5, 10 and 15 t ha⁻¹ levels respectively.

نیمه خشک که دارای محدودیت آب هستند حائز اهمیت است (Bhat et al., 2022).

بیش‌تر بودن تأثیر تیمارهای بیوجار در مقایسه با تیمارهای کمپوست در افزایش آب قابل دسترس برای گیاه (شکل ۶) را می‌توان به سطح ویژه و تخلخل بیش‌تر بیوجار نسبت به کمپوست، نسبت داد (جدول ۲). به‌طور مشابه، کاستلینی و همکاران (Castellini et al., 2025) با بررسی تأثیر کاربرد سه اصلاح‌کننده آلی شامل بیوجار، کمپوست و ورمی‌کمپوست تهیه شده از بقایای گیاهی و کود دامی بر رطوبت ظرفیت مزرعه و آب قابل دسترس برای گیاه گزارش کردند که همه اصلاح‌کننده‌های آلی سبب افزایش رطوبت ظرفیت مزرعه و آب قابل دسترس برای گیاه شدند. نتایج آن‌ها همچنین نشان داد تأثیر کاربرد بیوجار در افزایش رطوبت ظرفیت مزرعه و آب قابل دسترس برای گیاه به‌طور معنی‌داری بیش‌تر از اثر کمپوست و ورمی‌کمپوست بود. به‌طور مشابه لیانگ و همکاران (Liang et al., 2021) تأثیر کاربرد بیوجار (در سطوح، صفر، ۱۰ و ۲۵ تن در هکتار) بر ویژگی‌های فیزیکی و هیدرولیکی یک خاک لوم رسی سیلتی را در شرایط مزرعه‌ای بررسی کردند. نتایج آن‌ها نشان داد کاربرد سطوح مختلف بیوجار سبب افزایش معنی‌دار رطوبت ظرفیت مزرعه و آب قابل دسترس برای گیاه شد. الفادیل و همکاران (Alfadil et al., 2021) نیز با انجام مطالعه مزرعه‌ای گزارش کردند کاربرد سطوح مختلف بیوجار تهیه شده از بقایای ذرت سبب افزایش تخلخل کل خاک و افزایش آب قابل دسترس

نتایج مقایسه میانگین داده‌ها همچنین نشان داد که در همه تیمارهای کاربرد بیوجار و کمپوست، بجز تیمار کاربرد کمپوست در سطح ۱۵ تن در هکتار، آب قابل دسترس برای گیاه (PAW) به‌طور معنی‌داری بیش‌تر از تیمار شاهد بود (شکل ۶). بیش‌ترین مقدار آب قابل دسترس برای گیاه مربوط به دو تیمار B₁₀ و B₁₅ بود که به‌ترتیب ۳۸/۹ و ۳۷/۵ درصد بیش‌تر از این مقدار در تیمار شاهد بود. نتایج این پژوهش همچنین نشان‌دهنده تأثیر بیش‌تر تیمارهای بیوجار در افزایش آب قابل دسترس برای گیاه، در مقایسه با تیمارهای کمپوست بود. به‌طوری‌که آب قابل دسترس برای گیاه در تیمار B₁₀، ۲۱/۷ درصد بیش‌تر از تیمار CO₄₅ و ۲۶/۳ درصد بیش‌تر از تیمار CO₃₀ بود (شکل ۶).

با توجه به این‌که بیوجار ماده‌ای متخلخل و غنی از کربن است که سطح ویژه بالایی دارد، کاربرد آن در خاک می‌تواند با بهبود شبکه منفذی و ویژگی‌های فیزیکی و هیدرولیکی خاک سبب افزایش آب قابل دسترس خاک برای گیاه شود (Gao et al., 2020; Acharya et al., 2024; Wang et al., 2024). سه ویژگی تعیین‌کننده کارایی بیوجار در بهبود مقدار آب قابل دسترس برای گیاه، اندازه ذرات، سطح ویژه و تخلخل هستند، به‌طوری‌که هر چه تخلخل بیوجار بیش‌تر باشد، تأثیر آن بر مقدار آب قابل دسترس برای گیاه افزایش می‌یابد. افزایش آب قابل دسترس برای گیاه در اثر کاربرد بیوجار در خاک، می‌تواند تعداد دورهای آبیاری در مزارع را کاهش دهد. این ویژگی به‌ویژه در مناطق

برای گیاه شد.

