



Study of the spatial changes subsidence of Damghan plain and its prediction using artificial neural network model

Reza Ashouri¹ , Samad Emamgholizadeh² , Hooman Haji Kandy³ , Saeed Jamali³ 

¹ Ph.D. Student of Water Management, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: reza.ashouri1400@gmail.com

² Corresponding Author, Professor, Department of Water and Environmental Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Shahrood, Iran. Email: s_gholizadeh517@Shahroodut.ac.ir

³ Assistant Professor, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: hoo.haji_kandi@iauctb.ac.ir

³ Assistant Professor, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. E-mail: sae.jamali@iauctb.ac.ir

ABSTRACT

Introduction

Indiscriminate exploitation of groundwater has caused a decrease in the groundwater level and as a result, has caused land subsidence in many areas. This problem is especially visible in arid and semi-arid regions like Iran, where water supply for agriculture, drinking, and industry is done from groundwater water sources, and in recent years, it has seriously threatened the aquifers of the plains as a serious danger. In this research, due to the importance of the problem, land subsidence in the Damghan Plain aquifer located in Semnan province was studied and investigated.

Methods

In this research, the amount of subsidence was measured at the field, and then its spatial changes were investigated using conventional methods such as Kriging interpolation, Co-kriging, and inverse distance weighted interpolation (IDW). Also, the artificial neural network model was used to estimate and interpolate the amount of subsidence. Three statistical indices namely the coefficient of correlation (R^2), the root mean square error (RMSE), and the mean absolute error (MAE) were used to compare the estimation of subsidence values using an artificial neural network model, kriging interpolation method, cokriging, and IDW. To perform interpolation using kriging, cokriging, and IDW interpolation methods, the variogram of land subsidence data was drawn. Also, in order to increase the accuracy of the mentioned models in predicting the amount of subsidence, the auxiliary variable of water level reduction was used.

Results and discussion

Results show that the Gaussian function with segment-to-threshold ratio ($C_0/(C_0+C)$) equal to 0.26 has better performance compared to other models. Also, the artificial neural network has a better performance compared to the kriging method and the inverse weighted distance method and has been able to reduce the RMSE error value in the validation stage by 17.6% and 31.3%, respectively. It has also increased the value of the R^2 from 0.502 and 0.421 to 0.721. In this case, the comparison between the estimation of subsidence values using the artificial neural network model compared to the interpolation method of kriging, cokriging, and IDW shows that the artificial neural network model with a coefficient of determination (R^2) of 0.860 and 0.751 and 0.015 and 0.017, has a better performance compared to the mentioned methods and reduce the amount of prediction error. Therefore, the artificial neural network model can be used with good accuracy as an alternative method instead of conventional interpolation methods to investigate the spatial changes of land subsidence.

Conclusion

The research results showed:

Compared to circular, spherical, exponential, and linear functions, the Gaussian function can better estimate the spatial changes of land subsidence. The results of the kriging method were better than the inverse distance weighted (IDW) method. The artificial neural network model with Gauss function and two intermediate layers has better performance than other transfer models such as sigmoid, hyperbolic tangent, and hyperbolic Bode secant. The use of artificial neural network model has increased the accuracy of land subsidence estimation compared to conventional methods such as the kriging method and inverse weighted distance method.

Keywords: Modeling, Subsidence, Interpolation, Artificial Neural Network

Article Type: Research Article

Article history: Received: 04 October 2023 Revised: 23 November 2023 Accepted: 12 December 2023 ePublished: 15 December 2023

Cite this article: Ashouri, R., Emamgholizadeh, Haji Kandy, H., & Jamali, S. (2023). Prediction of the scour depth of bridge pier using artificial neural network model and comparison with empirical equations, *Advanced Technologies in Water Efficiency*, 3(3), 68-87. DOI: 10.22126/ATWE.2023.9801.1065

Publisher: Razi University

© The Author(s).





بررسی تغییرات مکانی فرونشست دشت دامغان و پیش‌بینی آن با استفاده مدل شبکه عصبی

مصنوعی

رضا آشوری^۱، صمد امامقلی زاده^۲، هومن حاجی کندی^۳، سعید جمالی^۳

^۱ دانشجوی دکتری منابع آب، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه آزاد تهران مرکزی، تهران، ایران. رایانامه: reza.ashouri1400@gmail.com

^۲ نویسنده مسئول، استاد گروه آب و محیط‌زیست، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران. رایانامه:

s_gholizadeh517@shahroodut.ac.ir

^۳ استادیار، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه آزاد تهران مرکزی، تهران، ایران. رایانامه: hoo.haji_kandi@iauctb.ac.ir

^۳ استادیار، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه آزاد تهران مرکزی، تهران، ایران. رایانامه: jamali@iauctb.ac.ir

چکیده

فرونشست زمین در اثر بهره‌برداری بی‌رویه از آب‌های زیرزمینی و در نتیجه کاهش تراز سطح آب زیرزمینی در بسیاری از مناطق جهان از جمله ایران به‌عنوان یک خطر جدی آبخوان‌های دشت‌ها را مورد تهدید جدی قرار داده است. در این تحقیق با توجه به اهمیت مسئله، فرونشست زمین در آبخوان دشت دامغان واقع در استان سمنان مورد مطالعه و بررسی قرار گرفت. بدین منظور، مقدار فرونشست به‌صورت میدانی در محل پیژومترها اندازه‌گیری گردید و سپس تغییرات مکانی آن با استفاده از روش‌های مرسوم مانند روش درون‌یابی کریجینگ، کو کریجینگ، درون‌یابی وزنی معکوس فاصله (IDW) مورد بررسی قرار گرفت. همچنین از مدل شبکه عصبی مصنوعی برای برآورد و درون‌یابی مقدار فرونشست مورد استفاده قرار گرفت. مقایسه بین برآورد مقادیر فرونشست با استفاده از مدل شبکه عصبی مصنوعی در مقایسه با روش درون‌یابی کوکریجینگ و IDW نشان می‌دهد که مدل شبکه عصبی مصنوعی با ضریب تبیین 0.721 و همچنین مقدار خطای RMSE برابر 0.17 متر، در مرحله صحت سنجی توانسته است عملکرد بهتری در مقایسه با روش‌های کوکریجینگ و IDW با مقدار خطای RMSE برابر با 0.31 و 0.37 متر داشته باشد. استفاده از مدل شبکه عصبی مصنوعی مقدار خطای RMSE را در مقایسه با دو روش کوکریجینگ و IDW به ترتیب $46/3\%$ و $54/4\%$ درصد کاهش داده است. لذا مدل شبکه عصبی مصنوعی می‌تواند با دقت مناسبی به‌عنوان روش جایگزین به‌جای روش‌های مرسوم درون‌یابی یادشده برای بررسی تغییرات مکانی فرونشست زمین مورد استفاده قرار گیرد.

واژه‌های کلیدی: مدل‌سازی، فرونشست، شبکه عصبی مصنوعی، درون‌یابی

نوع مقاله: مقاله پژوهشی

سابقه مقاله: دریافت: ۱۲ مهر ۱۴۰۲ اصلاح: ۰۲ آذر ۱۴۰۲ پذیرش: ۲۱ آذر ۱۴۰۲ چاپ الکترونیکی: ۲۴ آذر ۱۴۰۲

استناد: آشوری، ر، امامقلی زاده، ص،، حاجی کندی، ه، و جمالی، س. (۱۴۰۲). بررسی تغییرات مکانی فرونشست دشت دامغان و پیش‌بینی آن با استفاده مدل شبکه عصبی مصنوعی، فناوری‌های پیشرفته در بهره‌وری آب، ۳(۳)، ۶۸-۸۷، شناسه دیجیتال: 10.22126/ATWE.2023.9801.1065



© نویسندگان.

ناشر: دانشگاه رازی

مقدمه

برداشت از آب زیرزمینی برای مصارف مختلف مانند کشاورزی، صنعت و شرب انجام می‌گردد. در سال‌های اخیر، در دشت‌هایی که مقدار برداشت بیشتر از مقدار تغذیه بوده است، سطح سفره‌های آب زیرزمینی کاهش یافته است. پایین رفتن سطح سفره‌های آب زیرزمینی و بحرانی شدن وضعیت منابع آب در دشت‌ها یکی از بزرگ‌ترین و چالشی‌ترین مشکلات بخش زیست‌محیطی در آینده بسیار نزدیک خواهد شد. در حال حاضر قسمت اعظم مصارف آب استحصالی در بسیاری از کشورها به بخش کشاورزی اختصاص دارد. در اثر کاهش سطح آب زیرزمینی، مشکلات عدیده‌ای در دشت‌ها شاهد خواهیم بود که می‌توان به از دست رفتن آبخوان در اثر فرونشست، از بین رفتن سازه‌های زیربنایی مانند جاده‌ها، راه‌آهن، ساختمان و ... اشاره نمود (خورشید دوست و همکاران^۱، ۲۰۱۷).

