

Research Paper

The Effect of Land Use Changes and Climate on Land Subsidence in the Darab Plain of Fars Province

Fatemeh Abedi¹, Ataollah Kavian², Leila Gholami³ and Vahid Mousavi⁴

1- Ph.D. Student, Department of Watershed Management, Faculty of Natural Resources, Sari University of Agricultural Sciences and Natural Resources, Sari, Iran, (Corresponding author: fatemhabedi@gmail.com)

2- Professor, Department of Watershed Management, Faculty of Natural Resources, Sari University of Agricultural Sciences and Natural Resources, Sari, Iran

3- Associate Professor, Department of Watershed Management, Sari Faculty of Natural Resources, Sari University of Agricultural Sciences and Natural Resources, Sari, Iran

4- Assistant Professor, Department of Watershed Management, Faculty of Natural Resources, Tarbiat Modares University, Noor, Iran

Received: 18 July, 2025

Revised: 20 November, 2025

Accepted: 22 December, 2025

Extended Abstract

Background: Land subsidence (LS) is a morphological phenomenon occurring worldwide. In general, land subsidence can lead to a decrease in the Earth's surface in all regions of the globe, caused by either natural or human activities. LS and human activities have been intertwined throughout history. Recently, more than 150 major countries, including Mexico, Australia, Colombia, China, and the United States, have reported instances of LS. This phenomenon affects many regions of the world and can result from various natural or human factors, particularly the extraction of groundwater, mining activities, and the dissolution of mineral resources. Numerous reports emphasize that groundwater resources in extensive areas of central, eastern, and southern Iran are utilized as the sole source of water for agricultural, drinking, and industrial purposes. Iran consists of six major watersheds and 609 plains, with approximately 267 of them facing water scarcity. Given the significance of the Darab region in Fars Province as a key area prone to LS, the objectives of this study are (1) spatial modeling of LS in the Darab plain of Fars Province, (2) evaluating machine learning models individually for spatial modeling of land subsidence, and (3) identifying key factors affecting LS, including the effects of climate change and land use changes in the study area.

Methods: Sentinel-2 images from the years 2015 and 2024 were utilized for image classification to identify land use patterns and create Land Use/Land Cover (LULC) maps for the Darab region. The land uses, such as orchards, pastures, agricultural lands, urban areas, and barren lands, are observable in the region and have been analyzed for their impact on LS.

The data used to extract the LS map in this study included the C band of the ascending Sentinel-1A, the descending Sentinel-1A band, Interferometric Wide (IW) images, and strip mode images collected before and after subsidence, selected as empirical data. Climate data on temperature and precipitation from six existing stations in the area for the years 2015-2024 were prepared and interpolated using the IDW (Inverse Distance Weighting) method within ArcGIS, with a spatial resolution of 30 meters for digital modeling. Additionally, groundwater level maps of the plain were interpolated using the IDW method with ArcGIS, based on piezometric well statistics from 2002 to 2021. All informational or auxiliary layers were prepared in raster format with a pixel size of 10 meters. To perform the modeling process, the satellite imagery and DEM (Digital Elevation Model) of the area were first extracted using ArcGIS 10.7, after which the satellite images and DEM were imported into SAGAGIS software. The obtained data were then input into JMP software and the R environment for random forest modeling.

Results: Seven LS maps from 2015 to 2024 were extracted using Snap software. Using ArcGIS, an average was calculated from the images, revealing an average LS of about 11 cm during this period. Based on the land use change map from 2015 to 2024 and its correlation with the corresponding LS map for the same period, the greatest subsidence was observed in areas designated as orchards, residential, and agricultural lands. According to the results, the parameters that had the most significant impact on the modeling were groundwater level, temperature, and precipitation, respectively, with a wetness index being noteworthy. Among the machine learning models assessed in this study, the Random Forest (RF) model provided the best results, showing



a higher coefficient of determination ($R^2 = 0.95$ (Training), 0.93 (Validation)) and a lower Root Mean Square Error (RMSE = 0.001 (Training), 0.002 (Validation)).

Conclusion: In the present study, a direct relationship was observed between the increase in groundwater depth and the increase in land subsidence (LS) in the region. Based on the results of the Random Forest model and SHAP analysis, the most influential factors on subsidence, in order of importance, were groundwater level, temperature, precipitation, and the topographic wetness index. Based on the regression maps and validation parameters, among the predictive models used in this study, the Random Forest (RF) model provided the best results, showing a higher coefficient of determination ($R^2 = 0.95$ (Training), 0.93 (Validation)) and a lower Root Mean Square Error (RMSE = 0.001 (Training), 0.002 (Validation)). Creating such conditions and the situation surrounding LS and its hazardous consequences for the country requires a national commitment to acknowledge and address this phenomenon as a significant threat that could lead to disaster. Understanding this issue necessitates an increase in studies aimed at fully identifying prone areas as part of a national plan.

Keywords: Sentinel images, groundwater, root mean square error, Random Forest model (RF), radar interferometry (InSAR)

How to Cite This Article: Abedi, F., Kavian, A., Gholami, L., & Mousavi, V. (2026). The Effect of Land Use Changes and Climate on Land Subsidence in the Darab Plain of Fars Province. *J Watershed Manage Res*, 17(1), 17-32. DOI: 10.61882/jwmr.2026.1298



مقاله پژوهشی

بررسی اثر تغییرات کاربری اراضی و اقلیم بر فرونشست زمین در دشت داراب استان فارس

فاطمه عابدی^۱، عطاالله کاویان^۲، لیلا غلامی^۳ و وحید موسوی^۴^۱- دانشجوی دکتری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران، (نویسنده مسوول: fatemhabedi@gmail.com)^۲- استاد، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران^۳- دانشیار، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران^۴- استادیار، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، نور، ایران

تاریخ پذیرش: ۱۴۰۴/۱۰/۰۱

تاریخ ویرایش: ۱۴۰۴/۰۸/۲۹
صفحه: ۱۷ تا ۳۲

تاریخ دریافت: ۱۴۰۴/۰۴/۲۷

چکیده مبسوط

مقدمه و هدف: فرونشست زمین (LS) یک پدیده مورفولوژیکی است که در سطح جهان در حال وقوع است. به طور کلی، فرونشست زمین می تواند منجر به کاهش سطح زمین در تمامی مناطق کره زمین شود که این امر ناشی از فعالیت های طبیعی یا انسانی است. فرونشست زمین و فعالیت های انسانی در تمام تاریخ در هم تنیده بوده اند. اخیراً، بیش از ۱۵۰ کشور عمده، از جمله مکزیک، استرالیا، کلمبیا، چین و ایالات متحده، گزارش هایی در مورد فرونشست زمین ارائه داده اند. این پدیده بر بسیاری از مناطق جهان تأثیر می گذارد و می تواند ناشی از عوامل مختلف طبیعی یا انسانی، به ویژه برداشت آب های زیرزمینی، استخراج معادن، حل شدن مواد معدنی باشد. گزارش های متعددی بر این موضوع تأکید دارند که منابع آب زیرزمینی در مناطق وسیع از مرکز ایران و شرق و جنوب ایران به عنوان تنها منبع آب برای مصارف کشاورزی، شرب و صنعتی مورد استفاده قرار می گیرند. ایران شامل شش حوضه آبریز اصلی و ۶۰۹ دشت است که تقریباً ۲۶۷ مورد از آن ها دچار کمبود آب هستند. با توجه به اهمیت منطقه داراب در استان فارس به عنوان یک مکان کلیدی مستعد فرونشست زمین، اهداف این مطالعه عبارتند از: (۱) مدل سازی فضایی فرونشست زمین در دشت داراب استان فارس، (۲) ارزیابی مدل های یادگیری ماشین به صورت جداگانه برای مدل سازی فضایی فرونشست زمین، و (۳) شناسایی عوامل کلیدی مؤثر بر فرونشست زمین شامل اثرات تغییر اقلیم و تغییرات کاربری اراضی در منطقه مورد مطالعه.

مواد و روش ها: تصاویر Sentinel_2 سال های ۲۰۱۵ و ۲۰۲۴ برای طبقه بندی تصاویر به منظور شناسایی الگوهای کاربری اراضی و ایجاد نقشه های LULC منطقه داراب استفاده شد، که کاربری های باغ، مرتع، اراضی کشاورزی، مناطق شهری و اراضی بایر در منطقه قابل مشاهده بودند و برای بررسی اثر آن بر فرونشست زمین در منطقه داراب استفاده شد. داده های مورد استفاده به منظور استخراج نقشه فرونشست زمین در این مطالعه، باند Sentinel-1A C و Sentinel-1A نژولی، تداخل سنجی گسترده (IW) و تصاویر حالت نوار قیل و بعد از نشست به عنوان داده های تجربی انتخاب شدند. داده های اقلیمی دما و بارش مربوط به شش ایستگاه موجود در منطقه برای بازه سال های ۲۰۱۵ تا ۲۰۲۴ تهیه و با استفاده از روش IDW در محیط ArcGIS به قدرت تفکیک مکانی ۳۰ متر درون یابی و به منظور مدل سازی رقومی شدند. همچنین با استفاده از آمار چاه های پیرومتری مربوط به سال های ۲۰۰۲ تا ۲۰۲۱ منطقه نقشه های تراز آب زیرزمینی دشت با کمک نرم افزار ArcGIS و مدل IDW درون یابی گردیدند. تمام لایه های اطلاعاتی یا کمکی به فرمت رستری با اندازه پیکسل ۱۰ متری تهیه شدند. برای انجام فرآیند مدل سازی در آغاز به وسیله نرم افزار ArcGIS10.7 محدود تصاویر ماهواره ای و DEM منطقه استخراج و سپس تصاویر ماهواره ای و DEM منطقه وارد محیط نرم افزار SAGAGIS گردیدند. سپس، داده های به دست آمده جهت مدل سازی جنگل تصادفی وارد نرم افزار JMP و محیط نرم افزار R شدند.