نتیجه گیری

نتایج این پژوهش نشان دهنده تأثیر مثبت کاربرد تیمارهای بیوچار (در سطح ۱۰ و ۱۵ تن در هکتار) و کمپوست (در سطح ۳۰ و ۴۵ تن در هکتار) بر ویژگی‌های فیزیکی و شیمیایی خاک و فراهمی آب و عناصر غذایی فسفر و پتاسیم برای گیاه بود. به‌طور کلی تیمارهای کمپوست (سطح ۴۵ تن در هکتار) و بیوچار (سطوح ۱۰ و ۱۵ تن در هکتار) اثر مثبت مشابهی بر ویژگی‌های شیمیایی خاک داشتند، اما تیمارهای بیوچار (در سطح ۱۰ و ۱۵ تن در هکتار) در بهبود وضعیت رطوبتی خاک، فراهمی آب و پتاسیم در خاک برای گیاه بسیار مؤثرتر از تیمارهای کاربرد کمپوست بودند. مقایسه دو تیمار کاربرد بیوچار در سطح ۱۰ و ۱۵ تن در هکتار، نشان داد تفاوت معنی‌داری بین این دو سطح کاربرد بیوچار مشاهده نشد و هر دو تیمار اثرات مثبت مشابهی بر ویژگی‌های فیزیکی و شیمیایی خاک، فراهمی آب برای گیاه داشتند.

به‌طور کلی بر اساس نتایج این پژوهش، می‌توان نتیجه‌گیری کرد که سطح ۱۰ تن در هکتار بیوچار و سطح ۴۵ تن در هکتار کمپوست، مقادیر مناسبی برای بهبود ویژگی‌های شیمیایی خاک در خاک‌های آهکی مزارع نیشکر استان خوزستان هستند. همچنین سطح ۱۰ تن در هکتار بیوچار به‌عنوان مناسب‌ترین تیمار برای بهبود ویژگی‌های فیزیکی خاک و افزایش فراهمی آب برای گیاه نیشکر است. با توجه به کم بودن کربن آلی خاک در مزارع نیشکر و خاک مورد مطالعه و متفاوت بودن ویژگی‌های بیوچار و کمپوست (به‌ویژه ویژگی‌های فیزیکی و ساختار کربن پایداری آن) نیاز است اثرات بلندمدت تیمارها در پژوهش‌های مزرعه‌ای بررسی شود.

سپاسگزاری

نویسندگان مقاله از مؤسسه تحقیقات و آموزش نیشکر خوزستان برای حمایت مالی و مساعدت در مراحل مختلف اجرای این پژوهش، تشکر و قدردانی می‌کنند.