هم‌زمان با افزایش رشد جمعیت و همچنین صنعتی شدن جوامع بین سال‌های ۱۹۵۰ تا ۱۹۷۰، خطر فرونشست زمین در اثر پایین افتادن تراز سطح آب زیرزمینی مطرح شده است (والتام^۲، ۱۹۸۹). این مشکل بخصوص در مناطق خشک و نیمه‌خشک مانند ایران که تأمین آب کشاورزی، شرب و صنعت توسط آب زیرزمینی انجام می‌شود، به‌عنوان یک خطر جدی مطرح است، چراکه بهره‌برداری بیش‌ازحد منابع آب زیرزمینی در این دشت‌ها موجب تشدید فرونشست زمین شده است (تورانی و همکاران، ۱۳۹۷). پدیده فرونشست زمین در دشت‌های مختلف کشور از جمله دشت رفسنجان (تورانی و همکاران، ۱۳۹۷)، دشت ورامین (قوامی جمال و همکاران، ۱۴۰۱)، دشت مشهد (قره‌چلو، ۱۴۰۰)، استان فارس (گلیان و همکاران^۳، ۲۰۲۱)، جنوب دشت تهران (محمودپور و همکاران^۴، ۲۰۱۶)، دشت کاشان (قاضی فرد و همکاران، ۲۰۱۶)، دشت قزوین (بابایی و همکاران^۵، ۲۰۲۰)، دشت اراک (رجبی و قربانی^۶، ۲۰۱۶) گزارش شده است. برای مثال در دشت کرمان، کاهش حدود ۲۵ متری سطح آب زیرزمینی موجب فرونشست زمین به مقدار ۱۵ سانتی‌متر در سال شده است (تورانی و همکاران، ۱۳۹۷).

مبانی نظری و پیشینه پژوهش

کالانتري و همکاران (۱۳۹۹) به ارزیابی فرونشست دشت ملارد و شهریار در اثر برداشت آب زیرزمینی پرداختند. آن‌ها در تحقیق خود تأثیر فرونشست را بر سازه‌های زیربنایی در منطقه مورد مطالعه مورد ارزیابی قرار دادند. اغلب ویژگی‌های محیطی دارای پراکنشی پیوسته می‌باشند. از طرفی عملاً به دلیل اینکه امکان اندازه‌گیری و نمونه‌برداری به دلیل ایجاد هزینه زیاد امکان‌پذیر نیست، در این‌گونه موارد جهت توصیف و نمایش تغییرات پارامتر مورد نظر در نقاطی که اندازه‌گیری صورت نگرفته است، می‌توان از اطلاعات اندازه‌گیری شده در سایر نقاط مقدار آن‌ها را برآورد نمود. درون‌یابی فضایی^۷ که خود می‌تواند شامل درون‌یابی زمین‌آماری^۸ و درون‌یابی قطعی^۹ باشد، روشی برای تخمین داده‌ها در ناحیه پیوسته و پیش‌بینی نقاط ناشناخته (اطلاعاتی که گم‌شده است و یا نمی‌توان آن را به دست آورد) با استفاده از داده‌های مشاهداتی موجود است. درون‌یابی زمین‌آماری شامل درون‌یابی کریجینگ معمولی (OK)، درون‌یابی ساده کریجینگ (SK) و درون‌یابی جهانی کریجینگ (UK) است. درون‌یابی قطعی شامل درون‌یابی چندجمله‌ای جهانی (GPI)، درون‌یابی چندجمله‌ای محلی، درون‌یابی وزنی بافاصله معکوس (IDW)، درون‌یابی اسپلاین مسطح و درون‌یابی چندجمله‌ای محلی (LPI) است (لام^{۱۰}، ۱۹۸۳؛ میتاس و میتاسوا^{۱۱}، ۱۹۹۹).

¹ Khorshiddoust et al

² Waltham

³ Golian et a

⁴ Mahmoudpour et al

⁵ Babae et al

⁶ Rajabi & Ghorbani

⁷ Spatial interpolation

⁸ Geo-statistical interpolation

⁹ deterministic interpolation

¹⁰ Lam

¹¹ Mitas & Mitasova

اندازه‌گیری فرونشست یکی از پارامترهای مهم در علوم مهندسی است که معمولاً در یک منطقه مورد مطالعه به دلیل گستردگی و وسعت زیاد منطقه (دشت) و در نتیجه نیاز به هزینه خیلی زیاد، اندازه‌گیری آن در تمام نقاط امکان‌پذیر نیست. به عبارتی نمی‌توان مقدار آن را به صورت میدانی اندازه‌گیری کرد. در این گونه موارد می‌توان از روش زمین‌آمار که شاخه‌ای از علم آمار کاربردی است، جهت تخمین آماری پارامتر فرونشست در نقاطی که اندازه‌گیری صورت نگرفته است، استفاده کرد.

بررسی مطالعات سایر محققین نشان می‌دهد که تا به حال مطالعاتی مختلفی در ارتباط با اندازه‌گیری میدانی فرونشست، استفاده از روش سنجش از راه دور و استفاده از سیستم اطلاعات جغرافیایی انجام شده است. برای مثال می‌توان به تحقیق آروین و همکاران (۱۳۹۸) اشاره نمود. آن‌ها با استفاده از سنجش از دور و سیستم اطلاعات جغرافیایی، مدل‌سازی مکانی فرونشست زمین را در دشت میناب در استان هرمزگان مورد بررسی قرار دادند. آن‌ها بیان داشتند در این دشت، به دلیل کاهش بارش در سال‌های اخیر و همچنین خشک‌سالی‌های متوالی و محدودیت منابع آب سطحی، به دلیل برداشت بی‌رویه از آب زیرزمینی و حفاری بی‌رویه چاه‌ها موجب شده است که تعادل آبخوان منطقه مورد مطالعه به هم خورده و این امر موجب پایین رفتن سطح آب زیرزمینی شده است. آن‌ها با استفاده از تصاویر ماهواره‌ای راداری Semtinel-1 به بررسی میزان و گسترش فرونشست زمین پرداختند و سپس با استفاده از سیستم اطلاعات جغرافیایی به پهنه‌بندی فرونشست دشت پرداختند. در این دشت مقدار فرونشست حدود ۱۳ سانتی‌متر بین سال‌های ۱۳۹۳ و ۱۳۹۷ محاسبه گردید.

موراکامی و همکاران^۱ (۲۰۰۶) با استفاده از درون‌یابی فضایی بر اساس زمین‌آمار نقشه فرونشست زمین را در دشت کانتو شمالی^۲ مورد مطالعه قرار دادند. بدین منظور آن‌ها در مطالعه خود، از روش درون‌یابی فضایی بر اساس روش کریجینگ معمولی برای تهیه نقشه فرونشست زمین استفاده کردند و تغییرپذیری مکانی فرونشست را در منطقه مورد مطالعه مورد بررسی قرار دادند و در نهایت نقشه پهنه‌بندی فرونشست را برای کل منطقه ارائه دادند.

ایکومونیسان و همکاران^۳ (۲۰۲۰) اظهار داشتند، پیش‌بینی دقیق فرونشست زمین برای مدیریت مؤثر فرونشست زمین و سایر مخاطرات زمینی مرتبط بسیار مهم است. آن‌ها در تحقیق خود شهر لاگوس که یکی از پرجمعیت‌ترین شهر نیجریه است که تحت تأثیر فرونشست زمین گسترده قرار گرفته است را مورد مطالعه قرار دادند. آن‌ها در تحقیق خود کاربرد زمین‌آمار را جهت بررسی و تهیه نقشه فرونشست مورد استفاده قرار دادند. هدف از مطالعه بررسی نرخ‌های فرونشست فعلی و ارزیابی تغییرپذیری مکانی فرونشست زمین در منطقه مورد مطالعه با استفاده از روش زمین‌آمار بیان گردید. بدین منظور از ادغام نیم تغییر نمای تجربی (semivariogram) و کریجینگ معمولی بهره جستند. نتایج آن‌ها نشان داد که ابزارهای زمین‌آمار برای ارزیابی تنوع مکانی نرخ فرونشست موفقیت‌آمیز و مناسب است.

با توجه به اینکه دشت دامغان یکی از دشت‌های مهم استان سمنان است، افت سطح آب زیرزمینی در این دشت مشهود است. در این تحقیق بررسی تغییرات مکانی فرونشست دشت دامغان مورد بررسی و ارزیابی قرار گرفت. بررسی منابع نشان می‌دهد تحقیقی در ارتباط با انجام درون‌یابی با استفاده از مدل هوشمند برای پارامتر فرونشست انجام نگرفته است. لذا در این تحقیق عملکرد مدل شبکه عصبی مصنوعی در مقایسه با روش‌های مرسوم درون‌یابی مانند روش درون‌یابی کریجینگ، کوکریجینگ و درون‌یابی وزنی معکوس فاصله (IDW) مورد بررسی قرار گرفت و با استفاده از معیارهای آماری عملکرد و توانایی هر یک از روش‌های مذکور مورد ارزیابی قرار گرفت.