یافته ها: تعداد هفت نقشه فرونشست زمین از سال ۲۰۱۵ تا ۲۰۲۴ با کمک نرم افزار Snap استخراج شدند. با کمک نرم افزار ArcGIS میانگینی بین تصاویر گرفته شد که مقدار میانگین فرونشست زمین در این بازه سالی حدود ۱۱ سانتی متر بود. با توجه به نقشه تغییرات کاربری اراضی سال ۲۰۱۵ تا ۲۰۲۴ و تطابق آن ها با نقشه فرونشست زمین (LS) مربوط به همین بازه سالی، بیشترین نشست در مناطقی با کاربری باغ، مسکونی و کشاورزی قابل مشاهده بود. با توجه به نتایج، به ترتیب بیشترین تأثیر در مدل سازی را پارامترهای تراز آب زیرزمینی، دما و بارش، و شاخص خیزی دارند. در بین مدل های یادگیری مورد بررسی در این پژوهش، ماشین مدل جنگل تصادفی (RF) با ضریب تبیین بالاتر ($R^2=0.95(Training)$, $0.93(validation)$) و خطای جذر میانگین مربعات پایین تر ($RMSE=0.001(Training)$, $0.002(validation)$) بهترین نتیجه را ارائه داد.

نتیجه گیری: در پژوهش حاضر، رابطه مستقیمی بین افزایش عمق آب زیرزمینی و افزایش نرخ فرونشست زمین مشاهده شد. بر اساس نتایج مدل جنگل تصادفی و تحلیل SHAP، مهم ترین عوامل مؤثر بر فرونشست به ترتیب عبارت بودند از: سطح آب زیرزمینی، دما، بارش و شاخص رطوبت توپوگرافی. با توجه به نقشه های رگرسیونی و پارامترهای اعتبارسنجی از بین مدل های پیش بینی مورد استفاده در این پژوهش، مدل RF با ضریب تبیین بیشتر ($R^2=0.95(Training)$, $0.93(validation)$) و خطای جذر میانگین مربعات کمتر ($RMSE=0.001(Training)$, $0.002(validation)$) بهترین نتیجه را ارائه داد. ایجاد چنین شرایط و وضعیتی در رویداد پدیده فرونشست و پیامدهای مخاطره آمیز آن برای کشور، قبل از هر چیز عزم ملی برای پذیرش و مقابله با این پدیده به عنوان یک معضل و مخاطره منتهی به یک فاجعه را طلب می نماید. موضوعی که درک آن از یک سو مستلزم افزایش مطالعات برای شناسایی کامل نواحی مستعد به صورت یک طرح ملی است.

واژه های کلیدی: تصاویر Sentinel، آب زیرزمینی، خطای جذر میانگین مربعات، مدل جنگل تصادفی (RF)، تداخل سنجی راداری (InSAR)

مقدمه

سطح زمین در تمامی مناطق کره زمین شود که این امر ناشی از فعالیت های طبیعی یا انسانی است (Herrera-García et al., 2021). فرونشست زمین و فعالیت های انسانی در تمام تاریخ در هم تنیده بوده اند (Rahmati et al., 2019). اخیراً،

فرونشست زمین (LS)^۱ یک پدیده مورفولوژیکی است که در سطح جهان در حال وقوع است (Chitsazan et al., 2022). به طور کلی، فرونشست زمین می تواند منجر به کاهش

^۱ Land Subsidence (LS)

(Eghrari et al., 2023). یادگیری ماشین نسبت به روش‌های سنتی مبتنی بر آمار مزیت قابل توجهی دارد، به‌ویژه در علوم زمین و بوم‌شناسی، زیرا می‌تواند داده‌های پیچیده با ابعاد بالا را مدیریت کند که شامل تعاملات پیچیده و مقادیر گمشده نیز می‌شود (Chitsazan et al., 2022). بسیاری از محققان از الگوریتم‌های یادگیری ماشین مبتنی بر GIS در حوزه‌های مختلف علوم زمین و هیدرولوژی استفاده کرده‌اند، مانند نقشه‌برداری آب‌های زیرزمینی (Naghbi et al., 2016; Kariminejad et al., 2019; Arabameri et al., 2023). بررسی اثرات تغییر اقلیم نقش مهمی در تحلیل فرونشست زمین ایفا می‌کند. تغییرات دما، الگوهای بارش غیرقابل پیش‌بینی یا افزایش شدت پدیده‌هایی مانند خشکسالی ممکن است منجر به تغییراتی اساسی در میزان منابع آب زیرزمینی گردند که خود عاملی مؤثر در ایجاد فرونشست است. همچنین، تغییرات کاربری اراضی ناشی از توسعه شهری و کشاورزی تأثیر زیادی بر رفتار خاک دارد. این تغییرات ممکن است منجر به کاهش ظرفیت منابع آب زیرزمینی شوند یا ظرفیت جذب خاک را کاهش دهند. با توجه به اهمیت منطقه داراب در استان فارس به‌عنوان یک مکان کلیدی مستعد فرونشست زمین، اهداف این مطالعه عبارتند از: (۱) مدل‌سازی فضایی فرونشست زمین در دشت داراب استان فارس، (۲) ارزیابی مدل‌های یادگیری ماشین به‌صورت جداگانه برای مدل‌سازی فضایی فرونشست زمین، و (۳) شناسایی عوامل کلیدی مؤثر بر فرونشست زمین شامل اثرات تغییر اقلیم و تغییرات کاربری اراضی در منطقه مورد مطالعه.

مطالعاتی که تا کنون در دشت داراب در رابطه با بررسی فرونشست زمین انجام شده‌اند شامل گلی و همکاران (Gholi et al., 2019) که به ارزیابی آسیب‌پذیری سکونتگاه‌های روستایی ناشی از فرونشست زمین در استان فارس با مدل InSAR پرداختند. با استفاده از نقشه پهنه‌بندی خطر فرونشست، مشخص شد که به‌طور کلی ۱۰۵۵۲۳ نفر در محدوده خطر فرونشست زندگی می‌کردند که ۶۵۰۶۸ نفر آن در پهنه پرخطر قرار گرفتند. همچنین به‌ترتیب ۲۳۳۶ و ۳۴۳ زیرساخت و سرمایه اقتصادی در این پهنه قرار گرفتند که بیشترین تعداد در پهنه پرخطر واقع شده بودند. درنهایت، باید گفت که بیشتر نقاط روستایی منطقه مورد مطالعه در پهنه‌بندی خطر فرونشست، در پهنه پرخطر قرار می‌گیرند. هاشمی‌تنگستانی (Hashemi-Tangestani, 2017) اندازه‌گیری فرونشست زمین با استفاده از روش تداخل‌سنجی راداری تصاویر Sentinel-1؛ در حسن آباد، داراب، استان فارس را انجام داد. بیشینه نرخ میانگین فرونشست در منطقه مورد مطالعه ۵/۲ سانتیمتر در ماه در بازه زمانی سال ۱۳۹۵ برآورد شد. پس از آن، تأثیر تغییرات کاربری اراضی بر میزان فرونشست ارزیابی شد. علاوه بر این، رابطه بین کاربری اراضی و نرخ فرونشست پیش‌بینی شده و ترسیم میزان فرونشست بر اساس کاربری اراضی با استفاده از الگوریتم‌های یادگیری ماشین ارزیابی گردید. همچنین، با استفاده از مطالعات چاه‌های آب زیرزمینی، نمودار هیدروگراف واحد منطقه و انجام مشاهدات میدانی، نتایج حاصل از تداخل‌سنجی

بیش از ۱۵۰ کشور عمده، از جمله مکزیک، استرالیا، کلمبیا، چین و ایالات متحده، گزارش‌هایی را در مورد فرونشست زمین ارائه داده‌اند (Rahmani et al., 2022). این پدیده بر بسیاری از مناطق جهان تأثیر می‌گذارد (Bhattarai et al., 2017; Mohammady et al., 2019) و می‌تواند ناشی از عوامل مختلف طبیعی یا انسانی، به‌ویژه برداشت آب‌های زیرزمینی (Deng et al., 2017)، استخراج معادن، و حل شدن مواد معدنی (Pacheco et al., 2006) باشد. در ایران، بخش کشاورزی عمده‌ترین مصرف‌کننده منابع آب است. گزارش‌های متعددی بر این موضوع تأکید دارند که منابع آب زیرزمینی در مناطق وسیع از مرکز ایران و شرق و جنوب ایران به‌عنوان تنها منبع آب برای مصارف کشاورزی، شرب و صنعتی مورد استفاده قرار می‌گیرند. ایران شامل شش حوضه آبریز اصلی و ۶۰۹ دشت است که تقریباً ۲۶۷ مورد از آن‌ها دچار کمبود آب هستند. با توجه به نقش حیاتی آب در زندگی انسان و کشاورزی، بسیاری از این دشت‌ها دچار کمبود شده‌اند (Najafi et al., 2020). برداشت بیش از حد و تخلیه سفره‌های آب می‌تواند منجر به فرونشست زمین شود که می‌تواند به‌طور ناگهانی یا تدریجی با ترکیبی از عوامل طبیعی و انسانی بروز کند (Zhang et al., 2023; Gharechae et al., 2023). پیامدهای فرونشست زمین شامل آسیب‌های قابل توجه به زیرساخت‌ها، از جمله ساختمان‌ها، شبکه‌های حمل و نقل، سیستم‌های آبیاری و منابع زیرزمینی هستند (Cigna & Tapete, 2021). علاوه بر این، تغییرات کاربری اراضی و تغییرات اقلیمی نیز تأثیرات عمیق‌تری بر فرونشست زمین دارند. تغییر کاربری اراضی از مراتع به کشاورزی و توسعه شهری یا صنعتی می‌تواند فشار بیشتری بر منابع آب زیرزمینی وارد کند و در نتیجه، نرخ فرونشست را افزایش دهد. همچنین، تغییرات اقلیمی که منجر به تغییر الگوهای بارش و دما می‌شوند، می‌توانند بر توان ذخیره‌سازی آب‌های زیرزمینی و چرخه هیدرولوژیک تأثیر بگذارند و مشکلات بیشتری در مدیریت منابع آب ایجاد کنند. فراتر از تغییرات محیطی، فرونشست زمین بر فعالیت‌های اجتماعی و اقتصادی تأثیر می‌گذارد. علاوه بر این اثرات مستقیم، چندین نتیجه غیرمستقیم نیز شامل می‌شوند، از جمله کاهش ظرفیت ذخیره آب‌های زیرزمینی، آلودگی آب و افزایش خطرات سیلاب (Nhu et al., 2020). برای حفاظت از اراضی کشاورزی حاصل‌خیز و زیرساخت‌ها در برابر فرونشست، بهینه‌سازی نقشه‌برداری فرونشست زمین ضروری است، به‌طوری‌که برنامه‌ریزان استفاده از زمین، بتوانند منابع را به‌صورت پایدار مدیریت کنند (Mohammady et al., 2019). در سراسر جهان، برای ارزیابی قابلیت فرونشست زمین در مناطق مختلف، روش‌های متفاوتی به‌کار گرفته می‌شوند. به‌عنوان مثال، روش‌های داده‌کاوی و مدل‌های یادگیری ماشین ثابت کرده‌اند که در انجام مطالعات ضروری برای کنترل بهینه فرونشست زمین و کاهش خطرات بالقوه آن مؤثر هستند (Rahmati et al., 2019). الگوریتم‌های یادگیری ماشین یکی از بهترین رویکردها برای اولویت‌بندی و تعیین اهمیت عواملی هستند که بر عملکرد فرونشست زمین تأثیر دارند