References

- Acharya, B.S., Dodla, S., Wang, J.J., Pavuluri, K., Darapuneni, M., Dattamudi, S., Maharjan, B., & Kharel, G. (2024). Biochar impacts on soil water dynamics: knowns, unknowns, and research directions. *Biochar*, 6(1), 34. <https://doi.org/10.1007/s42773-024-00323-4>
- Adetunji, A.T., & Blanco-Canqui, H. (2026). Soil health response to biochar combined with other amendments: a review. *Biochar*, 8(1), 23. <https://doi.org/10.1007/s42773-025-00531-6>
- Adnan, M., Fahad, S., Saleem, M.H., & Lal, R. (2025). Sustainable phosphorus management in calcareous soils: problems and prospects. *Journal of Plant Nutrition*, 48(13), 2179-2200. <https://doi.org/10.1080/01904167.2025.2477269>
- Akpınar, D., Tian, J., Shepherd, E., & Imhoff, P.T. (2023). Impact of wood-derived biochar on the hydrologic performance of bioretention media: Effects on aggregation, root growth, and water retention. *Journal of Environmental Management*, 339, 117864. <https://doi.org/10.1016/j.jenvman.2023.117864>
- Albalasmeh, A.A., Quzaih, M.Z., Gharaibeh, M.A., Rusan, M., Mohawesh, O.E., Rababah, S.R., Alqudah, A., Alghamdi, A.G., & Naserin, A. (2024). Significance of pyrolytic temperature, application rate and incubation period of biochar in improving hydro-physical properties of calcareous sandy loam soil. *Scientific Reports*, 14(1), 7012. <https://doi.org/10.1038/s41598-024-57755-y>
- Alfakil, A.A., Shaghaleh, H., Alhaj Hamoud, Y., Xia, J., Wu, T., Hamad, A.A.A., Wang, Y., Oumarou Abdoulaye, A., & Sheteiwy, M.S. (2021). Straw biochar-induced modification of the soil physical properties enhances growth, yield and water productivity of maize under deficit irrigation. *Communications in Soil Science and Plant Analysis*, 52(16), 1. <https://doi.org/10.1080/00103624.2021.1901913>
- Al-Omran, A., Ibrahim, A., & Alharbi, A. (2021). Effects of biochar and compost on soil physical quality indices. *Communications in Soil Science and Plant Analysis*, 52(20), 2482-2499. <https://doi.org/10.1080/00103624.2021.1949461>
- Amin, A.E.E.A.Z. (2020). Carbon sequestration, kinetics of ammonia volatilization and nutrient availability in alkaline sandy soil as a function on applying calotropis biochar produced at different pyrolysis temperatures. *Science of the Total Environment*, 726, 138489. <https://doi.org/10.1016/j.scitotenv.2020.138489>
- Athar, M., Fatima, S., Zahra, A., Shah, M.A., Bashir, S., Seleiman, M.F., & Ali, N. (2025). Optimizing wheat growth and zinc uptake with compost and rice husk in alkaline conditions. *BMC Plant Biology*, 25(1), 502. <https://doi.org/10.1186/s12870-025-06537-3>
- Azim, R., Wang, Q., Sadiq, M., Zhou, X., Zhang, D., Zhao, X., Xu, Y., Sun, Y., Qi, W., Zhu, J., & Ahmed, S. (2024). Exploring the potential of straw and biochar application on soil quality indicators and crop yield in semi-arid regions. *Journal of Soil Science and Plant Nutrition*, 24(2), 1907-1923. <https://doi.org/10.1007/s42729-024-01668-2>
- Bhat, A.S., Kuriqi, A., Dar, M.U.D., Bhat, O., Sammen, S.S., Towfiqul Islam, A.R.M., Elbeltagi, A., Shah, O., Ai-Ansari, N., Ali, R., & Heddami, S. (2022). Application of biochar for improving physical, chemical, and hydrological