مواد و روش‌ها

منطقه مورد مطالعه

با توجه به شکل (۱) منطقه مورد مطالعه، آبخوان آبرفتی شهر دامغان است که در استان سمنان واقع شده است. محدوده مورد مطالعه در موقعیت جغرافیایی حفاصل ۵۳ درجه و ۲۱ دقیقه تا ۵۴ درجه و ۴۱ دقیقه طول شرقی و ۳۵ درجه و ۴۲ دقیقه تا ۳۶ درجه و ۳۰ دقیقه عرض شمالی قرار دارد. مساحت محدوده دشت آبرفتی حدود ۱۳۵۱/۲ کیلومترمربع است. مطابق شکل (۲) میانگین بارش،

¹ Murakami et al


² Northern Kanto plain

³ Ikuemonisan et al


دما و تبخیر سالیانه این دشت به ترتیب برابر با ۱۲۷ میلی‌متر، ۱۶/۴ درجه سانتی‌گراد و ۲۴۲۹ میلی‌متر است. تغییرات بارش سالیانه دشت دامغان بین سال‌های ۱۳۸۵ تا ۱۴۰۱ را نشان می‌دهد. بر اساس اقلیم بندی دوماستن، دشت دامغان دارای اقلیم گرم و خشک است. همچنین در شکل (۳) تغییرات ارتفاعی دشت، چاه‌های مشاهداتی و موقعیت چاه‌های بهره‌برداری نشان داده شده است. حداکثر، حداقل و متوسط ارتفاع حوضه آبریز دشت دامغان به ترتیب ۱۵۲۰، ۱۰۳۹ و ۱۲۵۰ متر از سطح آزاد است. نقشه خطوط هم‌پتانسیل آب زیرزمینی در آبخوان آبرفتی دامغان مربوط به سال‌های ۱۳۸۵ و ۱۴۰۰ در شکل (۳) نشان داده شده است. بررسی تغییرات تراز آب زیرزمینی در آبخوان در دو سال ۱۳۸۵ و ۱۴۰۰ نشان می‌دهد در این دشت، متوسط افت سطح آب در طول آماری مورد بررسی ۰/۴۹ متر در سال است.




شکل ۱. محدوده مورد مطالعه در دشت دامغان در محیط گوگل ارث



شکل ۲. تغییرات بارش سالیانه دشت دامغان بین سال‌های ۱۳۸۵ تا ۱۴۰۱



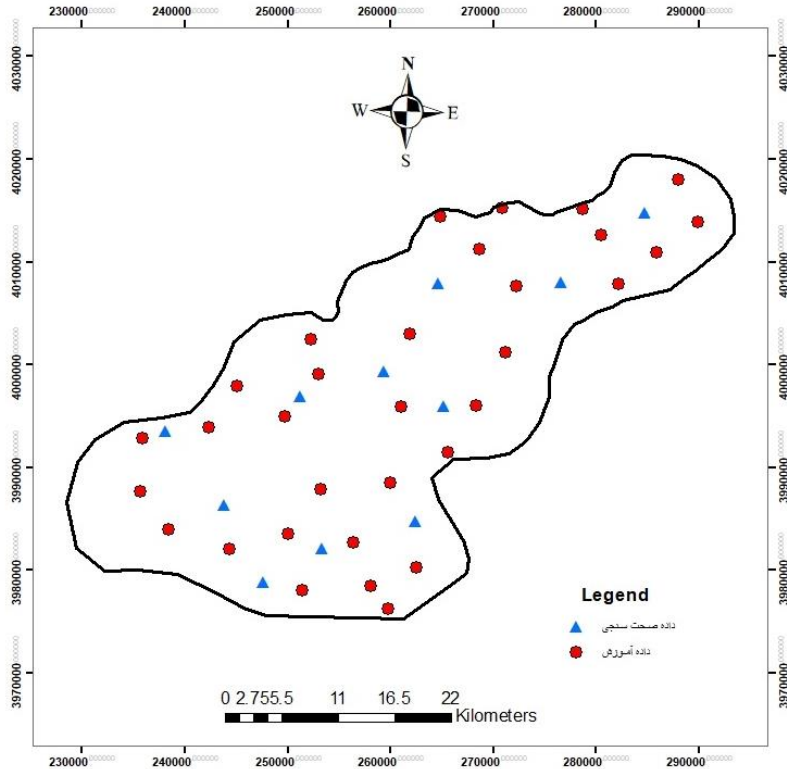
شکل ۳. تغییرات ارتفاعی منطقه مورد مطالعه، موقعیت چاه های بهره برداری و چاه های مشاهده ای




شکل ۴. تغییرات رقم سطح آب دشت دامغان بین سال های ۱۳۸۴ تا ۱۴۰۱

داده های مورد استفاده

در این مطالعه جهت انجام تحقیق در منطقه مورد مطالعه، مقدار فرونشست زمین در ۴۳ نقطه که پراکنش مکانی آن در شکل ۵ نشان داده شده است، اندازه گیری شد. شکل (۴) هیستوگرام داده های فرونشست اندازه گیری در محدوده دشت دامغان را نشان می دهد. برای ارزیابی و بررسی توانمندی سه روش کریجینگ، IDW یا معکوس فاصله، مدل شبکه عصبی مصنوعی به دو گروه آموزش و صحت سنجی تقسیم بندی شدند. از ۷۵ درصد داده های برای آموزش و ۲۵ درصد داده ها برای صحت سنجی مدل ها استفاده گردید. این داده ها کاملاً به طور تصادفی و به نحوی انتخاب شدند که دارای پراکنندگی مناسب در منطقه مورد تحقیق داشته باشند.



شکل ۵. موقعیت مکانی اندازه‌گیری فرونشست در محدوده دشت دامغان



شکل ۶. هیستوگرام داده‌های فرونشست اندازه‌گیری در محدوده دشت دامغان

مدل شبکه عصبی مصنوعی

بشر همواره در تلاش برای یافتن راه‌حلی بوده تا بتواند پردازش اطلاعات، مسائل و پدیده‌هایی را که به راحتی قابل حل نیست و یا یافتن روابط پیچیده میان پارامترهای پدیده‌های به راحتی امکان‌پذیر نیست را تسهیل نماید. لذا در این راستا با الگوبرداری از سیستم‌های بیولوژیک، به سیستم‌های هوشمندی دست‌یافته است که قادر به استخراج دانش الگوریتم یا نگاهت از دل محاسبات

عددی است. سامانه‌های دینامیکی یادشده که شبکه‌های عصبی مصنوعی نامیده می‌شوند، با پردازش بر روی داده‌های تجربی دانش یا قانون نهفته در ورای داده‌ها را ارائه می‌کنند. در حقیقت، یک شبکه عصبی مصنوعی مجموعه‌ای از تعداد زیادی واحدهای محاسباتی ساده مرتبط (نرون‌ها) است که شبیه به نرون‌های طبیعی مغز انسان هستند (هایکین^۱، ۱۹۹۹). شبکه‌های عصبی مصنوعی اولین بار توسط مک کالوچ و پیت^۲ (۱۹۴۳) معرفی گردید. امروزه توانمندی‌های روش شبکه‌ی عصبی در مدل‌سازی مسائل غیرخطی باعث شده تا در علوم مختلف مهندسی به‌موازات کاربرد روش‌های متداول، از روش شبکه عصبی نیز استفاده شود (مسلمی و همکاران^۳، ۲۰۱۴؛ کاشی و همکاران^۴، ۲۰۱۴؛ امامقلی زاده و همکاران^۵، ۲۰۱۴؛ امامقلی زاده و همکاران، ۲۰۱۵؛ بازوبندی و همکاران^۶، ۲۰۲۲).


یک شبکه عصبی شامل اجزای سازنده لایه‌ها و وزن‌ها است. رفتار شبکه نیز به ارتباط بین اعضا وابسته است. در حالت کلی در شبکه‌های عصبی سه نوع لایه نرونی وجود دارد:

لایه ورودی: از این لایه جهت معرفی مقادیر داده‌های ورودی به مدل و همچنین معرفی داده‌ها به اولین لایه مخفی انجام می‌گیرد. تعداد گره‌های لایه ورودی برابر با تعداد مقادیر داده‌های ورودی به مدل است.