دشت داراب استان فارس می‌پردازد. شناخت روابط بین تغییرات کاربری اراضی و اقلیم با فرونشست زمین، امکان توسعه برنامه‌های مدیریتی مؤثر برای حفظ منابع آب و خاک را فراهم می‌کند و مدیریت پایدار منابع آبی می‌تواند به کاهش تأثیرات منفی فرونشست کمک کند (Fathian *et al.*, 2021). همچنین، از محصولات سنجش‌ازدور نوری برای پهنه‌بندی تغییرات سطح اراضی، همراه با بررسی میزان فرونشست با استفاده از روش تداخل‌سنجی راداری (InSAR^3) برای بخشی از دشت داراب استفاده شد. این تحقیق می‌تواند مبنای علمی برای سیاست‌گذاری‌های کشاورزی و مدیریت منابع طبیعی در دشت داراب باشد و به سایر مناطق با چالش‌های مشابه نیز تعمیم یابد. علاوه بر این، اطلاعات حاصل از این تحقیق می‌تواند به عنوان راهنمایی برای برنامه‌ریزی شهری و کشاورزی پایدار مورد استفاده قرار گیرد (Bai *et al.*, 2019).

مواد و روش‌ها منطقه مورد مطالعه


منطقه مورد مطالعه به وسعت تقریبی $2464/43$ کیلومتر مربع در جنوب استان فارس در عرض جغرافیایی 28° و $28^\circ 47'$ و $28^\circ 54'$ شمالی و طول جغرافیایی 54° و $54^\circ 28'$ شرقی واقع است (شکل ۱). از لحاظ توپوگرافی، حداکثر ارتفاع منطقه از سطح دریای آزاد حدود 2150 متر و کمترین مقدار آن 1004 متر هستند. متوسط بارندگی و درجه حرارت سالیانه منطقه به ترتیب 255 میلی‌متر و 22 درجه سانتی‌گراد هستند. این منطقه مطابق تقسیم‌بندی دومارتن، دارای آب‌وهوای گرم و خشک است. بیش‌تر بارندگی محدوده مورد مطالعه در دوره سرد سال رخ می‌دهد و دی‌ماه پر باران‌ترین ماه سال است. در تابستان به دلیل دور بودن منابع رطوبتی و مسیرهای ورودی بخار آب و گاهی نبودن عامل صعود، هوای بسیار گرم و خشک کویری پیدا می‌کند (Abedi *et al.*, 2021). فلوچارت مطالعاتی این مطالعه در شکل ۲ قابل مشاهده است.

مورد بررسی و مطالعه قرار گرفت. یوسفی و همکاران (Yousefi *et al.*, 2023) به درک اثرات فرونشست بر پارامترهای آبخوان نامحدود با ادغام شبکه روش بولتزمن (LBM^1) و الگوریتم ژنتیک (GA^2) در دشت داراب پرداختند. میانگین خطای نسبی کوچک ($\sim 3/5\%$) بین فرونشست زمین پیش‌بینی‌شده و اندازه‌گیری‌های InSAR ، عملکرد بالایی رویکرد مدل‌سازی پیشنهادی را نشان می‌دهد. همچنین، مطالعات جدید در خارج از کشور شامل رن و همکاران (Ren *et al.*, 2024) که به درک فرونشست زمین در منطقه دلتای رودخانه مروارید چین بر اساس مشاهدات InSAR پرداختند. فرونشست در منطقه مورد مطالعه از یک الگوی خطی متمایز با یک بازگشت جزئی پیروی می‌کند که به‌طور بالقوه با افزایش سطح آب زیرزمینی مرتبط است. مناطقی با ضخامت رسوبات کواترنری بیش از 20 متر، درگیر در فعالیت‌های آبی‌پرووری یا کشاورزی و دارای زمین‌های احیا شده، مستعد فرونشست زمین طولانی و شدید هستند. علاوه بر این، ساخت و بهره‌برداری از خطوط مترو ممکن است باعث فرونشست زمین، به ویژه در مناطق آسیب‌پذیر زمین‌شناسی شود. در مطالعه جین و همکاران (Jin *et al.*, 2024)، چارچوب ارزیابی ریسک پیشرفته برای اثرات فرونشست زمین بر دکل‌های انتقال در منطقه فلات تبت در چین بررسی شد. نتایج حساسیت بر اساس مدل جنگل تصادفی با بهینه‌سازی گرگ خاکستری (GW0-RF) بهترین اثر مدل‌سازی را نشان دادند. نتایج آسیب‌پذیری نشان می‌دهند که 105 عدد دکل به‌شدت توسط فرونشست زمین آسیب دیده‌اند. نقشه توزیع خطر نشان می‌دهد که بخش مرکزی منطقه فلات تبت در چین منطقه اصلی برای مدیریت خطر فرونشست زمین در آینده است. در مجموع، 101 برج در سطح خطر بالا و بسیار بالا قرار دارند. در منطقه داراب، به دلیل مشغولیت عمده مردم به کشاورزی و باغداری و افزایش جمعیت، نیاز به تغییر کاربری مراتع و تغییرات اقلیمی وجود دارد. با این حال، پژوهش‌های کمی در مورد تأثیر تغییرات کاربری اراضی بر مقادیر فرونشست زمین انجام شده‌اند؛ بنابراین، این پژوهش به بررسی این موضوع در

³ Interferometric Synthetic Aperture Radar¹ Lattice Boltzmann Method² Genetic Algorithm



شکل ۱- نقشه منطقه مورد بررسی در ایران و استان فارس و مکان نقاط تعلیمی (Exploitation Points) به منظور مدل سازی
Figure 1. The map of the study area in Iran and Fars Province, and the locations of the training points (Exploitation Points) for modeling purposes.



شکل ۲- فلوچارت مطالعاتی
Figure 2. The study flowchart

شبکه‌های جاده‌ای، گسل‌ها و رودخانه‌ها نیز از این سازمان تهیه شدند. در محیط نرم‌افزاری ArcGIS، با بهره‌گیری از روش فاصله اقلیدسی^۱، فاصله از جاده‌های اصلی، گسل‌ها و رودخانه‌ها محاسبه گردید (Lukas *et al.*, 2023). داده‌های مورد استفاده در این مطالعه شامل باند راداری ماهواره Sentinel-1A (گذر صعودی) و باند راداری ماهواره Sentinel-1A (گذر نزولی) همراه با تصاویر حالت نوار و داده‌های تداخل‌سنجی گسترده (IW) قبل و بعد از رویداد نشست بودند که به عنوان داده‌های تجربی انتخاب شدند (جدول ۱). همچنین، مدل رقومی ارتفاعی (DEM) با قدرت تفکیک مکانی ۳۰ متر که توسط سازمان ناسا در سال ۲۰۰۷ تولید شد، مورد استفاده قرار گرفت (Farr *et al.*, 2007).

جمع‌آوری و پردازش داده‌ها

تصاویر ماهواره‌ای Sentinel-2 مربوط به سال‌های ۲۰۱۵ و ۲۰۲۴ با قدرت تفکیک مکانی ۱۰ متر تهیه شدند و به منظور طبقه‌بندی و شناسایی الگوهای کاربری اراضی و همچنین تهیه نقشه‌های پوشش و کاربری اراضی (LULC) مورد استفاده قرار گرفتند. این تصاویر با پوشش ابری کمتر از ۵ درصد انتخاب شدند تا کیفیت داده‌ها حفظ شود و شرایط آب‌وهوایی در طول دوره مطالعاتی یکنواخت باقی بمانند. تصاویر Sentinel-2 از Alaska از طریق پورتال وبسایت <https://search.asf.alaska.edu> دریافت شدند. از باندهای مرئی (قرمز، سبز و آبی) مربوط به تصاویر ماهواره‌ای Sentinel-2، یعنی باندهای ۴، ۸ و ۱۱، استفاده شد. مدل رقومی ارتفاعی (DEM) با دقت ۱۰ متر از سازمان زمین‌شناسی اخذ گردید. داده‌های مرتبط با حمل‌ونقل،

¹ Euclidean distance

جدول ۱- تصاویر SAR ماهواره‌ای مورد استفاده در پژوهش حاضر و پارامترهای آن‌ها


Table 1. Satellite SAR images used in this study and their parameters

ماهواره Satellite	حالت تصویر Image Mode	جهت مدار Orbit Direction	طول موج (سانتی‌متر) Wavelength (cm)	تفکیک زمانی (روز) Temporal resolution (day)	تفکیک مکانی (متر) Spatial Resolution (meters)	زاویه تابش مرکزی Central incidence angle
Sentinel-1A	IW swath	Ascending	5.6	12	2.33 × 13.99	39.5849°
Sentinel-1A سنیتیل 1A	IW swath	Descending نزولی	5.6	12	2.33 × 13.99	43.9305°

تغییرات کاربری و پوشش زمین در دشت داراب از سال ۲۰۱۵ تا ۲۰۲۴

نقشه‌های پوشش و کاربری اراضی (LULC) منطقه داراب برای سال‌های ۲۰۱۵ تا ۲۰۲۴ در پنج طبقه، در محیط نرم‌افزاری Google Earth Engine طبقه‌بندی شدند. براساس تصاویر ماهواره‌ای Sentinel-2، این منطقه در بازه زمانی یادشده با کاهش چشمگیر سطح مراتع و افزایش قابل توجه اراضی بایر روبه‌رو بوده است. بیشترین تغییرات کاربری

اراضی نیز مربوط به تبدیل مراتع (مناطق با پوشش گیاهی طبیعی متشکل از علف‌ها و گیاهان علفی) به اراضی بایر (مناطق فاقد پوشش گیاهی) بوده است. مناطق کشاورزی، باغی و شهری به‌عنوان عمده‌ترین انواع کاربری اراضی که منطقه را پوشش می‌دهند، شناسایی شدند (شکل ۳). جدول ۲، مساحت کل و درصد پوشش هر یک از کاربری‌ها را برای سال ۲۰۱۵ تا سال ۲۰۲۴ (Sentinel-2) ارائه می‌دهد.