- soil properties: a systematic review. *Sustainability*, 14(17), 11104. <https://doi.org/10.3390/su141711104>
12. Castellini, M., Bondi, C., Leogrande, R., Giglio, L., Vitti, C., Mastrangelo, M., & Bagarello, V. (2025). Evaluating the effects of compost, vermicompost, and biochar on physical quality of sandy-loam soils. *Applied Sciences*, 15(6), 3392. <https://doi.org/10.3390/app15063392>
13. Da Silva Mendes, J., Fernandes, J.D., Chaves, L.H.G., Guerra, H.O.C., Tito, G.A., & de Brito Chaves, I. (2021). Chemical and physical changes of soil amended with biochar. *Water, Air, & Soil Pollution*, 232(8), 338. <https://doi.org/10.1007/s11270-021-05289-8>
14. Danielson, R.E., & Sutherland, P.L. (1986). Porosity. In: A. Klute, (ed.), *Methods of Soil Analysis*. Part 1, Physical and Mineralogical Methods SSSA and ASA, Madison, WI, 443–461. <https://doi.org/10.2136/sssabookser5.1.2ed.c18>
15. Dong, L., Zhang, W., Xiong, Y., Zou, J., Huang, Q., Xu, X., Ren, P., & Huang, G. (2022). Impact of short-term organic amendments incorporation on soil structure and hydrology in semiarid agricultural lands. *International Soil and Water Conservation Research*, 10(3), 457–469. <https://doi.org/10.1016/j.iswcr.2021.10.003>
16. Enebe, M.C., Ray, R.L., & Griffin, R.W. (2025). The impacts of biochar on carbon sequestration, soil processes, and microbial communities: A review. *Biochar*, 7(1), 107. <https://doi.org/10.1007/s42773-025-00499-3>
17. Estrada-Bonilla, G.A., Durrer, A., & Cardoso, E.J. (2021). Use of compost and phosphate-solubilizing bacteria affect sugarcane mineral nutrition, phosphorus availability, and the soil bacterial community. *Applied Soil Ecology*, 157, 103760. <https://doi.org/10.1016/j.apsoil.2020.103760>
18. Gao, Y., Shao, G., Lu, J., Zhang, K., Wu, S., & Wang, Z. (2020). Effects of biochar application on crop water use efficiency depend on experimental conditions: A meta-analysis. *Field Crops Research*, 249, 107763. <https://doi.org/10.1016/j.fcr.2020.107763>
19. Ghorbani, M., & Amirahmadi, E. (2024). Insights into soil and biochar variations and their contribution to soil aggregate status—A meta-analysis. *Soil and Tillage Research*, 244, 106282. <https://doi.org/10.1016/j.still.2024.106282>
20. Ghorbani, M., Neugschwandtner, R.W., Konvalina, P., Asadi, H., Kopecký, M., & Amirahmadi, E. (2023). Comparative effects of biochar and compost applications on water holding capacity and crop yield of rice under evaporation stress: A two-years field study. *Paddy and Water Environment*, 21(1), 47–58. <https://doi.org/10.1007/s10333-022-00912-8>
21. Haufiku, A.M., Ausiku, P.A., & Huttunen, S. (2025). The role of organic and inorganic soil amendments on soil physicochemical properties and wheat (*Triticum aestivum* L.) agronomic performance in Semi-arid North-Central Namibia: A Review. *Discover Agriculture*, 3(1), 215. <https://doi.org/10.1007/s44279-025-00383-5>