لایه‌های میانی یا پردازشگر مخفی: عملکرد این لایه‌ها به‌وسیله ورودی‌ها و وزن ارتباط بین آن‌ها و لایه‌های پنهان تعیین می‌شود. وزن‌های بین واحدهای ورودی و پنهان تعیین می‌کنند که چه وقت یک واحد پنهان باید فعال شود. انتخاب تعداد لایه‌های مخفی و تعداد گره‌های مخفی می‌تواند بر عملکرد شبکه اثرگذار باشد.

لایه خروجی: لایه‌ای که خروجی آن، خروجی نهایی شبکه است و عملکرد واحد خروجی بسته به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان و خروجی است.

تابه‌حال شبکه عصبی مختلفی معرفی شده است که شبکه عصبی مصنوعی پرسپترون^۷ در زمره کاربردی‌ترین شبکه عصبی می‌باشند (رانا و همکاران^۸، ۲۰۱۸؛ روملهارت و همکاران^۹، ۱۹۸۶؛ زو و همکاران^{۱۰}، ۲۰۰۹). این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و سلول‌های عصبی که اغلب زیاد هم نیستند، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. این همان چیزی است که در بسیاری از مسائل فنی مهندسی به‌عنوان راه‌حل اصلی مطرح است. در شکل (۷) شبکه عصبی مصنوعی و لایه‌های ورودی، میانی و خروجی نشان داده شده است.



شکل ۷. شبکه‌های عصبی مصنوعی چندلایه

¹ Haykin
² McCulloch & Pitts
³ Moslemi et al
⁴ Kashi et al
⁵ Emamgholizadeh et al
⁶ Bazoobandi et al
⁷ Perceptron
⁸ Rana et al
⁹ Rumelhart et al
¹⁰ Zou et al

توابع انتقال گره، در ایفای هدف کنترل شدت سیگنال^۱ خروجی گره نقش دارد. این توابع شدت صوت خروجی را بین صفر و یک قرار می‌دهند. ورودی تابع انتقال حاصل ضرب نقطه‌ای سیگنال‌های ورودی تمامی گره‌ها و بردار وزن گره‌ها است. Qnet گزینه انتخاب چهار تابع انتقال را به کاربر ارائه می‌دهد که شامل سیگموئید^۲ با رابطه ریاضی $(1/(1+\exp(-x)))$ ، گوس^۳ با رابطه ریاضی $(\exp(-x*x))$ ، تانژانت هیپربولیک^۴ $(\tanh(x))$ و سکانت هیپربولیک^۵ $(\operatorname{sech}(x))$ می‌باشند.

از الگوریتم پس انتشار خطا^۶ (BP) برای آموزش شبکه‌های عصبی چندلایه پرسپترون^۷ (MLP) استفاده می‌شود. به عبارتی توپولوژی این شبکه‌ها با یادگیری پس انتشار خطا تکمیل می‌شود. قانون پس انتشار خطا از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت موسوم است که در این مسیر، بردار ورودی به شبکه چندلایه پرسپترون اعمال می‌شود. مسیر دوم به مسیر برگشت موسوم است و در این مسیر پارامترهای شبکه چندلایه پرسپترون تغییر و تنظیم می‌گردند. در حقیقت در این مدل خطاها در لایه خروجی به سمت لایه ورودی منتشر می‌شوند و وزن‌ها مطابق رابطه (۱) اصلاح می‌شوند:

$$\Delta w_{ij}(n) = -\varepsilon \times \frac{\partial E}{\partial w_{ij}} + \alpha \times \Delta w_{ij}(n-1) \quad (1)$$

در این رابطه $\Delta w_{ij}(n)$ و $\Delta w_{ij}(n-1)$ به ترتیب افزایش وزن بین گره i و j در طول گذر n و $(n-1)$ یا دوره هستند، E خطا است و α را ضریب نرخ یادگیری و ضریب حرکت نامیده می‌شوند و نرخ یادگیری الگوریتم را کنترل می‌کنند. برای بهینه‌سازی سرعت یادگیری شبکه، این عوامل باید در طول فرآیند آموزش به‌درستی تنظیم شوند. محدوده معتبر برای ε و α بین صفر و یک است.

درون‌یابی

منطق روش رایج جهت درون‌یابی با خصوصیات مکانی، بر این اصل استوار است که احتمال شباهت نقاطی که در فضا به یکدیگر نزدیک‌تر هستند، بیشتر از نقاطی است که از یکدیگر دور هستند. با استفاده از توابع درون‌یابی، ارزش توصیفی نقاط نامعلوم یک منطقه بر پایه تعدادی مشاهده (نقاط معلوم) در داخل آن برآورد می‌گردند و داده‌های مربوط به نقاط نمونه‌برداری شده به تمامی منطقه تعمیم داده می‌شوند. داده‌های نقاط معلوم به روش‌های مختلف تهیه‌شده و می‌توانند به صورت نقاط، خطوط و یا با سطح پراکنش منظم و یا نامنظم باشند. ارزش‌های توصیفی نیز می‌توانند از نوع داده‌های ارتفاعی، اقتصادی، اقلیمی و ... باشند. درون‌یابی شامل دو گروه خطی و غیرخطی می‌شود. درون‌یابی خطی در دنیای واقعی صحت ندارد، مگر در سطوح بسیار کوچک. روش‌های درون‌یابی غیرخطی به منظور حذف اثرات فرضیه خطی بودن تغییرات طراحی شده‌اند که از مهم‌ترین این روش‌ها می‌توان به روش‌های وزنی معکوس فاصله (IDW)، اسپیلاین (RBF) و کریجینگ (Kriging) اشاره کرد.

درون‌یابی به روش کریجینگ^۸ و کوکریجینگ^۹

شاخه‌ای از علم آمار کاربردی به نام زمین‌آمار قادر به ارائه مجموعه وسیعی از تخمین‌گرهای آماری به منظور برآورد خصوصیت موردنظر در مکان‌های نمونه‌برداری نشده با استفاده از اطلاعات حاصل از نقاط نمونه‌برداری شده است (هونیا و همکاران^{۱۰}، ۲۰۱۸؛ رای و همکاران^{۱۱}، ۲۰۰۲). کریجینگ یک روش زمین‌آمار برای درون‌یابی داده‌ها بر اساس واریانس فضایی است. درون‌یابی

1 Signal Strength
 2 Sigmoid
 3 Gaussian
 4 Hyperbolic Tangent
 5 Hyperbolic Secant
 6 Back-Propagation
 7 Multi-layer Perceptron
 8 Kriging
 9 CoKriging
 10 Bhunia et al
 11 Ryu et al

کریجینگ روش پیشرفته‌ای است که در مقایسه با سایر روش‌های درون‌یابی، محاسبات آن نیازمند زمان بیشتر است و با توجه به فرضیات پایه آن، معمولاً در سطوح کوچک به کار گرفته می‌شود. کریجینگ بهترین تخمین‌گر خطی نارایب با حداقل پراکندگی واریانس است (بوستان^۱، ۲۰۱۷). برتری کریجینگ نسبت به سایر روش‌های درون‌یابی این است که همراه هر تخمین، مقدار خطای آن را نیز می‌دهد که با استفاده از این ویژگی منحصر به فرد می‌توان قسمت‌های واجد خطای زیاد که برای کاهش خطا به داده‌های بیشتری نیاز دارند را مشخص نمود (حسینی پاک، ۱۳۸۹). برای برآورد مقادیر بر اساس کریجینگ روش‌های مختلفی وجود دارد که از مهم‌ترین آن‌ها می‌توان به روش‌های کریجینگ معمولی (OK)، کوکریجینگ (CK) و کریجینگ رگرسیون (RK) اشاره کرد. کوکریجینگ در حقیقت بسط روش کریجینگ معمولی است. در این روش برای بهبود دقت روش کریجینگ برای تخمین یک متغیر با نمونه‌برداری ضعیف (پارامتر هدف) از یک متغیر کمکی استفاده می‌شود (واکرناگل^۲، ۲۰۰۳). دو روش کریجینگ و کوکریجینگ از توابع نیم تغییر نمای تجربی semivariogram و cross-semivariogram برای کمیت و توصیف الگوهای فضایی متغیر وابسته استفاده می‌کنند (وسترن و همکاران^۳، ۲۰۰۴). روش عمومی محاسبه کریجینگ بر اساس رابطه (۲) است:

$$Z_0' = \sum_{i=1}^N w_i Z_i \quad (2)$$

در رابطه فوق، Z_0' مقدار برآورد شده، w_i برابر با وزن و Z_i برابر با مقادیر نمونه‌ها است. وزن‌ها به درجه همبستگی بین نقاط نمونه و نقاط برآورد شده بستگی دارد و همیشه جمع آن‌ها برابر با ۱ است. برای درک بهتر ساختار فضایی نمونه‌های برداشت شده و انتخاب بهترین روش درون‌یابی، خود همبستگی فضایی (spatial autocorrelation) بین نمونه‌ها مطالعه می‌شود. این بررسی را می‌توان با ترسیم فاصله بین نمونه‌ها و واریانس ارزش نمونه‌ها یا به عبارت دیگر سمی واریوگرام‌ها به دست آورد. سمی واریوگرام، بر این اساس که خواص پدیده‌ها در مکان‌های نزدیک‌تر شباهت بیشتری به هم دارند تا در فاصله‌های دورتر، درجه وابستگی یا همبستگی بین نقاط را اندازه‌گیری می‌کند. سمی واریوگرام، بر اساس نصف میانگین مربع واریانس بین نقاط محاسبه می‌شود. برای مشاهدات $Z_i, i=1, \dots, k$ در مکان‌های x_1, \dots, x_k ، نیم‌واریوگرام تجربی $\gamma(h)$ به صورت زیر تعریف می‌شود (کرسی^۴، ۱۹۹۳؛ مترون^۵، ۱۹۶۳):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i+h)]^2 \quad (3)$$