شکل ۳- تغییرات کاربری‌های مختلف اراضی از سال ۲۰۱۵ (A) تا سال ۲۰۲۴ (B)
Figure 3. Changes in various land uses from 2015 (A) to 2024 (B)

جدول ۲- پوشش کل مساحت (بر حسب کیلومتر مربع) طبق کلاس‌های مختلف LULC و درصد پوشش (%) برای سال‌های ۲۰۱۴ تا سال ۲۰۲۴

Table 2. Total area coverage (in square kilometers) according to different LULC classes and percentage coverage (%) from 2015 to 2024

Area (%)		Area (km ²)		تغییر کاربری و پوشش زمین	
Δ	2024	2015	Δ	2024	2015
-11.56	38.06	49.62	-284.16	935.77	1219.92
10.25	31.61	21.35	252.03	777	524.97
-1.61	2.52	4.12	-39.47	61.86	101.34
2.26	23.86	21.60	55.65	586.57	530.92
0.65	3.95	3.30	15.95	97.18	81.23
					Residential areas

همه آنها شامل مراحل پردازش مشابهی مانند ثبت تصویر، تولید تداخل گرام‌ها، تخمین خط پایه فضایی، بازکردن فاز، تخمین پارامتر، و ساخت شبکه مرجع هستند (Xue *et al.*, 2020). در این پژوهش، الگوریتم سری زمانی InSAR (Berardino *et al.*, 2002) برای محاسبه تداخل‌نگارهای

بررسی فرونشست زمین

اگرچه چارچوب‌های پردازش سری زمانی InSAR بسیار زیاد و متنوع هستند، اما همگی آنها از یک اصل اساسی مشترک یعنی استفاده از فاز سه‌بعدی مکانی-زمانی برای استخراج سیگنال مورد نظر استفاده می‌کنند. علاوه بر این،

و B12) دارای قدرت تفکیک مکانی ۲۰ متر دارند. سرانجام، آئروسل ساحلی آن (B1) و باند سیروس (B10) اندازه پیکسل ۶۰ متری دارند. همچنین برای کاهش تعداد اطلاعات خام (تعداد طیف‌ها) تصویر ماهواره‌ای تعدادی پارامترها از قبیل شاخص شوری^۹، شاخص گیج^{۱۱}، شاخص روشنایی^{۱۲} (نشان دهنده ترکیبات زمین‌شناسی مواد سطحی)، شاخص کربنات^{۱۳}، شاخص رس^{۱۴} و شاخص گیاهی نرمال شده^{۱۵} (نشان دهنده وضعیت پوشش گیاهی) برای تخمین فرونشست زمین استفاده گردید (جدول ۳) (Abedi et al., 2021).

پارامترهای مربوط به LULC و تراز آب زیرزمینی

با استفاده از نقشه‌های کاربری زمین (LULC) در سال‌های ۲۰۱۵ تا ۲۰۲۴ و با بهره‌گیری از نرم‌افزار TerrSet، نقشه‌های مربوط به فاصله از باغ‌ها، مناطق مسکونی و اراضی کشاورزی استخراج شدند (جدول ۳) عابدی و همکاران (Abedi et al., 2021). همچنین، اطلاعات مربوط به زمین، شامل داده‌های حمل و نقل، شبکه‌های جاده‌ای، گسل‌ها و رودخانه‌ها، از سازمان زمین‌شناسی دریافت گردید. در محیط ArcGIS، به منظور تعیین فاصله از جاده‌های اصلی، گسل‌ها و رودخانه‌ها، از روش فاصله اقلیدسی استفاده شد. علاوه بر این، با بهره‌گیری از آمار چاه‌های پی‌زومتری مربوط به سال‌های ۲۰۰۲ تا ۲۰۲۱، نقشه‌های تراز آب زیرزمینی دشت با استفاده از نرم‌افزار ArcGIS و مدل IDW (درون‌یابی فاصله‌ای معکوس وزنی) تهیه شدند. در شکل ۳، مهم‌ترین پارامترهای تأثیرگذار در مدل‌سازی یادگیری ماشین این مطالعه با استفاده از نرم‌افزار R Studio و مدل جنگل تصادفی تعیین شده‌اند. ترتیب تأثیر این پارامترها در مدل‌سازی در شکل ۵ قابل مشاهده است.

آماده‌سازی داده‌ها

تمام لایه‌های اطلاعاتی یا کمکی به فرمت رستری با اندازه پیکسل ۱۰ متری تهیه شدند. این اطلاعات به‌عنوان پارامترهای مستقل در مدل شناخته می‌شوند. تمام داده‌ها (پارامترهای محیطی) به فرمت نهایی txt تبدیل شدند. برای انجام فرآیند مدل‌سازی در آغاز به‌وسیله نرم‌افزار ArcGIS 10.7 محدود تصاویر ماهواره‌ای و DEM منطقه استخراج شدند. سپس، تصاویر ماهواره‌ای و DEM منطقه وارد محیط نرم‌افزار SAGAGIS شدند تا پارامترهای کمکی استخراج و تصاویر و نقشه‌ها رقومی شوند. داده‌های به‌دست آمده جهت آماده‌سازی و نظم دادن به داده‌های مستخرج از ساگا وارد محیط JMP شدند. جهت مدل‌سازی داده‌ها وارد محیط نرم‌افزار R گردیدند (Abedi et al., 2021).

تغییر شکل به‌کار گرفته شد و مقدار جابجایی هدف سطح در امتداد جهت LOS^۱ در هر مدار سکوی ماهواره استخراج گردید. به‌طور کلی، با ضرب مداوم سکوها ماهواره‌ای SAR، سنسورهای متعدد عمده‌تاً برای استخراج جابجایی سطح دو بعدی یا سه بعدی و سری‌های زمانی جابجایی حاصل استفاده شد تا تفسیر ناحیه تغییر شکل، دقیق‌تر شود (Wang et al., 2021; Hu et al., 2010; Dai et al., 2016; Wang et al., 2015). به‌طور کلی، ابتدا سیستم مختصات نشست بر اساس DEM کمکی ایجاد شد و با سیستم مختصات سه‌بعدی و سیستم مختصات SAR Range-Doppler (محدوده دامنه SAR) ترکیب گردید تا برآورد جابجایی سری زمانی نشست یک سکوی حسگر واحد محقق گردد. سپس، پس از تصحیح بایاس مدار و معرفی وزن‌دهی واریانس نویز مشاهده‌ای، از مدل ادغام هندسی فیلتر کالمن (KF^۲) برای ادغام سری‌های زمانی جابجایی زمین در هر سکوی و در نهایت، زمان پایش جابجایی نشست با وضوح زمانی بالا استفاده و سری با ابعاد یکپارچه تشکیل شد.

پارامترهای اقلیمی

داده‌های اقلیمی دما و بارش مربوط به شش ایستگاه موجود (ایستگاه نشان داده شده در شکل ۳ (b)) در منطقه از بازه سال‌های ۲۰۱۵ تا ۲۰۲۴ تهیه شده و با استفاده از روش IDW در محیط ArcGIS با قدرت تفکیک مکانی ۳۰ متر درون‌یابی (Taghizadeh Mehrjardie et al., 2014) و به‌منظور مدل‌سازی رقومی شد (Abedi et al., 2021).

استخراج عوارض سرزمین

بعد از آماده‌سازی DEM، از آن برای استخراج داده‌های کمکی یا تصاویر تخمین‌زننده استفاده گردید. پارامترهای زمین‌نما از قبیل شیب^۳، عمق دره^۴، مساحت حوزه‌های اصلاح شده^۵، شاخص رطوبت توپوگرافی^۶، ارتفاع بالای شبکه زهکشی^۷، شاخص بالای پشته با درجه تفکیک بالا^۸ و پارامترهای بیان شده در جدول ۳ در محیط نرم‌افزار ساگا^۹ محاسبه و استخراج گردید. راه‌کار خارج کردن همه متغیرهای ذکر شده در مطالعه هنگل و روسیتر (Hengl & Rossiter, 2003) شرح داده شده است. برنامه سنتنیل ۲ یک مأموریت تصویربرداری چندطیفی با وضوح بالا و توان تفکیک زمانی پنج روزه جهانی است. این ماهواره دارای ابزاری چند طیفی می‌باشد که مجموعاً دارای ۱۳ بلند با توان تفکیک مکانی ۱۰، ۲۰ و ۶۰ متری می‌باشد. این سنسور شامل باندهای آبی (B2)، سبز (B3)، قرمز (B4) و نزدیک مادون قرمز (B8)، دارای وضوح ۱۰ متر هستند. قرمز (B5)، مادون قرمز نزدیک (B7، B6 و B8A) و SWIR مادون قرمز با موج کوتاه (B11)

⁹ SAGA

¹⁰ Salinity Index

¹¹ Gypsum Index

¹² Brightness Index

¹³ Carbonate Index

¹⁴ Clay Index

¹⁵ Normalized difference vegetation index

¹ Line of Sight

² Kalman Filter

³ Slope


⁴ Valley depth

⁵ Modified catchments area

⁶ Wetness Index

⁷ Altitude above channel network

⁸ Multiresolution ridgetop flatness index (MrRTF)



شکل ۴- توزیع فضایی چهار متغیر کمکی مثالی که به عنوان مهمترین متغیرهای توضیحی در مدل سازی نقشه LS استفاده می شوند. به ترتیب: Piezometric level of water، سطح پیزومتری آب (a) Temperature (b) دما، (b) TWI، شاخص رطوبت توپوگرافی (c) Precipitation، بارش (d).