22. Helmke, P.A., & Sparks, D.L. (1996). Lithium, sodium, potassium, rubidium, and cesium. In: D.L. Sparks (ed.), *Methods of soil analysis: Part 3, chemical methods*, SSSA and ASA, Madison, WI, 5, 551–574. <https://doi.org/10.2136/sssabookser5.3.c19>
23. Ibrahim, A., Marie, H.A.M., & Elfaki, J. (2021). Impact of biochar and compost on aggregate stability in loamy sand soil. *Agricultural Research Journal*, 58(1), 34–44. <https://doi.org/10.5958/2395-146X.2021.00005.3>
24. Karimi, A., Moezzi, A., Chorom, M., & Enayatizamir, N. (2020). Application of biochar changed the status of nutrients and biological activity in a calcareous soil. *Journal of Soil Science and Plant Nutrition*, 20(2), 450–459. <https://doi.org/10.1007/s42729-019-00129-5>
25. Karimi, A., Zakavi, N., Safirzadeh, S., Noroozi, H., & Ariz, A. (2024a). Evaluation of sugarcane nutritional status by deviation from optimum percentage (DOP) method in Khuzestan province. *Iranian Journal of Soil and Water Research*, 55(3), 449–466. (In Persian with English abstract). <https://doi.org/10.22059/ijswr.2024.371718.669657>
26. Karimi, A., Zanganeh-Yusefabadi, E., & Safirzadeh, S. (2024b). Comparison of availability and uptake of phosphorus and potassium in sugarcane under subsurface drip irrigation and furrow irrigation. *Irrigation Sciences and Engineering*, 47(3), 57–67. (In Persian with English abstract). <https://doi.org/10.22055/jise.2024.43784.2078>
27. Karimi, A., Moezzi, A., Chorom, M., & Enayatizamir, N. (2026). Impact of acidified biochar on soil fertility, growth and nutrient uptake of maize in calcareous soil. *Discover Soil*, 3, 23. <https://doi.org/10.1007/s44378-026-00183-3>
28. Khajavi-Shojaei, S., Moezzi, A., Norouzi Masir, M., & Taghavi, M. (2024). Characteristics of conocarpus wastes and common reed biochars as a predictor of potential environmental and agronomic applications. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 46(1), 10414–10431. <https://doi.org/10.1080/15567036.2020.1783396>
29. Khaji, P., Moezzi, A., Enayatizamir, N., Moradi, N., & Karimi, A. (2025). Effects of modified biochars on some biological and chemical properties of calcareous soil. *Iranian Journal of Soil and Water Research*, 56(2), 373–388. (In Persian with English abstract). <https://doi.org/10.22059/ijswr.2024.384714.669826>
30. Kirkham, M. (2014). Field capacity, wilting point, available water, and the non-limiting water range. In: K. Sonnack, (ed.). *Principles of Soil Plant Water Relations*. Dana Dreibelbisplace. Kansas State University, pp. 101–115. <https://doi.org/10.1016/B978-012409751-3/50008-6>
31. Kroetsch, D., & Wang, C. (2008). Particle Size Distribution. In: M.R. Carter, & E.G. Gregorich (ed.), *Soil Sampling and Methods of Analysis*, Taylor & Francis Group, Boca Raton, 713–725. <https://doi.org/10.1201/9781420005271.ch55>