تابع $\gamma_{ij}(h)$ یعنی نیم تغییرنمای تجربی مقاطع (Cross-variogram) برای تعیین وابستگی متقابل فضایی بین دو متغیر با استفاده از رابطه زیر محاسبه می‌شود:

$$\gamma_{ij}(h) = \frac{1}{2N(\square)} \sum_{i=1}^{N(\square)} [Z_i(x_i) - Z_i(x_i+h)] [Z_j(x_i) - Z_j(x_i+h)] \quad (4)$$

که در آن تعداد داده‌های $Z(x_i)$ و $Z(x_i+h)$ به ترتیب دو مقدار اندازه‌گیری شده در مکان‌های x_i و x_i+h که با یکدیگر فاصله h از هم دارند می‌باشند. همچنین $N(h)$ تعداد داده‌ها هست.

درون‌یابی وزنی معکوس فاصله^۶ (IDW)

IDW یکی از تکنیک‌های درون‌یابی کاربردی و قطعی در رشته‌های مختلف از جمله مهندسی آب مورد استفاده قرار گرفته است. در این روش برآوردهای IDW بر اساس مکان‌های شناخته شده انجام می‌گردد. وزن‌های اختصاص داده شده به نقاط درون‌یابی، عکس فاصله آن از نقطه درون‌یابی است. در نتیجه، نقاط نزدیک به گونه‌ای ساخته می‌شوند که وزن بیشتری داشته باشند؛ بنابراین، تأثیر بیشتری نسبت به نقاط دور داشته باشند و بالعکس. نقاط نمونه شناخته شده به طور ضمنی از یکدیگر خودگردان هستند (روبینسون و مترنیچت^۷، ۲۰۰۶).

¹ Bostan

² Wackernagel

³ Western et al

⁴ Cressie

⁵ Matheron

⁶ Inverse distance weighting (IDW)

⁷ Robinson & Metternicht

ارزیابی نتایج مدل

جهت ارزیابی نتایج به‌دست‌آمده از روش‌های شبکه عصبی مصنوعی، روش کریجینگ و روش درونیابی وزنی معکوس فاصله از سه شاخص آماری میانگین قدر مطلق خطا (MAE)، ریشه مربع میانگین خطا (RMSE) و ضریب تبیین (R^2) که روابط آن‌ها در زیر آمده است، استفاده شد:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (5)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (6)$$

$$R^2 = \frac{(\sum_{i=1}^N (O_i - \bar{O}_i)(P_i - \bar{P}_i))^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (7)$$

در این روابط N تعداد نقاط، O و P به ترتیب مقادیر اندازه‌گیری و محاسباتی فرونشست زمین می‌باشند.

یافته‌ها

نتایج اندازه‌گیری میدانی مقدار فرونشست زمین

همان‌طور که در بخش مواد و روش‌ها توضیح داده شد، در این تحقیق از داده‌های اندازه‌گیری شده فرونشست در ۴۳ نقطه که پراکنش مکانی آن در شکل (۵) نشان داده شده است، استفاده گردید. مطابق شکل (۸) و بازدید میدانی انجام‌شده در این دشت، نشان می‌دهد فرونشست به‌وضوح در نقاط مختلف دشت قابل‌رؤیت است. همچنین در برخی از مکان‌ها (مانند قسمت جنوب غربی دشت) ترک‌های طولی نیز در نزدیکی سازه‌هایی مانند جاده، ریل راه‌آهن مشاهده شده است. این خطری جدی برای سازه‌های زیربنایی است. همچنین مقادیر حداقل، حداکثر و متوسط فرونشست در کل دشت دامغان به ترتیب برابر با ۳، ۱۸/۵ و ۹/۳ سانتی‌متر بوده است. بیشترین مقدار فرونشست زمین در جنوب دشت دامغان مشاهده شده است. دلیل این امر مربوط تشکیلات رسی منطقه و خاصیت غیرقابل انعطاف‌پذیری آن در ارتباط با فرونشست است. از طرفی در این منطقه کاربری اراضی از نوع کشاورزی بوده و برداشت آب توسط چاه‌های منطقه بیشتر از سایر قسمت‌ها است.



شکل ۸. فرونشست اتفاق افتاده در محدوده دشت دامغان شامل ترک در سطح زمین و فرونشست اطراف پی‌زومتر مشاهداتی

نتایج درون‌یابی فرونشست زمین با استفاده از دو روش کریجینگ و وزنی معکوس فاصله

همان‌طور که قبلاً بیان شد، دو روش کریجینگ (زمین‌آماری) و وزنی معکوس فاصله IDW (قطعی) روش‌های درون‌یابی هستند که از آن‌ها می‌توان برای درون‌یابی استفاده کرد. برای بررسی همبستگی فضایی و ساختار فضایی متغیرها، پس از نرمال‌سازی، نیم تغییر نمای تجربی (Semivariogram) بر روی داده مقدار فرونشست ترسیم شد. نیم تغییر نمای تجربی، همبستگی فضایی را بین داده‌های مشاهداتی یا اندازه‌گیری شده در مکان‌های مختلف فراهم می‌کند و نشان می‌دهد که چگونه اندازه‌گیری در یک نقطه با اندازه‌گیری‌ها در نقاط همسایه همبستگی دارد. انواع مختلفی از توابع نیمه متغیر (به‌عنوان مثال، دایره‌ای، کروی، نمایی، گاوسی و خطی) را می‌توان برای مدل‌سازی نیم تغییر نمای تجربی استفاده کرد.

محاسبه پارامترهای کلیدی مربوط به نیم تغییر نمای تجربی در جدول (۱) آورده شده است. در این جدول $C_0 / (C_0 + C)$ نسبت قطعه (C_0) به آستانه است و وابستگی مکانی مقدار فرونشست زمین را نشان می‌دهد. نسبت‌های ۰ تا ۰/۲۵، ۰/۲۵ تا ۰/۷۵ و بیشتر از ۰/۷۵ به ترتیب وابستگی مکانی قوی، متوسط و ضعیف متغیرها را نشان می‌دهند (کامباردلا و همکاران^۱، ۱۹۹۴). اگر ضریب همبستگی مدل برازش داده‌شده بر داده‌ها کمتر از ۰/۵ باشد، همبستگی مکانی ضعیف تعریف می‌شود (دوفرا و همکاران^۲، ۲۰۰۷). همان‌طوری که نتایج این جدول نشان می‌دهد بهترین مدل مربوط به مدل گاوسی بوده است.

نتایج محققین دیگر نیز نشان داد استفاده از تابع گاوسی نتایج بهتری را در مقایسه با مدل‌های دایره‌ای، کروی، نمایی و خطی نشان می‌دهد و این مدل را در مطالعات خود استفاده. (امامقلی زاده و همکاران، ۲۰۱۷؛ ایوانسک و همکاران^۳، ۲۰۱۴؛ وانگ و همکاران^۴، ۲۰۰۳)؛ بنابراین، در این تحقیق نیز از این تابع برای مدل‌سازی نیم تغییر نمای تجربی استفاده شد. شکل (۹) نیم تغییر نمای تجربی فرونشست زمین را با استفاده از مدل گاوسی نشان می‌دهد. همچنین شکل (۱۰) مقادیر فرونشست درون‌یابی شده در محدوده دشت دامغان با استفاده از روش کریجینگ و مدل گاوسی را نشان می‌دهد.