Figure 4. Spatial distribution of four auxiliary variables that are used as the most important explanatory variables in LS mapping modeling. In order: Piezometric level of water (a), Temperature (b); TWI, topographic wetness index (c), Precipitation (d).

جدول ۳- متغیرهای کمکی محیطی و منابع آنها برای مدل سازی نقشه LS (Abedi et al., 2021)

مکانی Spatial Resolution	مخفف Abbreviation	متغیرهای کمکی Auxiliary Variables	منابع Sources
250(m)	Temperature	(درجه سانتی گراد) دما Temperature	نقشه های اقلیمی Climate Maps
250(m)	Precipitation	(میلی متر) بارش Precipitation	
10(m)	DEM	ارتفاع (Elevation)	مدل رقومی ارتفاع DEM
10(m)	CNBL	سطح پایه شبکه کانال Base Level of the Channel Network	
10(m)	MRVBF	صافی کف دره با وضوح چندگانه Multiresolution index of Valley Bottom Flatness (MrVBF)	
10(m)	TWI	شاخص رطوبت توپوگرافی Wetness Index	
10(m)	Slope	شیب (درجه) (Slope)	
10(m)	LS-factor	فاکتور طول-شیب (Length-Slope Factor)	
10(m)	FlowA	تجمع جریان (Flow Accumulation)	
10(m)	ValleyDepth	عمق دره (Valley depth)	
10(m)	SurfaceArea	مساحت سطح (Catchment Area)	
10(m)	MRRTF	شاخص همواری دره با درجه تفکیک بالا Multiresolution index of Valley Bottom Flatness	
10(m)	LST	دمای سطح زمین (Land Surface Temperature)	
10(m)	MFeatures	ویژگی های مورفولوژی (Morphological Features)	
10(m)	Texture	بافت (Texture)	
10(m)	BrightnessIndex	شاخص روشنایی Brightness Index: $[(red)^2 + (NIR)^2] / 0.5$	تصاویر سنجش از راه دور Remote Sensing Images
10(m)	ClayIndex	شاخص خاک رس Clay Index: $(SWIR-1/SWIR-2)$	
10(m)	GypsumIndex	شاخص گچ GypsumIndex: $(SWIR-1 - NIR)/(SWIR-1 + NIR)$	
10(m)	CarbonateIndex	شاخص کربنات Carbonate Index: $(red/green)$	
10(m)	NDVI	تفاوت شاخص گیاهی نرمال شده Normalized difference vegetation index: $(NIR - Red)/(NIR + red)$	
10(m)	SAVI	شاخص پوشش گیاهی تعدیل شده با خاک Soil-Adjusted Vegetation Index: $(1-L)/(NIR-red)/(NIR + red+L)$	
10(m)	BSI	شاخص لختی خاک Bare Soil Index: $(NIR-red)/(NIR + C1 \times red - C2 \times blue + L)$	استفاده و پوشش زمین Land Use/Land Cover
10(m)	Urban	فاصله از مناطق شهری (Distance from urban areas)	
10(m)	Agriculture	فاصله از زمین های کشاورزی (Distance from agricultural land)	
10(m)	Garden	فاصله از باغات (Distance from gardens)	
30(m)	fault	فاصله از گسل (Distance From Fault)	پارامترهای مربوط به زمین Land-Related Parameters
30(m)	river	فاصله از رودخانه (Distance From River)	
30(m)	road	فاصله از جاده (Distance From Road)	
30(m)	Waterof Level	سطح آب زیرزمینی (Groundwater Level)	آب زیرزمینی Groundwater

مرحله پیش‌بینی

در آخر، پیش‌بینی میزان فرونشست در سال‌های مشخص با الگوریتم‌های یادگیری ماشین مدل جنگل تصادفی (RF)^۱ و درخت تصمیم (DT) در نرم‌افزار SASJMP و RStudio صورت گرفت که در ادامه درباره‌ی آن‌ها توضیح داده شده است.

جنگل تصادفی

یادگیری RF الگوریتم‌های داده کاوی هستند که در آنها چندین درخت تصمیم آموزش داده می‌شوند و نتایج میانگین پیش‌بینی‌های درختان منفرد هستند (Breiman, 2001). جنگل مجموعه‌ای از درختان تصادفی است که در آن هر درخت بر اساس یک نمونه بوت استرپ تصادفی از کل مجموعه آموزشی آموزش داده می‌شود. یک زیرمجموعه تصادفی انتخاب شده از متغیرهای توضیحی برای تنظیم قوانین برای تقسیم بازگشتی فضای ویژگی در هر گره به مناطق حاوی مشاهدات با مقادیر پاسخ مشابه استفاده می‌شود

جدول ۴- فرآپارامترهای مدل‌های یادگیری ماشین (Abedi et al., 2021)

پارامترهای تعریف شده Defined parameters	تعریف Definition	فرآپارامترهای Hyper-parameters	مدل Model
2-40	تعداد متغیرهای ورودی The number of input variables	mtry	RF
100-3000	تعداد درختان The number of trees	ntree	
2-20	حداقل تعداد مشاهدات در یک گره پایانی The minimum number of observations in a terminal node	nodesize	
5-20	تابع کرنل Kernel function	minsplit	
5.2-20.3	پارامتر پناهی Penalty parameter	minbucket	
0.01-0.05	پارامتر پهنای باند Bandwidth parameter	cp	

روش آماری

بررسی عملکرد روش‌های مختلف از طریق معیارهای برازش قابل مقایسه است. در ارزیابی روش‌های پیش‌بینی فرونشست در این تحقیق از خطای جذر میانگین مربعات و ضریب تبیین استفاده گردید (رابطه‌های ۱ و ۲) (Armstrong & Collopy, 1992).

رابطه (۱)

$$R^2 = 1 - \frac{\sum_{i=1}^n [(x_i) - (\bar{x})]^2}{\sum_{i=1}^n [(x_i) - (\bar{x})]^2}$$

رابطه (۲)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [(x_i) - (\hat{x}_i)]^2}$$

x_i داده‌های مشاهداتی و تخمین زده شده، $\bar{x}$ میانگین داده‌های مشاهداتی تخمین زده شده و n تعداد داده‌ها می‌باشد.

نتایج و بحث

نقشه‌های فرونشست زمین

هفت نقشه فرونشست زمین از سال ۲۰۱۵ تا سال ۲۰۲۴ با کمک نرم‌افزار SNAP استخراج شدند. از تصاویر Sentinel-

(Strobl et al., 2009). در کار رگرسیون، پیش‌بینی‌های همه درختان منفرد در نهایت میانگین می‌شوند تا یک پیش‌بینی واحد را ارائه کنند (جدول ۴).


درخت تصمیم

DT^۲ها یا یادگیری مبتنی بر درخت، الگوریتم‌های قدرتمندی هستند که روابط بین ورودی‌ها و خروجی‌های بالقوه را با استفاده از درخت تصمیم نشان می‌دهند. آنها حاوی گره‌ها و برگ‌هایی هستند که در آن مجموعه داده‌های آموزشی به گره ریشه معرفی می‌شوند و سپس به صورت بازگشتی برای بهینه‌سازی همگنی درون گره‌ها و ناهمگنی بین گره‌ها تقسیم می‌شوند. تقسیم در هر گره تصمیم بر اساس قوانینی است که از مجموعه‌ای از متغیرهای توضیحی تولید می‌شوند. تصمیمات نهایی با توجه به متغیر پاسخ در گره‌های پایانه (یعنی برگ‌ها) گرفته می‌شوند (جدول ۴) (Abedi et al., 2021).

۲ استفاده شد و با استفاده از روش تداخل سنجی راداری (InSAR) سپس با کمک نرم‌افزار ArcGIS و روش Raster Calculator میانگینی بین تصاویر گرفته شد که مقدار میانگین فرونشست زمین در این بازه سالی حدود ۱۱ سانتی متر بود (شکل ۵). همانند مطالعه حاضر، خرمی و همکاران (Khorami et al., 2019) تعیین فرونشست به روش تداخل سنجی راداری پراکنشگر دائمی را انجام دادند. آنها بیان کردند که نرخ فرونشست بسیار بالایی در نواحی شمال غرب و شمال شهر مشهد با بیشینه‌ای در حدود ۱۴ سانتی‌متر در سال داشت. در ادامه، شفیعی و همکاران (Shafiei et al., 2020) در دشت نورآباد (استان فارس) بررسی فرونشست آبخوان با استفاده از روش تداخل سنجی راداری را انجام دادند. نقشه‌های حاصل از فرونشست نشان دادند که نرخ نشست در هر سال میانگین چهار سانتی‌متر و طی بازه زمانی چهار ساله (۱۶ سانتی‌متر) بود. نتایج این مطالعات با مطالعه‌ی ما در برآورد فرونشست زمین در بازه ذکر شده همخوانی دارند.

^۲ Decision Tree


^۱ Random Forest



شکل ۵- میانگین نقشه LS مربوط به سال های ۲۰۱۵ تا ۲۰۲۴ در دشت داراب
Figure 5. The average LS map for the years 2015 to 2024 in the Darab Plain.

بیشترین حجم برداشت مربوط به شمال دشت است (شکل ۴). کاهش سطح آب زیرزمینی رابطه مستقیمی با افزایش فرونشست در منطقه داشته است (شکل ۶).

همچنین، با استفاده از آمار چاه های پیرومتری مربوط به سال های ۲۰۰۲ تا ۲۰۲۱ منطقه، نقشه های تراز آب زیرزمینی دشت با کمک نرم افزار ArcGIS و مدل IDW درونیابی شدند که سطح آب زیرزمینی از ۱۴۱۱ به ۱۴۲۹ متر رسید.