32. Le Bissonnais, Y.L. (1996). Aggregate stability and assessment of soil crust ability and erodibility: I. Theory and methodology. *European Journal of Soil Science*, 47(4), 425-437. <https://doi.org/10.1111/j.1365-2389.1996.tb01843.x>
33. Liang, J., Li, Y., Si, B., Wang, Y., Chen, X., Wang, X., Chen, H., Wang, H., Zhang, F., Bai, Y., & Biswas, A. (2021). Optimizing biochar application to improve soil physical and hydraulic properties in saline-alkali soils. *Science of the Total Environment*, 771, 144802. <https://doi.org/10.1016/j.scitotenv.2020.144802>
34. Luo, T., Lu, W., Chen, L., Min, T., Ru, S., Wei, C., & Li, J. (2022). The effects of acidic compost tea on activation of phosphorus, Fe, Zn, and Mn in calcareous soil and cotton (*Gossypium hirsutum* L.) growth in Xinjiang, China. *Journal of Soil Science and Plant Nutrition*, 22(3), 3822-3834. <https://doi.org/10.1007/s42729-022-00933-6>
35. Mihoub, A., Amin, A.E.E.A.Z., Motaghian, H.R., Saeed, M.F., & Naeem, A. (2022). Citric acid (CA)-modified biochar improved available phosphorus concentration and its half-life in a P-fertilized calcareous sandy soil. *Journal of Soil Science and Plant Nutrition*, 22(1), 465-474. <https://doi.org/10.1007/s42729-021-00662-2>
36. Moradi, N., & Karimi, A. (2020). Effect of corn stover-modified biochar on some biological properties of a Cd-contaminated calcareous soil. *Journal of Soil Management and Sustainable Production*, 9(4), 127-144. (In Persian with English abstract). <https://doi.org/10.22069/ejsms.2020.16591.1888>
37. Murphy, J.A.M.E.S., & Riley, J.P. (1962). A modified single solution method for the determination of phosphate in natural waters. *Analytica Chimica Acta*, 27, 31-36. [https://doi.org/10.1016/S0003-2670\(00\)88444-5](https://doi.org/10.1016/S0003-2670(00)88444-5)
38. Nelson, D.W., & Sommers, L.E. (1982). Total carbon, organic carbon, and organic matter. *Methods of soil analysis: Part 2, chemical and microbiological properties*, SSSA and ASA, Madison, WI, 539-579. <https://doi.org/10.2134/agronmonogr9.2.2ed.c29>
39. Olsen, S.R., Cole, C.V., Watanabe, E.S., & Dean, L.A. (1954). *Estimation of available phosphorus in soils by extraction with sodium bicarbonate*. United States Department of Agriculture Circular, 939, 1-18.
40. Piccolo, A., & Drosos, M. (2025). The essential role of humified organic matter in preserving soil health. *Chemical and Biological Technologies in Agriculture*, 12(1), 21. <https://doi.org/10.1186/s40538-025-00730-0>
41. Rayment, G.E., & Higginson, F.R. (1992). *Australian laboratory handbook of soil and water chemical methods*. Inkata Press: Melbourne.
42. Rhoades, J. (1982). Soluble salts. In: A.L. Page (ed.), *Methods of soil analysis*, Part 2, Chemical and microbiological properties, SSSA and ASA, Madison, WI, 167-179. <https://doi.org/10.2134/agronmonogr9.2.2ed.c10>
43. Sayara, T., Basheer-Salimia, R., Hawamde, F., & Sánchez, A. (2020). Recycling of organic wastes through composting: Process performance and compost application in agriculture. *Agronomy*, 10(11), 1838. <https://doi.org/10.3390/agronomy10111838>
44. Sharma, S., Yost, M.A., & Reeve, J.R. (2025). Roles of organic agriculture for water optimization in arid and semi-arid regions. *Sustainability*, 17(12), 5452. <https://doi.org/10.3390/su17125452>
45. Singh, B., Camps-Arbestain, M., & Lehmann, J. (2017). *Biochar: a guide to analytical methods*. Csiro Publishing. <https://doi.org/10.1071/9781486305100>
46. Singh, H., Northup, B.K., Rice, C.W., & Prasad, P.V. (2022). Biochar applications influence soil physical and chemical properties, microbial diversity, and crop productivity: a meta-analysis. *Biochar*, 4(1), 8. <https://doi.org/10.1007/s42773-022-00138-1>
47. Wang, D., Li, S., Sun, X., Hao, D., Li, Y., & Wang, H. (2024). Effects of compost application of green waste on soil properties: A meta-analysis. *Sustainability*, 16(20), 8877. <https://doi.org/10.3390/su16208877>
48. Xiao, L., Lin, Y., Chen, D., Zhao, K., Wang, Y., You, Z., Zhao, R., Xie, Z., & Liu, J. (2024). Maximizing crop yield and water productivity through biochar application: A global synthesis of field experiments. *Agricultural Water Management*, 305, 109134. <https://doi.org/10.1016/j.agwat.2024.109134>
49. Yuan, Q., Gao, Y., Ma, G., Wu, H., Li, Q., Zhang, Y., Liu, S., Jie, X., Zhang, D., & Wang, D. (2025). The long-term effect of biochar amendment on soil biochemistry and phosphorus availability of calcareous soils. *Agriculture*, 15(5), 458. <https://doi.org/10.2139/ssrn.4440742>
50. Zanganeh-Yusefabadi, E., Karimi, A., Sheini-Dashtegol, A., Naseri, A., & Zarei, S. (2024). Changes in soil salinity and sodicity under subsurface drip irrigation and furrow irrigation of sugarcane. *Irrigation and Drainage Structures Engineering Research*, 24(93), 59-43. <https://doi.org/10.31579/2637-8914/089>
51. Zhang, Y., Liu, Q., Du, Z., Wang, Z., Chen, Y., Li, Y., Jin, J., & Sun, K. (2026). Decadal straw and biochar amendments in calcareous soils: Contrasting abiotic retention and biotic mineralization processes shape phosphorus availability. *Soil and Tillage Research*, 257, 106931. <https://doi.org/10.1016/j.still.2025.106931>