جدول ۱. بهترین مدل برازش داده‌شده بر نیم تغییر نمای تجربی و پارامترهای محاسبه‌شده برای پارامتر فرونشست زمین


نوع مدل	اثر قطعه‌ای C_0 (nugget)	مقدار آستانه C (partial sill)	دامنه تأثیر Range (m)	$+CC_0$	$C_0 / (C_0 + C)$	R^2	RSS	وابستگی مکانی
خطی	0.376	0.136	28,583	0.512	0.266	0.073	0.265	ضعیف
کروی	0.001	0.467	5,000	0.468	0.998	0.387	0.204	ضعیف
توانی	0.001	0.476	7,230	0.477	0.998	0.23	0.224	ضعیف
گاوسی	0.010	18.200	4,503	18.210	0.999	0.366	0.194	متوسط

¹ Cambardella et al

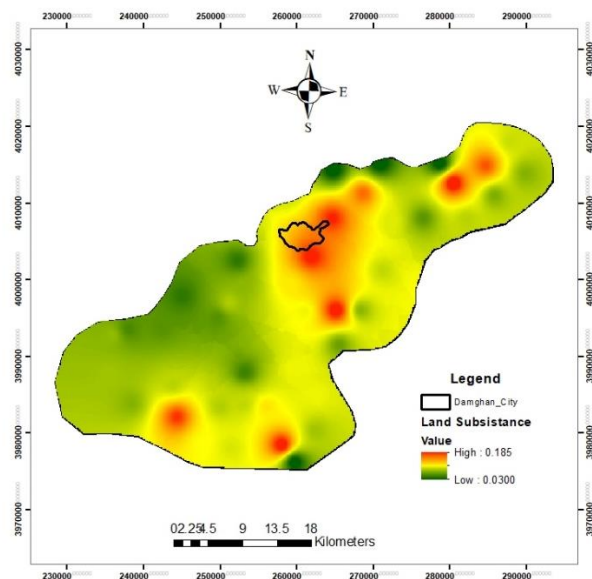
² Duffera et al

³ Ivajnsiĉ et al

⁴ Wang et al



شکل ۹. نیم تغییر نمای تجربی مقدار فرونشست زمین در منطقه مورد مطالعه (دشت دامغان) با استفاده از مدل گاوسی



شکل ۱۰. فرونشست درون‌یابی شده در محدوده دشت دامغان با استفاده از روش کریجینگ با استفاده از مدل گاوسی

نتایج درون یابی با استفاده از مدل شبکه عصبی مصنوعی

همان طور که در بخش مواد و روش ها اشاره شد، مدل ANN/MLP (با یک الگوریتم انتشار برگشتی) برای تخمین فرونشست استفاده شد. برای مدل MLP، تعداد لایه ها و همچنین تعداد گره ها ساختار مدل شبکه عصبی مصنوعی را تعیین می کند. دقت مدل شبکه عصبی مصنوعی در مقایسه با مدل های کریجینگ و IDW مورد ارزیابی قرار گرفت. داده ورودی به مدل مانند مدل های قبلی همان مختصات نقاط اندازه گیری فرونشست یعنی X و Y است. انتخاب تعداد صحیح گره ها برای لایه پنهان در مدل شبکه عصبی مصنوعی مهم است، زیرا تعداد کمی از گره ها ممکن است منجر به زیر برازش می شود و تعداد زیادی گره ها ممکن است منجر به بیش از حد برازش شوند و در نتیجه زمان آموزش مدل افزایش یابد. علاوه بر این، تابع انتقال برای لایه های مخفی یا خروجی باید انتخاب شود. در این مطالعه از چهار تابع انتقال به نام های سیگموئید (Sigmoid)، (Gaussian)، (Hyperbolic Tangent) و (Hyperbolic Secant) استفاده گردید؛ مانند مطالعات بازوبندی و همکاران (۲۰۲۲)، کاشی و همکاران (۲۰۱۴) و امامقلی زاده و همکاران (۲۰۱۳ و ۲۰۱۸) از روش آزمون و خطا برای یافتن بهترین ساختار مدل ANN برای تخمین مقدار فرونشست در مکان های مختلف استفاده شد. برای توقف آموزش مدل MLP از دو معیار استفاده شد. خطای آستانه و عدد تکرار به عبارت دیگر، زمانی که RMSE بین برآوردها و مشاهدات کمتر از 0.0001 بود یا زمانی که تکرارهای مدل به حداکثر ۱۰۰۰۰۰ رسید، تکرار مدل متوقف شد. فرونشست تخمین زده شده در جدول (۲) برای مراحل کالیبراسیون (آموزش) و اعتبارسنجی (آزمایش) نشان داده شده است. نتایج مدل شبکه عصبی مصنوعی با دولا لایه پنهان و تابع انتقال گاوسی بهترین نتایج را در مقایسه با سایر توابع انتقال را نشان می دهد. با توجه به اینکه تابع گاوسین بهتر از سایر توابع انتقال بوده است، در ادامه برای بررسی تأثیر تعداد لایه میانی بر عملکرد مدل شبکه عصبی مصنوعی، مدل با لایه های میانی از ۱ تا ۵ اجرا گردید که نتایج به دست آمده در جدول (۳) نشان داده شده است. همان طوری که نتایج این جدول نشان می دهد، با افزایش تعداد لایه های از ۲ به بعد، میزان خطا افزایش یافته است که این امر به علت پیچیده تر شدن مدل در تخمین مقدار فرونشست است. همچنین شکل (۸) نمودار پراکندگی فرونشست تخمین زده شده در مقابل فرونشست اندازه گیری شده از مدل ANN را در دو مرحله کالیبراسیون و اعتبارسنجی نشان می دهد.

جدول ۲. نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی با استفاده از توابع انتقال مختلف

صحت سنجی			آموزش			نوع تابع
R ²	RMSE (m)	MAE (m)	R ²	RMSE (m)	MAE (m)	
0.282	0.043	0.030	0.482	0.036	0.026	سیگموئید
0.274	0.047	0.033	0.458	0.040	0.029	هیپربولیک سکانت
0.266	0.052	0.036	0.447	0.043	0.031	هیپربولیک تانژانت
0.401	0.048	0.033	0.412	0.044	0.031	گوسین

جدول ۳. نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی با استفاده از تابع انتقال گاوسین و تعداد لایه میانی مختلف

صحت سنجی			آموزش			تعداد لایه میانی
R ²	RMSE (m)	MAE (m)	R ²	RMSE (m)	MAE (m)	
0.401	0.048	0.033	0.412	0.044	0.031	1
0.502	0.038	0.028	0.458	0.041	0.030	2
0.441	0.046	0.033	0.442	0.049	0.037	3
0.412	0.055	0.040	0.432	0.059	0.044	4
0.402	0.061	0.044	0.410	0.065	0.048	5

مقایسه بین نتایج درون‌یابی با استفاده از مدل شبکه عصبی مصنوعی، روش کریجینگ و روش وزنی معکوس فاصله

به‌منظور مقایسه نتایج درون‌یابی بین سه روش مدل شبکه عصبی مصنوعی، روش کریجینگ و روش وزنی معکوس فاصله، بهترین عملکرد آن‌ها در این بخش با استفاده از شاخص‌های آماری مورد استفاده قرار گرفت. با توجه به بخش قبلی، بهترین عملکرد مدل را شبکه عصبی مصنوعی با تابع انتقالی گاوس و دو لایه میانی داشته است. همچنین برای دو روش درون‌یابی روش کریجینگ و روش وزنی معکوس فاصله، نتایج بررسی نیم تغییر نمای تجربی مقدار فرونشست زمین در دشت دامغان نشان داد که مدل گاوس بهتر از سایر مدل‌ها بوده است. نتایج حاصل از سه روش مذکور در جدول (۴) آمده است. با توجه به نتایج این جدول می‌توان نتیجه گرفت که شبکه عصبی مصنوعی دارای عملکرد بهتری در مقایسه با روش کریجینگ و روش وزنی معکوس فاصله داشته است و توانسته است مقدار خطای RMSE را در مرحله صحت سنجی به ترتیب ۱۷/۶ و ۳۱/۳ درصد کاهش دهد. همچنین مقدار ضریب تبیین را از ۰/۵۰۲ و ۰/۴۲۱ به ۰/۷۲۱ افزایش داده است.