شکل ۶- اهمیت متغیرهای کمکی در مدل سازی LS با کمک الگوریتم SHAP
Figure 6. The importance of auxiliary variables in LS modeling using the SHAP algorithm


نتایج مدل‌سازی

اهمیت پارامترهای مختلف در مدل‌سازی

با توجه به شکل ۶، بیشترین تأثیر بر مدل‌سازی را پارامترهای تراز آب زیرزمینی، شاخص رطوبت توپوگرافی، دما و بارش دارند. در این مطالعه، نمودار SHAP یا "SHapley Additive exPlanations" به ما کمک می‌کند تا بفهمیم هر ویژگی چقدر بر خروجی مدل تأثیر دارد و جهت این تأثیر چگونه است. در نمودار فوق، محور افقی نشان‌دهنده مقدار SHAP (تأثیر ویژگی بر خروجی مدل) است و محور عمودی شامل لیستی از ویژگی‌ها است که در تحلیل داده‌های فرونشست استفاده شده‌اند. متغیر بارندگی به‌طور عمده تأثیر منفی بر پیش‌بینی فرونشست داشته است، به‌خصوص وقتی مقادیر آن بالا بوده‌اند (رنگ قرمز نشان‌دهنده مقادیر بالا است). دما نیز تأثیری مشابه با بارندگی دارد ولی شدت آن کمتر به نظر می‌رسد. شاخص رطوبت توپوگرافی دارای تأثیر نسبتاً قابل توجهی است که بالا بودن مقدار این شاخص در بیشتر موارد اثر مثبت داشته است. سطح آب زیرزمینی نیز نقش مهمی ایفا کرده است و تغییرات آن می‌تواند هم اثر مثبت و هم منفی بسته به مقادیر مختلف داشته باشند. حضور گسل‌ها اثرات متنوعی دارد اما بیشتر در جهت کاهش احتمال وقوع فرونشست عمل کرده‌اند. به‌طور کلی، نمودار نشان‌دهنده ترکیب پیچیده‌ای از عوامل طبیعی و انسانی مؤثر بر فرونشست زمین‌ها است که برخی دارای اثرات مستقیم‌تر مانند بارندگی هستند در حالی که برخی دیگر مثل گسل یا فعالیت‌های انسان‌ساخت مانند کشاورزی اثری پیچیده‌تر دارند.

در مطالعه نجفی و همکاران (Najafi et al., 2022)، رابطه بین LS و عوامل تأثیرگذار را با استفاده از روش «شاخص آماری دو متغیره (BSI)» بررسی کردند و نتایج آنها نشان می‌دهند که «تغییرات سطح آب زیرزمینی» مهم‌ترین عامل در وقوع LS است که با مطالعه ما همخوانی دارد (شکل ۵). محمدحسینی و شیخ شریعتی کرمانی

(Mohammadhasani & Shikh Shariate Kermani, 2021)، تعیین میزان فرونشست زمین با استفاده از تکنیک تداخل سنجی راداری را انجام دادند. به این منظور، با هم نهادسازی نقشه‌های فرونشست با لایه‌های کاربری اراضی نیز موید رخداد بیشینه عرصه نشست است که بالاترین میزان فرونشست به‌ترتیب به کاربری باغات و مرتع است و کاربری‌های منطقه مسکونی در رده‌های بعدی قرار دارند. در مطالعه ما نیز پارامترهای فاصله از باغ، شهر و کشاورزی از پارامترهای تأثیرگذار در وقوع LS هستند که با نتایج شکل ۵ مطالعه ما همخوانی دارد. ژو و همکاران (Zhou et al., 2016) آشکارسازی فرونشست زمین تحت کاربری‌های مختلف توسط تجزیه و تحلیل سری زمانی InSAR را انجام دادند. نتایج آنها نشان داد که میزان فرونشست زمین در این مناطق به‌طور معنی‌داری متفاوت بود. در این مطالعه، میزان فرونشست زمین با کاربری اراضی (کشاورزی، مسکونی و صنعتی) مرتبط شد و بین فرونشست زمین و سطح آب زیرزمینی همبستگی قوی وجود داشت. این مطالعه با مطالعه ما همخوانی دارد (رجوع به شکل‌های ۵ و ۲). میندرهود و همکاران (Minderhoud et al., 2018) رابطه بین کاربری اراضی و فرونشست را بررسی کردند. در نتیجه، الگوهای فضایی قابل مشاهده در فرونشست مشاهده شده را می‌توان تا حد زیادی با کاربری اراضی زمین توضیح داد. در مطالعه ما نیز رابطه همبستگی منفی بین فرونشست زمین و سطح آب زیرزمینی و اقلیم وجود دارد (شکل ۶). علبدینی و همکاران (Abedini et al., 2021) بررسی فرونشست دشت با استفاده از روش تداخل سنجی راداری را انجام دادند. نتایج نشان دادند که بیشترین نرخ فرونشست در بازه زمانی ۲۰۱۵-۲۰۲۰، ۱۵ سانتی‌متر محاسبه گردید که این مقدار به‌سمت غرب و مرکز دشت کاهش یافت به‌صورتی که در قسمت غرب دشت، کمترین مقدار فرونشست مشاهده گردید. پیامد این افت سطح آب زیرزمینی منجر به ایجاد فرونشست در منطقه گردید.



شکل ۷- نمودار پراکنشی برای نمایش ضریب همبستگی بین نقاط با LS واقعی و LS پیش‌بینی شده مربوط به نقاط تعلیمی
Figure 7. The scatter plot showing the correlation coefficient between points with actual LS and predicted LS for the training points

¹ Bivariate Statistical Index

جدول ۴- آماره‌های واسنجی و اعتبارسنجی برای مدل‌های مورد استفاده

Table 4. Validation Statistics for the Models Used			
مدل یادگیری Model	RMSE	R2	
	واسنجی (Training)	اعتبارسنجی (Validation)	اعتبارسنجی (Validation)
RF	0.001	0.002	0.95
DT	0/002	0/003	0/93

عملکرد مدل

با توجه به ضرایب تعیین و پارامترهای اعتبارسنجی، مدل RF با مقدار با ضریب همبستگی بالاتر ($R^2=0.95$ (Training), 0.93 (validation)) و خطای جذر میلنگین مربعات پایین‌تر ($RMSE=0.001$ (Training), 0.002 (validation)) بهترین نتیجه را ارائه می‌دهد که با نتایج آذرخش و همکاران (Azarakhsh *et al.*, 2022) به بررسی مدل‌سازی و پیش‌بینی فرونشست زمین با استفاده از سری زمانی Sentinel-1 و الگوریتم‌های یادگیری ماشین پرداختند. آن‌ها از مدل جنگل تصادفی (RF) و شبکه‌های عصبی مصنوعی (ANN) استفاده کردند و نتایج نشان داد که مدل RF عملکرد بهتری نسبت به ANN داشت که با یافته‌های مطالعه حاضر همخوانی دارد. نتایج تجربی مدل‌سازی LS نشان دادند که RF بهتر از ANN عمل کرد، که نشان‌دهنده نتایج قوی‌تر و قابل اعتمادتر با مقدار ناحیه مورد مطالعه است. مختاری و همکاران (Mokhtari *et al.*, 2019) به مدل‌سازی خطر وقوع فرونشست زمین را با استفاده از الگوریتم جنگل تصادفی و یازده متغیر محیطی مؤثر بر وقوع فرونشست پرداختند. ارزیابی نتایج مدل نشان‌دهنده دقت بسیار مناسب مدل (۸۶٪ درصد) بود. در مطالعه ما، مدل RF نتایج بسیار خوبی را ارائه داد که نتایج این مطالعات با نتایج ما همخوانی دارند.

نتیجه‌گیری کلی

در این مطالعه میزان فرونشست برای توالی‌های کاربری اراضی (شامل مرتع، باغ، کشاورزی، اراضی بایر و اراضی مسکونی) تحت پارامترهای مختلف اقلیمی (بارش و دما) در دشت داراب، استان فارس بررسی شد. پس از آن، تأثیر تغییرات کاربری اراضی بر میزان فرونشست زمین در بازه زمانی ۲۰۱۵ تا ۲۰۲۴ ارزیابی شد. علاوه بر این، رابطه بین کاربری اراضی اقلیم و نرخ فرونشست پیش‌بینی شده و ترسیم میزان فرونشست بر اساس کاربری اراضی با استفاده از الگوریتم‌های یادگیری ماشین ارزیابی شد. نوسانات اقلیمی و کاربری در راستای آن، تغییرات تراز آب زیرزمینی مهم‌ترین عامل مؤثر در بروز فرونشست زمین در منطقه داراب بودند. تعداد هفت نقشه فرونشست زمین از سال ۲۰۱۵ تا سال ۲۰۲۴ با کمک نرم‌افزار SNAP استخراج شدند. از تصاویر Sentinel-2 استفاده شد و با استفاده از روش تداخل‌سنجی راداری (InSAR) و سپس با کمک نرم‌افزار ArcGIS و روش Raster Calculator میانگینی بین تصاویر گرفته شد که مقدار میانگین فرونشست زمین در این بازه سالی حدود ۱۱ سانتی‌متر بود (شکل ۵). با استفاده از آمار چاه‌های پیزومتری مربوط به سال‌های ۲۰۰۱ تا ۲۰۲۱ منطقه، نقشه‌های تراز آب زیرزمینی دشت با کمک نرم‌افزار ArcGIS و مدل IDW

درون‌یابی شدند. سطح آب‌زیرزمینی از ۱۴۱۱ به ۱۴۲۹ متر رسید. بیشترین حجم برداشت مربوط به شمال دشت بود. افزایش عمق آب زیرزمینی رابطه مستقیمی با افزایش نشست در منطقه داشت. با توجه به شکل ۶ و استفاده از الگوریتم SHAP یا "SHapley Additive exPlanations" در محیط نرم‌افزار RStudio به ما کمک می‌کند تا بفهمیم هر ویژگی چقدر بر خروجی مدل تأثیر دارد و جهت این تأثیر چگونه است. در نمودار فوق، محور افقی نشان‌دهنده مقدار SHAP (تأثیر ویژگی بر خروجی مدل) است و محور عمودی شامل فهرستی از ویژگی‌ها است که در تحلیل داده‌های فرونشست استفاده شده‌اند. متغیر بارندگی به‌طور عمده تأثیر منفی بر پیش‌بینی فرونشست داشت، به خصوص وقتی که مقادیر آن بالا بودند (رنگ قرمز نشان‌دهنده مقادیر بالا است). دما نیز تأثیری مشابه با بارندگی دارد ولی شدت آن کمتر به‌نظر می‌رسد. شاخص رطوبت توپوگرافی دارای تأثیر نسبتاً قابل توجهی بود که بالا بودن مقدار این شاخص در بیشتر موارد اثر مثبت داشت. سطح آب زیرزمینی نیز نقش مهمی ایفا کرد و تغییرات آن می‌تواند هم اثر مثبت و هم منفی بسته به مقادیر مختلف داشته باشند. حضور گسل‌ها اثرات متنوعی دارد اما بیشتر در جهت کاهش احتمال وقوع فرونشست عمل کرده‌اند. به‌طور کلی، نمودار نشان‌دهنده ترکیب پیچیده‌ای از عوامل طبیعی و انسانی مؤثر بر فرونشست زمین‌ها است که برخی دارای اثرات مستقیم‌تر مانند بارندگی هستند در حالی که برخی دیگر مثل گسل یا فعالیت‌های انسان‌ساخت مانند کشاورزی اثری پیچیده‌تر دارند.