Contents

Assessing the Effect of Sampling Distance on the Spatial Structure of Available Potassium in the Agricultural Soils of Shahrekord Plain	529
M. Barati Zanyani, M.H. Salehi, A. Hossienpur, A. Jafari	
Agroclimatic Zoning of Iran Based on Barley (<i>Hordeum vulgare</i> L.) Planting Date and Length of Growing Period Using Advanced Spatial Analysis Methods	539
Kh. Ahmadaali, M. Kazempour, E. Fazli, A. Liaghat, I. Hajirad	
Monthly Rainfall Simulation Using Hybrid Machine Learning Models: NAMAK Lake Basin	553
A. DalirGabrabad, M.A. Abdollahi, A. Ashrafzadeh	
Depth Assessment of Soil Properties Using an Integrated Effect Size-Based and Multivariate Approach (Case Study: Razavi Khorasan Province)	573
N. Mazloom– M. Zangiabadi	
Reliability Assessment of Gridded SPEI (SPEIbase) in Iran's Catchments	589
N. Poodineh, H. Nazaripour, M. Khosravi	
Impact of Biochar and Compost Application on Soil Physical and Chemical Characteristics and Water Availability for Sugarcane Plant	609
A. Karimi, E. Zangeneh-Yusefabadi	

WATER AND SOIL

(AGRICULTURAL SCIENCES AND TECHNOLOGY)

Vol . 39

No. 6

Feb.-Mar 2026

Published by: Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

Manager in Charge: Valizadeh, R. (Ruminant Nutrition) Prof., Ferdowsi University of Mashhad

Editor in Chief: Fotovat, A. (Soil Science) Prof., Ferdowsi University of Mashhad

Editorial Board:

Alizadeh, A.	Irrigation and Drainage	Ferdowsi University of Mashhad
Bazrafshan, J.	Agricultural Meteorology	Faculty of Agricultural Engineering and Technology
Fotovat, A.	Soil Science	Ferdowsi University of Mashhad
Ghadiri, H.	Soil Science	Griffith University
Khorassani, R.	Soil Science	Ferdowsi University of Mashhad
Khormali, F.	Soil Science	Agricultural Sciences & Natural Resources University of Gorgan
Lakzian, A.	Soil Science	Ferdowsi University of Mashhad
Liaghat, A.	Irrigation and Drainage	University of Tehran
Mosaedi, A.	Irrigation and Civil Eng.	Ferdowsi University of Mashhad
Mousavi Baygi, M	Agricultural Meteorology	Ferdowsi University of Mashhad
Oustan, Sh.	Soil Science	Tabriz University
Taghvaeian, S.	Irrigation	Oklahoma University

Publisher: Ferdowsi University of Mashhad

Address: Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

P.O. Box: 91775- 1163

Fax: +98 51 8787430

E-Mail: jswa3@um.ac.ir

Web Site: <https://jsw.um.ac.ir/>

Journal of Water and Soil is published bimonthly (six issues per year).



Vol. 39 No. 6

2026

Journal of **Water and Soil** (Agricultural Science and Technology)

ISSN:2008-4757

Contents

- Assessing the Effect of Sampling Distance on the Spatial Structure of Available Potassium in the Agricultural Soils of Shahrekord Plain..... 529**
M. Barati Zanyani, M.H. Salehi, A. Hossienpur, A. Jafari
- Agroclimatic Zoning of Iran Based on Barley (*Hordeum vulgare* L.) Planting Date and Length of Growing Period Using Advanced Spatial Analysis Methods 539**
Kh. Ahmadaali, M. Kazempour, E. Fazli, A. Liaghat, I. Hajirad
- Monthly Rainfall Simulation Using Hybrid Machine Learning Models: NAMAK Lake Basin 553**
A. DalirGabrabad, M.A. Abdollahi, A. Ashrafzadeh
- Depth Assessment of Soil Properties Using an Integrated Effect Size-Based and Multivariate Approach (Case Study: Razavi Khorasan Province) 573**
N. Mazloom– M. Zangiabadi
- Reliability Assessment of Gridded SPEI (SPEIbase) in Iran's Catchments 589**
N. Poodineh, H. Nazaripour, M. Khosravi
- Impact of Biochar and Compost Application on Soil Physical and Chemical Characteristics and Water Availability for Sugarcane Plant 609**
A. Karimi, E. Zangeneh-Yusefabadi