جدول ۴. مقایسه بین نتایج مدل شبکه عصبی مصنوعی، روش کریجینگ و روش وزنی معکوس فاصله


صحت سنجی			آموزش			نوع تابع
R ²	RMSE (m)	MAE (m)	R ²	RMSE (m)	MAE (m)	
0.721	0.031	0.020	0.785	0.031	0.020	ANN
0.502	0.038	0.028	0.458	0.041	0.030	Kriging
0.421	0.046	0.033	0.487	0.049	0.037	IDW

در مجموع با توجه به معیارهای خطا، نتایج به‌دست‌آمده رضایت‌بخش نبوده است، لذا برای افزایش دقت سه روش مورد استفاده (مدل شبکه عصبی مصنوعی، روش کریجینگ و روش وزنی معکوس فاصله) از پارامتر کمکی یعنی کاهش سطح آب، به‌عنوان یک پارامتر ورودی به مدل برای پیش‌بینی فرونشست استفاده گردید. بدین منظور از مدل کوکریجینگ، روش IDW وزنی و مدل شبکه عصبی مصنوعی برای پیش‌بینی فرونشست زمین استفاده گردید. نتایج به‌دست‌آمده در جدول (۵) نشان داده شده است. همان‌طوری که نتایج این جدول نشان می‌دهد، افزودن پارامتر کمکی افت سطح آب زیرزمینی به مدل‌های مذکور موجب بهبود عملکرد هر سه روش شده است. بطوریکه مقایسه بین کریجینگ معمولی نشان می‌دهد، مقدار خطای RMSE به مقدار درصد ۳۰/۲ و ۱۷/۹ درصد به ترتیب برای مرحله آموزش و صحت‌سنجی کاهش پیدا کرده

است. همچنین برای مدل IDW و IDW وزنی نیز مقدار خطا RMSE به ترتیب برای مرحله آموزش و صحت‌سنجی ۵۵/۴ و ۳۲/۱ درصد کاهش یافته است. همانند دو روش مذکور، استفاده از پارامتر کمکی به‌عنوان داده ورودی به مدل شبکه عصبی مصنوعی موجب بهبود عملکرد مدل در تخمین مقدار فرونشست شده است و مقدار خطا RMSE به ترتیب ۴۹/۸ و ۴۶/۵ درصد به ترتیب برای مرحله آموزش و صحت‌سنجی کاهش پیدا کرده است.

جدول ۵. مقایسه بین نتایج مدل شبکه عصبی مصنوعی، روش کوکریجینگ و روش وزنی معکوس فاصله با استفاده از متغیر کمکی

صحت سنجی			آموزش			نوع تابع
R ²	RMSE (m)	MAE (m)	R ²	RMSE (m)	MAE (m)	
0.751	0.017	0.013	0.860	0.015	0.012	ANN
0.512	0.031	0.024	0.523	0.029	0.022	CoKriging
0.511	0.037	0.027	0.536	0.033	0.024	Weighted IDW



شکل ۱۱. فرونشست اندازه‌گیری شده و پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی

بحث

پدیده فرونشست زمین در سال‌های اخیر در بسیاری از دشت‌های ایران به دلیل برداشت بی‌رویه از آب زیرزمینی از جمله دشت دامغان اتفاق افتاده است. در این تحقیق با استفاده از داده‌های اندازه‌گیری شده فرونشست زمین در این دشت به بررسی تغییرات مکانی آن با استفاده از روش کریجینگ و کوکریجینگ (روش زمین‌آمار) و روش وزنی معکوس فاصله (IDW) و IDW وزنی (روش قطعی) در کل دشت مورد بررسی قرار گرفت. جهت ارزیابی مقادیر برآورد شده فرونشست دشت از سه شاخص آماری میانگین قدر مطلق خطا (MAE)، ریشه مربع میانگین خطا (RMSE) و ضریب تبیین (R²) استفاده شد.

نتیجه‌گیری

نتایج تحقیق با استفاده از ترسیم نیم تغییر نمای تجربی نشان داد، در منطقه مورد مطالعه (دشت دامغان) استفاده از مدل گaus دقت بهتری را در مقایسه با سایر مدل‌ها مانند دایره‌ای، کروی، نمایی و خطی بوده است. همچنین مقایسه بین نتایج روش‌های مذکور با مدل شبکه عصبی

مصنوعی نشان داد استفاده از مدل شبکه عصبی مصنوعی موجب افزایش دقت برآورد فرونشست زمین در منطقه مورد مطالعه شده است و بهتر می‌تواند تغییرات مکانی را تخمین بزند. به طوری که مدل شبکه عصبی مصنوعی در مقایسه با دو روش کوکریجینگ و IDW وزنی توانسته است، مقدار خطای RMSE را در مرحله صحت‌سنجی به ترتیب برابر با $۴۶/۳$ و $۵۴/۴$ درصد کاهش دهد. همچنین ضریب تبیین نیز از $۰/۵۱۲$ و $۰/۵۱۱$ به $۰/۷۵۱$ در مرحله صحت‌سنجی افزایش یافته است. در مجموع نتایج بررسی در این تحقیق نشان می‌دهد از شبکه عصبی مصنوعی می‌توان به‌عنوان روش جایگزین به‌جای روش‌های مرسوم مانند روش کوکریجینگ و روش وزنی معکوس فاصله در میان‌یابی مقدار فرونشست زمین استفاده کرد.

منابع

- آروین، عبدالخالق، وهازاده کبریا، قربان، موسوی، سید رمضان، و بختیاری کیا، مسعود. (۱۳۹۸). مدل سازی مکانی فرونشست زمین در جنوب حوزه آبخیز میناب با استفاده از سنجش از دور و سیستم اطلاعات جغرافیایی. فصلنامه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی، ۱۰(۳)، ۳۴-۱۹. <https://civilica.com/doc/963959>
- تورانی، مرجان، آق آتابای، مریم، روستایی، مه آسا. (۱۳۹۷). مطالعه فرونشست در شهر گرگان با استفاده از روش تداخل سنجی راداری. مجله آمایش جغرافیایی فضا، ۸(۲۷)، ۱۲۸-۱۱۷. https://gps.gu.ac.ir/article_65973.html
- حسینی پاک، علی اصغر. (۱۳۸۹). زمین آمار (ژئو استاتستیک). موسسه چاپ و انتشارات دانشگاه تهران. <https://www.gisoom.com/book/1686692>
- قره‌چلو، سعید، اکبری قوچانی، حسام، گلین، سعید، و گنجی، کامران. (۱۴۰۰). فصلنامه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی ۱۲(۳)، ۶۱-۴۰. <https://doi.org/10.30495/girs.2021.680336>
- قوامی جمال، صادق، غلامی، حامد، رجبی حران، مهرداد، و مبینی، محمدحسین. (۱۴۰۱). تأثیر احداث سد ماملو بر فرونشست اراضی دشت ورامین. فصلنامه انسان و محیط زیست، ۲۰(۲)، ۱۸۵-۱۷۱. <https://dorl.net/dor/20.1001.1.15625532.1401.20.2.13.4>
- کلانتری، سعید، عبادتی، ناصر، و ذاکری نیری، محمود. (۱۳۹۹). ارزیابی فرونشست دشت شهریار و ملارد ناشی از برداشت آب‌های زیرزمینی و تأثیر آن بر سازه‌های زیربنایی. نشریه زمین‌شناسی محیط زیست، ۵۲، ۳۹-۲۳. <https://magiran.com/p2311953>

References

- Arvin, A., Vahabzadeh, G., Mousavi, S. R., & Bakhtyari Kia, M. (2019). Geospatial modeling of land subsidence in the south of the Minab watershed using remote sensing and GIS. *Journal of RS and GIS for Natural Resources*, 10(3), 19-34. <https://civilica.com/doc/963959/> [In Persian]
- Babae, S., Mousavi, Z., Masoumi, Z., Malekshah, A. H., Roostaei, M., & Aflaki, M. (2020). Land subsidence from interferometric SAR and groundwater patterns in the Qazvin plain, Iran. *International Journal of Remote Sensing*, 41(12), 4780-4798. <https://doi.org/10.1080/01431161.2020.1724345>
- Bazoobandi, A., Emamgholizadeh, S., & Ghorbani, H. (2022). Estimating the amount of cadmium and lead in the polluted soil using artificial intelligence models. *European Journal of Environmental and Civil Engineering*, 26(3), 933-951. <https://doi.org/10.1080/19648189.2019.1686429>
- Bhunia, G. S., Shit, P. K., & Maiti, R. (2018). Comparison of GIS-based interpolation methods for spatial distribution of soil organic carbon (SOC). *Journal of the Saudi Society of Agricultural Sciences*, 17(2), 114-126. <https://doi.org/10.1016/j.jssas.2016.02.001>
- Bostan, P. (2017). Basic kriging methods in geostatistics. *Yuzuncu Yıl University Journal of Agricultural Sciences*, 27(1), 10-20. <https://doi.org/10.29133/yyutbd.305093>