با توجه به نقشه‌های رگرسیونی و پارامترهای اعتبارسنجی، از بین مدل‌های پیش‌بینی مدل RF با ضریب تبیین بالاتر ($R^2=0.95$ (Training), 0.93 (validation)) و خطای جذر میانگین مربعات پایین‌تر ($RMSE=0.001$ (Training), 0.002 (validation)) بهترین نتیجه را ارائه می‌دهد. پدیده فرونشست زمین یکی از مشکلات جدی و رو به افزایش در بسیاری از نقاط جهان، به‌ویژه در کشور ما است. این پدیده نه تنها می‌تواند به زیرساخت‌ها و ساختمان‌ها آسیب بزند، بلکه پیامدهای اجتماعی و اقتصادی ناگواری را نیز به‌همراه دارد. برای مقابله با این چالش بزرگ، کشور نیازمند عزم ملی است تا بتواند این پدیده را به‌عنوان یک معضل اساسی شناسایی کند و با آن مواجه شود. اولین گام در این مسیر، اجرای مطالعات جامع برای شناسایی دقیق نواحی مستعد فرونشست است. چنین طرح‌هایی باید تحت یک برنامه ملی انجام شوند تا اطلاعات کافی درباره وضعیت جغرافیایی، زیستی و اقلیمی مناطق مختلف جمع‌آوری گردد. شناخت دقیق مناطق آسیب‌پذیر می‌تواند پایه‌گذار تصمیمات مؤثر جهت مدیریت منابع آب زیرزمینی باشد که خود یکی از عوامل کلیدی در بروز پدیده فرونشست محسوب می‌شود. از سوی دیگر،

کاربری اراضی صورت گیرد تا استانداردهای لازم پایداری بناها مطابق با واقعیت‌های موجود تعریف شوند. به طور کلی، بررسی تأثیر تغییرات اقلیمی و تغییرات کاربری اراضی بر روی وقوع فرونشست نیازمند رویکرد چندجانبه‌ای است که شامل پژوهش علمی دقیق، آگاهی‌دهی عمومی مؤثر، همکاری بین بخشی میان نهادهای و شهروندان باشد. تنها با اتخاذ چنین رویکرد همه‌جانبه‌ای می‌توان ضمن کاهش خطرات احتمالی ناشی از این پدیده طبیعی فاجعه‌آمیز، آینده‌ای ایمن‌تر برای جامعه ساخت.

آگاهی‌رسانی عمومی درباره پیامدهای ناشی از فرونشست زمین ضروری است. لازم است تا زیرساخت‌های لازم برای اطلاع‌رسانی فراهم شود تا مردم بتوانند در جریان اطلاعات مربوطه قرار گیرند. ایجاد بستر مناسب برای مشارکت مردم و مسئولان در حل مشکل فرونشست اهمیت زیادی دارد چراکه بدون همکاری عمومی نمی‌توان انتظار داشت که سیاست‌های اجرایی مؤثر واقع شوند. در نهایت، جهت پیشگیری از شدت گرفتن پدیده فرونشست و کاهش عواقب آن، دستگاه‌های ذیربط باید تمامی مقررات ساخت‌وساز را مورد بازنگری قرار دهند. این بازنگری باید بر اساس شرایط جدید اقلیمی و

References

- Abedi, F., Amirian-Chakan, A., Faraji, M., Taghizadeh-Mehrjardi, R., Kerry, R., Razmjoue, D., & Scholten, T. (2021). Salt dome related soil salinity in southern Iran: Prediction and mapping with averaging machine learning models. *Land Degradation & Development*, 32(3), 1540-1554.
- Abedini, M., Ebadi, A., Qala, A. (2022). Investigating the subsidence of Mahidasht plain in Kermanshah province using radar interferometric method. *Geography and Planning*, 26(79), 207-220. [In Persian]
- Armstrong, J. S., & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), 69-80.
- Arabameri, A., Yariyan, P., & Santosh, M. (2021). Land Subsidence Spatial Modeling and Assessment of the Contribution of Geo-Environmental Factors to Land Subsidence: Comparison of Different Novel Ensemble Modeling Approaches. 16 February 2021, PREPRINT (Version 1) available at Research Square, <https://doi.org/10.21203/rs.3.rs-194202/v1>.
- Azarakhsh, Z., Azadbakht, M., & Matkan, A. (2022). Estimation, modeling, and prediction of land subsidence using Sentinel-1 time series in Tehran-Shahriar plain: A machine learning-based investigation. Remote Sensing Applications: *Society and Environment*, 25, 100691.
- Berardino, P., Fornaro, G., Lanari, R., & Sansosti, E. (2002). A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11), 2375-2383.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). Classification and Regression Trees. Boca Raton, Florida: Chapman Hall/CRC.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 12-20. <https://doi.org/10.1023/A:1010933404324>.
- Bhattarai, R., Alifu, H., Maitiniyazi, A., & Kondoh, A. (2017). Detection of land subsidence in Kathmandu Valley, Nepal, using DInSAR technique. *Land*, 6(2), 39.
- Chitsazan, M., Rahmani, G., & Ghafoury, H. (2022). Land subsidence susceptibility mapping using PWRSTFAL frame- work and analytic hierarchy process: fuzzy method (case study: Damaneh-Daran Plain in the West of Isfahan Province, Iran). *Environmental Monitoring and Assessment*. 194(3), 192.
- Cigna, F., & Tapete, D. (2021). Present-day land subsidence rates, surface faulting hazard and risk in Mexico City with 2014-2020 Sentinel-1 IW InSAR. *Remote Sensing of Environment* 253, 112161.
- Deng, Z., Ke, Y., Gong, H., Li, X., Li, Z., (2017). Land subsidence prediction in Beijing based on PS-InSAR technique and improved Grey-Markov model. *GIS Science and Remote Sensing*, 54(6), 797-818.
- Dai, K., Li, Z., Tomás, R., Liu, G., Yu, B., Wang, X., ... & Stockamp, J. (2016). Monitoring activity at the Daguangbao mega-landslide (China) using Sentinel-1 TOPS time series interferometry. *Remote Sensing of Environment*, 186, 501-513.
- Eghrari, Z., Delavar, M.R., Zare, M., Beitollahi, A., & Nazari, B. (2023). Land subsidence susceptibility mapping using machine learning algorithms. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 129-136.
- Gharechae, H., Samani, A.N., Sigaroodi, S.K., Baloochiyan, A., Moosavi, M.S., Hubbart, J.A., & Sadeghi, S.M. (2023). Land subsidence susceptibility mapping using Interferometric Synthetic Aperture Radar (InSAR) and machine learning models in a semiarid region of Iran. *Land*, 12(4), 843.
- Freeze, R. A. (2000). Social decision making and land subsidence. In Land subsidence—proceeding of the 6th international symposium on land subsidence, 1, 353-384.
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., ... & Alsdorf, D. (2007). The shuttle radar topography mission. *Reviews of Geophysics*, 45(2).
- Fathian, H., Hashemi, S. A., & Alirezaei, M. (2021). Water resources management and land subsidence: A review. *Journal of Hydrology*, 602, 126579.
- Gambolati, G., & Teatini, P. (2015). Geomechanics of subsurface water withdrawal and injection. *Water Resources Research*, 51(6), 3922-3955.