- Cambardella, C., Moorman, T., Parkin, T., Karlen, D., Novak, J., Turco, R., & Konopka, A. (1994). Field-scale variability of soil properties in central Iowa soils. *Soil science society of America journal*, 58(5), 1501-1511. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>
- Cressie, N. (1993). *Statistics for spatial data: Wiley series in probability and statistics*. Wiley-Interscience, New York, 15, 105-209. <https://doi.org/10.1002/9781119115151>
- Duffera, M., White, J. G., & Weisz, R. (2007). Spatial variability of Southeastern US Coastal Plain soil physical properties: Implications for site-specific management. *Geoderma*, 137(3-4), 327-339. <https://doi.org/10.1016/j.geoderma.2006.08.018>
- Emamgholizadeh, S., Bateni, S., & Jeng, D. S. (2013). Artificial intelligence-based estimation of flushing half-cone geometry. *Engineering Applications of Artificial Intelligence*, 26(10), 2551-2558. <https://doi.org/10.1016/j.engappai.2013.05.014>
- Emamgholizadeh, S., Esmailbeiki, F., Babak, M., Zarehaghi, D., Maroufpoor, E., & Rezaei, H. (2018). Estimation of the organic carbon content by the pattern recognition method. *Communications in Soil Science and Plant Analysis*, 49(17), 2143-2154. <https://doi.org/10.1080/00103624.2018.1499750>
- Emamgholizadeh, S., Kashi, H., Maroufpoor, I., & Zalaghi, E. (2014). Prediction of water quality parameters of Karoon River (Iran) by artificial intelligence-based models. *International Journal of Environmental Science and Technology*, 11, 645-656. <https://doi.org/10.1007/s13762-013-0378-x>
- Emamgholizadeh, S., Moslemi, K., & Karami, G. (2014). Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). *Water resources management*, 28, 5433-5446. <https://doi.org/10.1007/s11269-014-0810-0>
- Emamgholizadeh, S., Parsaeian, M., & Baradaran, M. (2015). Seed yield prediction of sesame using artificial neural network. *European Journal of Agronomy*, 68, 89-96. <https://doi.org/10.1016/j.eja.2015.04.010>
- Emamgholizadeh, S., Shahsavani, S., & Eslami, M. A. (2017). Comparison of artificial neural networks, geographically weighted regression and Cokriging methods for predicting the spatial distribution of soil macronutrients (N, P, and K). *Chinese Geographical Science*, 27, 747-759. <https://doi.org/10.1007/s11769-017-0906-6>
- Gharechelou, S., Akbari Ghoochani, H., Golian, S., & Ganji, K. (2021). Evaluation of land subsidence relationship with groundwater depletion using Sentinel-1 and ALOS-1 radar data (Case study: Mashhad plain). *Journal of RS and GIS for Natural Resources*, 12(3), 40-61. <https://doi.org/10.30495/girs.2021.680336> [In Persian]
- Ghavami Jamal, S., Gholami, H., Rajabi, M., & Mobini, M. H. (2022). Effect of the construction of Mamloo dam on land subsidence in Varamin plain. *Human & Environment*, 20(2), 171-185. <https://dorl.net/dor/20.1001.1.15625532.1401.20.2.13.4>
- Ghazifard, A., Moslehi, A., Safaei, H., & Roostaei, M. (2016). Effects of groundwater withdrawal on land subsidence in Kashan Plain, Iran. *Bulletin of Engineering Geology and the Environment*, 75, 1157-1168. <https://doi.org/10.1007/s10064-016-0885-3>
- Golian, M., Saffarzadeh, A., Katibeh, H., Mahdad, M., Saadat, H., Khazaei, M., Sametzadeh, E., Ahmadi, A., Sharifi Teshnizi, E., & Samadi Darafshani, M. (2021). Consequences of groundwater overexploitation on land subsidence in Fars Province of Iran and its mitigation management programme. *Water and Environment Journal*, 35(3), 975-985. <https://doi.org/10.1111/wej.12688>
- Haykin, S. (1999). *Neural network a comprehensive foundation*. Prentice-Hall, New Jersey. <https://doi.org/10.1142/S0129065794000372>
- Hosnepak, A. A. (2010). *Geostatistics*. Tehran University Printing and Publishing Institute. <https://www.gisoom.com/book/1686692> [In Persian]
- Ikuemonisan, F. E., Ozebo, V. C., & Olatinsu, O. B. (2020). Geostatistical evaluation of spatial variability of land subsidence rates in Lagos, Nigeria. *Geodesy and Geodynamics*, 11(5), 316-327. <https://doi.org/10.1016/j.geog.2020.04.001>
- Ivajnsič, D., Kaligarič, M., & Žiberna, I. (2014). Geographically weighted regression of the urban heat island of a small city. *Applied Geography*, 53, 341-353. <https://doi.org/10.1016/j.apgeog.2014.07.001>

- Kalantari, S., Ebadati, N., & Zakeri Nayyeri, M. (2020). Assessment of subsidence of Shahriar and Mallard plains due to groundwater abstraction and its effect on infrastructure. *Iranian Journal of Environmental Geology*, 52, 23-39. <https://magiran.com/p2311953> [In Persian]
- Kashi, H., Emamgholizadeh, S., & Ghorbani, H. (2014). Estimation of soil infiltration and cation exchange capacity based on multiple regression, ANN (RBF, MLP), and ANFIS models. *Communications in Soil Science and Plant Analysis*, 45(9), 1195-1213. <https://doi.org/10.1080/00103624.2013.874029>
- Khorshiddoust, A. M., Razmi, R., Maali, N., & Abbaszadeh, K. (2017). Studying the effective factors in subsidence in Tasuj, Iran using AHP method. *Journal of Geography and Planning*, 21(60), 1-21. <https://www.researchgate.net/publication/319617912>
- Lam, N. S.-N. (1983). Spatial interpolation methods: a review. *The American Cartographer*, 10(2), 129-150. <https://doi.org/10.1559/152304083783914958>
- Mahmoudpour, M., Khamsehchiyan, M., Nikudel, M. R., & Ghassemi, M. R. (2016). Numerical simulation and prediction of regional land subsidence caused by groundwater exploitation in the southwest plain of Tehran, Iran. *Engineering Geology*, 201, 6-28. <https://doi.org/10.1016/j.enggeo.2015.12.004>
- Matheron, G. (1963). Principles of geostatistics. *Economic geology*, 58(8), 1246-1266. <https://doi.org/10.2113/gsecongeo.58.8.1246>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133. <https://doi.org/10.1007/BF02478259>
- Mitas, L., & Mitasova, H. (1999). Spatial interpolation. *Geographical information systems: principles, techniques, management and applications*, 1(2), 481-492. http://fatra.cnr.ncsu.edu/~hmitaso/gmslab/papers/mitas_mitasova_1999_2005.pdf
- Murakami, S., Yasuhara, K., Suzuki, K., & Komine, H. (2006). Reliable land subsidence mapping using a spatial interpolation procedure based on geostatistics. *Soils and foundations*, 46(2), 123-134. <https://doi.org/10.3208/sandf.46.123>
- Rajabi, A. M., & Ghorbani, E. (2016). Land subsidence due to groundwater withdrawal in Arak plain, Markazi province, Iran. *Arabian Journal of Geosciences*, 9, 1-7. <https://doi.org/10.1007/s12517-016-2753-7>
- Rana, A., Rawat, A. S., Bijalwan, A., & Bahuguna, H. (2018). Application of multi layer (perceptron) artificial neural network in the diagnosis system: a systematic review. 2018 International conference on research in intelligent and computing in engineering (RICE). <https://doi.org/10.1109/RICE.2018.8509069>
- Robinson, T., & Metternicht, G. (2006). Testing the performance of spatial interpolation techniques for mapping soil properties. *Computers and electronics in agriculture*, 50(2), 97-108. <https://doi.org/10.1016/j.compag.2005.07.003>
- Rumelhart, D. E., McClelland, J. L., & PDP Research Group, C. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition, Volume1: Foundations*. MIT press. <https://doi.org/10.1109/JSAC.2023.3287614>
- Ryu, J.S., Kim, M.S., Cha, K.J., Lee, T. H., & Choi, D.H. (2002). Kriging interpolation methods in geostatistics and DACE model. *KSME International Journal*, 16, 619-632. <https://doi.org/10.1007/BF03184811>
- Tourani, M., Agh-Atabai, M., & Roostaei, M. (2018). Study of subsidence in Gorgan using InSAR method. *Geographical Planning of Space*, 8(27), 117-128. https://gps.gu.ac.ir/article_65973_en.html?lang=fa [In Persian]

- Wackernagel, H. (2003). *Multivariate Geostatistics*, 3rd éd. In: Springer Verlag, Berlin Heidelberg. <https://doi.org/10.1007/BF02769635>
- Waltham, A. (1989). *Ground subsidence*: Blackie & Son Limited. First published. <https://www.taylorfrancis.com/chapters/mono/10.1201/9781482267785-29/ground-subsidence-tony-waltham>.
- Wang, K., Zhang, C., & Li, W. (2013). Predictive mapping of soil total nitrogen at a regional scale: a comparison between geographically weighted regression and cokriging. *Applied Geography*, 42, 73-85. <https://doi.org/10.1016/j.apgeog.2013.04.002>.
- Zou, J., Han, Y., & So, S.S. (2009). Overview of artificial neural networks. *Artificial neural networks: methods and applications*, 14-22. https://doi.org/10.1007/978-1-60327-101-1_2.