- Godschalk, D. R. (2003). Urban hazard mitigation: Creating resilient cities. *Natural Hazards Review*, 4(3), 136-143.
- Galloway, D. L., & Burbey, T. J. (2011). Regional land subsidence accompanying groundwater extraction. *Hydrogeology Journal*, 19(8), 1459.
- Goli, A., Moradi, M., & Dehghani, M. (2019). Land subsidence vulnerability assessment of rural settlements in Fars Province. *Journal of Research & Rural Planning*, 8(4), 91-106. [In Persian]
- Hu, J., Li, Z., Zhu, J., Ren, X., & Ding, X. (2010). Inferring three-dimensional surface displacement field by combining SAR interferometric phase and amplitude information of ascending and descending orbits. *Sci. China-Earth Science*. 53(4), 550–560. <https://doi.org/10.1007/s11430-010-0023-1>.
- Herrera-García, G., Ezquerro, P., Tomás, R., Béjar-Pizarro, M., López-Vinielles, J., Rossi, M., Ye, S., (2021). Mapping the global threat of land subsidence. *Science*, 371(6524), 34-36.
- Kariminejad, N., Hosseinalizadeh, M., Pourghasemi, H.R., Bernatek-Jakiel, A., Campetella, G., Ownegh, M., (2019). Evaluation of factors affecting gully headcut location using summary statistics and the maximum entropy model: Golestan Province, NE Iran. *Science of the Total Environment*, 677, 281-298.
- Jin, B., Zeng, T., Wang, T., Zhang, Z., Gui, L., Yin, K., & Zhao, B. (2024). Advanced risk assessment framework for land subsidence impacts on transmission towers in salt lake region. *Environmental Modelling & Software*, 177, 106058.
- Khorrami, M., Abrishami, S., & Maghsoudi, Y. (2020). Mashhad Subsidence Monitoring by Interferometric Synthetic Aperture Radar Technique. *Amirkabir Journal of Civil Engineering*, 51(6), 1187-1204. [In Persian]
- Khajeh, M., Bagherafshan, A., Vagharehfar, H., & Ismailpour, Y. (2014). A quantitative and qualitative study of groundwater resources in the Parisean Plain. <https://civilica.com/doc/2150774>. [In Persian]
- Lee, S., & Park, I. (2013). Application of decision tree model for the ground subsidence hazard mapping near abandoned underground coal mines. *Journal of Environmental Management*, 127, 166-176.
- Lukas, P., Melesse, A. M., & Kenea, T. T. (2023). Prediction of future land use/land cover changes using a coupled CA-ANN model in the upper omo–gibe river basin, Ethiopia. *Remote Sensing*, 15(4), 1148.
- Lopez-Alvarez, B., Ramos-Leal, J. A., Santacruz-De Leon, G., Morán-Ramírez, J., Carranco-Lozada, S. E., & Noyola-Medrano, C. (2013). Subsidence associated with land use changes in urban aquifers with intensive extraction. *Natural Science*, 5(2A), 291-295. <https://doi.org/10.4236/ns.2013.52A041>
- Minderhoud, P. S. J., Coumou, L., Erban, L. E., Middelkoop, H., Stouthamer, E., & Addink, E. A. (2018). The relation between land use and subsidence in the Vietnamese Mekong delta. *Science of the Total Environment*, 634, 715-726.
- Mohammadhasani, M., Behnaz Sheikhshariati Kermani, M. (2021). Determining the Rate of Land Subsidence using Radar Interferometry Technique (Case Study: Industrial Area West of Kerman). *Transportation Research Paper*, 18(3), 75-90. [In Persian]
- Mokhtari, D., Ebrahimi, H., & Salmani, S. (2019). Land subsidence susceptibility modeling using random forest approach (Case study: Tasuj plane catchment). *RS & GIS for Natural Resources*, 10(3), 93-105. [In Persian]
- Mohammady, M., Pourghasemi, H.R., & Amiri, M. (2019). Land subsidence susceptibility assessment using random for- est machine learning algorithm. *Environmental Earth Sciences*, 78, 1-12.
- Naghbi, S.A., Pourghasemi, H.R., & Dixon, B. (2016). GIS-based groundwater potential mapping using boosted regres- sion tree, classification and regression tree, and random forest machine learning models in Iran. *Environmental Monitoring and Assessment*, 188, 1-27.
- Najafi, Z., Pourghasemi, H.R., Ghanbarian, G., & Fallah Shamsi, S.R. (2020). Land-subsidence susceptibility zonation us- ing remote sensing, GIS, and probability models in a Google Earth Engine platform. *Environmental Earth Sciences*, 79, 1-16.
- Nguyen, M., Lin, Y. N., Tran, Q. C., Ni, C. F., Chan, Y. C., Tseng, K. H., & Chang, C. P. (2022). Assessment of long-term ground subsidence and groundwater depletion in Hanoi, Vietnam. *Engineering Geology*, 299, 106555.
- Najafi, Z., Pourghasemi, H. R., Ghanbarian, G., & Shamsi, S. R. F. (2022). Identification of land subsidence prone areas and their mapping using machine learning algorithms. In *Computers in Earth and Environmental Sciences* (pp. 535-545). Elsevier.
- Nhu, V.H., Shirzadi, A., Shahabi, H., Singh, S.K., Al-Ansari, N., Clague, J.J., Ahmad, B.B. (2020). Shallow landslide susceptibility mapping: a comparison between logistic model tree, logistic regression, naïve Bayes tree, artificial neural network, and support vector machine algorithms. *International Journal of Environmental Research and Public Health*, 17(8), 2749.
- Poland, J. F. (1984). Guidebook to studies of land subsidence due to ground-water withdrawal.
- Shen, S. L., Ma, L., Xu, Y. S., & Yin, Z. Y. (2013). Interpretation of increased deformation rate in aquifer IV due to groundwater pumping in Shanghai. *Canadian Geotechnical Journal*, 50(11), 1129-1142.
- Shafiei, N., GoliMokhtari, L., Ahmadi, A. A., Zandi, R. (2020). Investigation of subsidence of Noorabad plain aquifer using radar interferometry method. *Quantitative Geomorphology Research*, 8(4), 93-111. [In Persian]
- Shen, S. L., Wu, H. N., Cui, Y. J., & Yin, Z. Y. (2014). Long-term settlement behaviour of metro tunnels in the soft deposits of Shanghai. *Tunnelling and Underground Space Technology*, 40, 309-323.

- Shen, S. L., Wu, Y. X., & Misra, A. (2017). Calculation of head difference at two sides of a cut-off barrier during excavation dewatering. *Computers and Geotechnics*, 91, 192-202.
- Taghizadeh Mehrjardi, R., Khorad, K., Sadeghinia, M., Zolghadri, A. (2014). Investigating the efficiency of geostatistical methods for zoning groundwater salinity (Case Study: Fars Province). The Second National Conference on Desert Management in Arid and Desert Regions, Semnan. <https://civilica.com/doc/329515>. [In Persian]
- Ren, T., Gong, W., Gao, L., & Zhao, F. (2024). Understanding land subsidence in the Pearl River Delta region of China based on InSAR observations. *Engineering Geology*, 107646.
- Rahmati, O., Falah, F., Naghibi, S.A., Biggs, T., Soltani, M., Deo, R.C., & Bui, D.T. (2019). Land subsidence modelling using tree-based machine learning algorithms. *Science of the Total Environment*, 672, 239-252.
- Tomás, R., Herrera, G., Cooksley, G., & Mulas, J. (2011). Persistent Scatterer Interferometry subsidence data exploitation using spatial tools: The Vega Media of the Segura River Basin case study. *Journal of Hydrology*, 400(3-4), 411-428.
- Vapnik, V. (1995). The nature of statistical learning theory. New York, NY: *Springer Verlag*.
- Vapnik, V. (1998). Three remarks on the support vector method of function estimation.
- Wang, B., Zhao, C., Zhang, Q., Lu, Z., & Pepe, A. (2021). Long-term continuously updated deformation time series from multisensor InSAR in Xi'an, China from 2007 to 2021. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 7297-7309.
- Wang, X., Liu, G., Yu, B., Dai, K., Zhang, R., Ma, D., & Li, Z. (2015). An integrated method based on DInSAR, MAI and displacement gradient tensor for mapping the 3D coseismic deformation field related to the 2011 Tarlay earthquake (Myanmar). *Remote Sensing of Environment*, 170, 388-404.
- Wang, X. W., Yang, T. L., Xu, Y. S., & Shen, S. L. (2019). Evaluation of optimized depth of waterproof curtain to mitigate negative impacts during dewatering. *Journal of Hydrology*, 577, 123969.
- Wu, H. N., Shen, S. L., & Yang, J. (2017). Identification of tunnel settlement caused by land subsidence in soft deposit of Shanghai. *Journal of Performance of Constructed Facilities*, 31(6), 04017092.
- Ye-Shuang, X., Xue-Xin, Y., Shui-Long, S., & An-Nan, Z. (2019). Experimental investigation on the blocking of groundwater seepage from a waterproof curtain during pumped dewatering in an excavation. *Hydrogeology Journal*, 27(7), 2659-2672.
- Xue, F., Lv, X., Dou, F., & Yun, Y. (2020). A review of time-series interferometric SAR techniques: A tutorial for surface deformation analysis. *IEEE Geoscience and Remote Sensing Magazine*, 8(1), 22-42.
- Yin, Z. Y., Karstunen, M., Chang, C. S., Koskinen, M., & Lojander, M. (2011). Modeling time-dependent behavior of soft sensitive clay. *Journal of Geotechnical and Geoenvironmental Engineering*, 137(11), 1103-1113.
- Yin, Z. Y., Zhu, Q. Y., Yin, J. H., & Ni, Q. (2014). Stress relaxation coefficient and formulation for soft soils. *Géotechnique Letters*, 4(1), 45-51.
- Yin, Z. Y., Jin, Y. F., Shen, J. S., & Hicher, P. Y. (2018). Optimization techniques for identifying soil parameters in geotechnical engineering: Comparative study and enhancement. *International Journal for Numerical and Analytical Methods in Geomechanics*, 42(1), 70-94.
- Yousefi, R., Talebbeydokhti, N., Afzali, S. H., Dehghani, M., & Hekmatzadeh, A. A. (2023). Understanding the effects of subsidence on unconfined aquifer parameters by integration of Lattice Boltzmann Method (LBM) and Genetic Algorithm (GA). *Natural Hazards*, 115(2), 1571-1600.
- Zhang, Y., Liu, Y., Zhang, X., Huang, H., Qin, K., Bai, Z., & Zhou, X. (2021). Correlation analysis between land-use/cover change and coastal subsidence in the Yellow River Delta, China: reviewing the past and prospecting the future. *Remote Sensing*, 13(22), 4563.
- Zhou, C., Gong, H., Chen, B., Li, X., Li, J., Wang, X., ... & Duan, G. (2019). Quantifying the contribution of multiple factors to land subsidence in the Beijing Plain, China with machine learning technology. *Geomorphology*, 335, 48-61.
- Zhou, C., Gong, H., Chen, B., Zhu, F., Duan, G., Gao, M., & Lu, W. (2016). Land subsidence under different land use in the eastern Beijing plain, China 2005-2013 revealed by InSAR timeseries analysis. *GIScience & Remote Sensing*, 53(6), 671-688.
- Zhang, L., Arabameri, A., Santosh, M., Pal, S.C., (2023). Land subsidence susceptibility mapping: comparative assessment of the efficacy of the five models. *Environmental Science and Pollution Research*, 1-20.